



FRANKLIN DANIEL INÁCIO

**MACAÚBA - IA: IMPULSIONANDO A PRODUÇÃO
SUSTENTÁVEL DE BIOCOMBUSTÍVEL POR MEIO DA
IDENTIFICAÇÃO AUTOMATIZADA DE PLANTAS
UTILIZANDO INTELIGÊNCIA ARTIFICIAL**

**LAVRAS – MG
2025**

FRANKLIN DANIEL INÁCIO

**MACAÚBA - IA: IMPULSIONANDO A PRODUÇÃO SUSTENTÁVEL DE
BIOCOMBUSTÍVEL POR MEIO DA IDENTIFICAÇÃO AUTOMATIZADA DE PLANTAS
UTILIZANDO INTELIGÊNCIA ARTIFICIAL**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do programa de Pós-Graduação em Agronomia/Fitotecnia, área de concentração em Produção Vegetal, para obtenção do título de Mestre.

Prof. Dr. Adão Felipe dos Santos
Orientador

Prof. Dr. Rafael Peron Castro
Coorientador

**LAVRAS – MG
2025**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Inácio, Franklin Daniel.

Detecção de plantas de macaúba usando drones e inteligência artificial / Franklin Daniel Inácio. - 2025.

61 p.: il.

Orientador(a): Adão Felipe dos Santos.

Coorientador(a): Rafael Peron Castro.

Dissertação (mestrado acadêmico) - Universidade Federal de Lavras, 2025.

Bibliografia.

1. Inteligência Artificial. 2. *Acrocomia aculeata* 3. Drones. I. Santos, Adão Felipe dos. II. Castro, Rafael Peron . III. Título.

FRANKLIN DANIEL INÁCIO

**MACAÚBA - IA: IMPULSIONANDO A PRODUÇÃO SUSTENTÁVEL DE
BIOCOMBUSTÍVEL COM IDENTIFICAÇÃO AUTOMATIZADA DE PLANTAS
ATRAVÉS DE INTELIGÊNCIA ARTIFICIAL**

**MACAÚBA - AI: DRIVING SUSTAINABLE BIOFUEL PRODUCTION THROUGH
AUTOMATED PLANT IDENTIFICATION WITH ARTIFICIAL INTELLIGENCE**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do programa de Pós-Graduação em Agronomia/Fitotecnia, área de concentração em Produção Vegetal, para obtenção do título de Mestre.

APROVADA em 17 de janeiro de 2025.

Dr. Alexandre dos Santos

IFMT

Dr. Rouverson Pereira da Silva

UNESP

Prof. Dr. Adão Felipe dos Santos
Orientador

Prof. Dr. Rafael Peron Castro
Coorientador

**LAVRAS – MG
2025**

*A minha mãe, Ana Aparecida do Rosário Inácio
e aos meus irmãos, pelos quais sou o que sou.*

DEDICO

AGRADECIMENTOS

Agradeço a Deus por me dar forças todos os dias nessa caminhada.

A minha mãe Ana Aparecida do Rosário Inácio, a toda minha família (não vou escrever todos os nomes pois são muitos).

À Universidade Federal de Lavras (UFLA), minha casa durante os últimos doze anos, onde me tornei engenheiro ambiental, agrônomo, cervejeiro e especialista, mas acima de qualquer título essa casa me tornou uma pessoa melhor. Aos servidores do Departamento de Agricultura (DAG) que me auxiliaram durante toda essa jornada, em especial ao corpo docente do Programa de Fitotecnia, que transmitiram seus conhecimentos e agregaram muito a minha formação profissional.

Ao meu orientador Prof. Dr. Adão Felipe dos Santos, pela oportunidade de ingressar na sua equipe, pela confiança e por todos os ensinamentos na área de Agricultura de Precisão e na vida.

Ao meu coorientador Prof. Dr. Rafael Peron Castro, pelos ensinamentos, e pelas oportunidades.

Ao Grupo de Extensão e Pesquisa em Agricultura Digital (GEPAD), por me acolherem e ajudarem durante todo o processo do mestrado. A amizade de vocês foi essencial!

As agências de fomento CAPES, FAPEMIG e CNPq, e a EPAMIG pelo apoio e financiamento de nossas pesquisas.

A todos que de alguma forma contribuíram com o trabalho, muito obrigado!

“Para iludir minha desgraça, estudo.”

(Augusto dos Anjos)

RESUMO GERAL

A substituição de combustíveis fósseis por energias renováveis tem atraído atenção nos últimos tempos. Nesse cenário, a cultura da macaúba (*Acrocomia aculeata*) é uma excelente alternativa, uma vez que possui alto potencial de produção de biocombustível e pode ser uma fonte de extrativismo vegetal, devido a sua ampla ocorrência em ambientes naturais. No entanto, o mapeamento preciso e a quantificação de populações de macaúba visando extrativismo é um desafio, o que dificulta o aproveitamento econômico otimizado. Dessa forma, objetivou-se identificar e contar plantas de macaúba em ambiente nativo por meio de imagens de VANT's (Veículos Aéreos Não Tripulados) ou comumente conhecidos como drone utilizando modelos de inteligência artificial implementados com ajuda do YOLOv8, bem como verificar qual versão (nano, small, medium, large e extralarge) é mais eficaz na detecção das plantas de macaúba. As imagens foram coletadas em duas regiões de ocorrência natural das plantas de macaúba no município de Lavras - MG, Brazil, utilizando câmera RGB acoplada ao drone DJI Mavic 3. No total foram adquiridas 1921 imagens que foram divididas entre treinamento (70%), validação (20%) e teste (10%) e treinadas por 100 épocas cada rede. Os resultados mostram um desempenho elevado para todas as versões do YOLOv8 aplicadas ao mapeamento de macaúba, com precisão acima de 95%. Apesar de ser estabelecido 100 épocas para treinamento, a rede nano teve maior capacidade de aprendizado em 52 épocas de treinamento. O mAP foi elevado em todas as redes, atingindo 98%, com a versão large alcançando esse valor de forma mais precoce com apenas 74 épocas. Em termos de perda, a versão xlarge foi a primeira a atingir os valores mínimos, mas apresentou o pior desempenho no teste, enquanto a versão large se sobressaiu com uma taxa de acerto de 94,71% nas imagens de teste. Esses resultados demonstram o potencial robusto das redes YOLOv8 para aplicações de mapeamento e detecção de plantas com o uso de drones, com destaque para as versões large e nano.

Palavras-chave: *Acrocomia aculeata*; aprendizado profundo; drones; YOLO.

GENERAL ABSTRACT

The replacement of fossil fuels with renewable energy sources has gained significant attention in recent times. In this context, the macaúba palm (*Acrocomia aculeata*) emerges as an excellent alternative due to its high potential for biofuel production and its capacity to serve as a source of plant-based extractivism, given its widespread occurrence in natural environments. However, accurate mapping and quantification of macaúba populations for extractivism purposes remain challenging, hindering optimized economic utilization. Thus, this study aimed to identify and count macaúba plants in native environments using drone imagery combined with artificial intelligence models implemented through YOLOv8. Additionally, it sought to evaluate which version (nano, small, medium, large, and extralarge) is most effective in detecting macaúba plants. Images were collected from two regions with natural occurrences of macaúba in the municipality of Lavras-MG, Brazil, using an RGB camera mounted on a DJI Mavic 3 drone. A total of 1,921 images were captured and divided into training (70%), testing (20%), and validation (10%) datasets, with each network trained over 100 epochs. The results demonstrated high performance across all YOLOv8 versions applied to macaúba mapping, with accuracy exceeding 95%. Although training was set for 100 epochs, the nano version achieved significant learning within 52 epochs. All networks displayed high mAP values, reaching up to 98%, with the large version achieving this value earlier, at just 74 epochs. Regarding loss, the xlarge version was the first to reach minimum values but exhibited the poorest performance during testing, while the large version excelled with an accuracy rate of 94.71% on test images. These findings highlight the robust potential of YOLOv8 networks for mapping and detecting plants using drones, with the large and nano versions standing out.

Keywords: *Acrocomia aculeata*; deep learning; drones; YOLO.

INDICADORES DE IMPACTO

O estudo visou aprimorar as técnicas de mapeamento de plantas de macaúba por meio de drones e redes neurais artificiais, fornecendo embasamento técnico-científico para a identificação precisa e contagem automática. O objetivo foi otimizar o manejo sustentável da macaúba, especialmente em regiões onde a agricultura familiar e o extrativismo desempenham papel fundamental na geração de renda. O mapeamento automatizado permitiu identificar áreas com alto potencial de extração, orientando os pequenos produtores na coleta sustentável dos frutos e auxiliando no planejamento da produção. A difusão dessa tecnologia foi realizada por meio de publicações científicas, participação em eventos técnicos (I Congresso Internacional de Macaúba e II Congresso Nacional de Macaúba) e dias de campo, reunindo agricultores, profissionais da área e representantes de políticas públicas. Entre os 17 Objetivos de Desenvolvimento Sustentável (ODS) da Organização das Nações Unidas (ONU), o estudo está alinhado ao (1), “Erradicação da Pobreza”, ao contribuir para a geração de renda de pequenos produtores por meio do manejo sustentável da macaúba e fortalecimento da economia local. Além disso, apoia o (2), “Fome Zero e Agricultura Sustentável”, uma vez que o uso eficiente dessa tecnologia promove o aumento da produtividade agrícola, otimiza o manejo dos recursos naturais e melhora a segurança alimentar. Também está alinhado ao (7), “Energia Limpa e Acessível”, ao incentivar o cultivo da macaúba para produção de biocombustíveis, como o biodiesel, reduzindo a dependência de combustíveis fósseis. O estudo reforça o (8), “Trabalho Decente e Crescimento Econômico”, ao promover oportunidades de trabalho para agricultores familiares e incentivar o desenvolvimento de cadeias produtivas sustentáveis. Finalmente, contribui para o (13), “Ação Contra a Mudança Global do Clima”, ao fomentar práticas agrícolas resilientes e mitigar as emissões de gases de efeito estufa por meio da produção de biocombustíveis renováveis. Entre as áreas temáticas da Política Nacional de Extensão, o trabalho impacta na comunicação (1) entre a universidade e os agricultores familiares, fortalecendo o diálogo sobre o uso de novas tecnologias, como drones e redes neurais artificiais, aplicadas ao manejo sustentável da macaúba. Além disso, contribui para o meio ambiente (5), ao promover o extrativismo sustentável e a preservação dos ecossistemas, garantindo o uso responsável dos recursos naturais. O estudo também se insere na área de trabalho (7), ao incentivar a geração de renda para pequenos produtores e extrativistas por meio da coleta planejada de frutos. Na área de tecnologia e produção (8), o projeto inova ao desenvolver métodos precisos de mapeamento automatizado, aumentando a eficiência do manejo agrícola. Por fim, o trabalho impacta no desenvolvimento urbano e rural (9), ao auxiliar no planejamento territorial sustentável, fortalecendo a economia das comunidades rurais e promovendo a melhoria da qualidade de vida no campo.

IMPACT INDICATORS

The study aimed to enhance techniques for mapping macaúba plants using drones and neural networks, providing scientific and technical foundations for the precise identification and automatic counting of these plants. The goal was to optimize the sustainable management of macaúba, especially in regions where family farming and extractivism play a key role in income generation. Automated mapping enabled the identification of areas with high extraction potential, guiding small producers in the sustainable collection of fruits and assisting in production planning. The dissemination of this technology was carried out through scientific publications, participation in technical events, and field days, bringing together farmers, professionals, and public policy representatives. Among the 17 Sustainable Development Goals (SDGs) of the United Nations (UN), the study aligns with (1), "No Poverty," by contributing to the income generation of small producers through sustainable macaúba management and

strengthening the local economy. Additionally, it supports (2), "Zero Hunger and Sustainable Agriculture," as the efficient use of this technology promotes increased agricultural productivity, optimizes the management of natural resources, and improves food security. It is also aligned with (7), "Affordable and Clean Energy," by encouraging the cultivation of macaúba for biofuel production, such as biodiesel, reducing dependence on fossil fuels. The study reinforces (8), "Decent Work and Economic Growth," by promoting job opportunities for family farmers and encouraging the development of sustainable production chains. Finally, it contributes to (13), "Climate Action," by fostering resilient agricultural practices and mitigating greenhouse gas emissions through renewable biofuel production. Among the thematic areas of the National Extension Policy, the work impacts communication (1) between the university and family farmers, strengthening the dialogue on the use of new technologies, such as drones and neural networks, applied to sustainable macaúba management. It also contributes to the environment (5), promoting sustainable extractivism and ecosystem preservation, ensuring the responsible use of natural resources. The study also falls under the area of work (7), by encouraging income generation for small producers and extractivists through planned fruit collection. In the technology and production area (8), the project innovates by developing precise automated mapping methods, increasing the efficiency of agricultural management. Finally, the work impacts urban and rural development (9), by aiding sustainable territorial planning, strengthening the economy of rural communities, and improving the quality of life in the countryside.

LISTA DE FIGURAS

Figura 1 – Subprodutos da cadeia da macaúba.	34
Figura 2 – Município de Lavras - MG (A) Localização das áreas (B) e (C) com presença de indivíduos de Macaúba.	36
Figura 3 – Representação esquemática de todo o processo desde a aquisição das imagens até o treinamento da rede para identificação e contagem de plantas de macaúba em ambientes nativos.	38
Figura 4 – Dimensões das imagens redimensionadas para serem utilizadas na etapa de rotulagem por meio da ferramenta LabelImg sendo: a) 591 x 554 pixels, b) 595 x 595 pixels, c) 2187 x 2123 pixels e d) 13000 x 8400 pixels.	39
Figura 5 – Esquema da arquitetura YOLOv8, destacando o Backbone, Head e Detect, elementos centrais detecção de objetos.	40
Figura 6 – Diferentes resoluções de imagens coletadas por drone para detecção de macaúba em ambiente nativo, em que 0 representa a classe a ser detectada.	43
Figura 7 – Validação do processo de classificação em que (a) representa o alvo identificado e (b) representa o resultado do IoU.	44
Figura 8 – Métricas de avaliação (precision e mAP) das diferentes versões do YOLOv8 sendo, a) nano, b) small, c) medium, d) large e, e) x-large, considerando a época de treinamento na etapa de treino e validação.	45
Figura 9 – Exemplo da variação da classificação em cada rede. a-nano, b-small, c-medium, d-large, e x-large.	47
Figura 10 – Exemplo da variação da classificação em cada rede em diferentes escalas. a-nano, b-small, c-medium, d-large, e x-large.	51

SUMÁRIO

	PRIMEIRA PARTE	13
1	INTRODUÇÃO	13
2	REFERENCIAL TEÓRICO	15
2.1	Cultura da macaúba	15
2.2	Uso de drones na agricultura	17
2.3	Inteligência artificial	19
2.4	Redes neurais convolucionais	20
2.5	Visão computacional	22
	REFERÊNCIAS	26
	SEGUNDA PARTE	31
	ARTIGO 1 – DETECÇÃO E CONTAGEM DE PLANTAS DE MACAÚBA EM AMBIENTES NATIVOS USANDO DRONES E MODELO YOLOV8	31
1	INTRODUÇÃO	33
2	MATERIAL E MÉTODOS	36
2.1	Área de estudo	36
2.2	Aquisição das imagens	37
2.4	Data set	37
2.5	Google colabatory	39
2.6	Deep learning	39
2.7	Métricas de avaliação	41
3	RESULTADOS	43
3.1	Treinamento e validação	43
3.2	Teste	46
4	DISCUSSÃO	49
5	CONCLUSÕES	54
	REFERÊNCIAS	55
	CONSIDERAÇÕES FINAIS	58
	APÊNDICES	59

PRIMEIRA PARTE

1 INTRODUÇÃO

A nova economia, marcada pela integração de conceitos como economia circular, desenvolvimento sustentável e inovação tecnológica, tem buscado soluções capazes de mitigar os efeitos das mudanças climáticas enquanto promovem crescimento econômico. A agricultura, como um dos setores mais impactados pela crise ambiental global, tem se transformado para atender a essa demanda, buscando espécies vegetais que aliam alto potencial produtivo e baixo impacto ambiental. Nesse contexto, a sustentabilidade emerge como um dos pilares centrais para o desenvolvimento de cadeias produtivas resilientes e adaptadas às novas exigências do mercado global. A identificação e valorização de espécies nativas com características únicas, adaptáveis e de ampla aplicabilidade econômica têm se mostrado estratégias promissoras para enfrentar esses desafios.

Entre as espécies de interesse, destaca-se a macaúba (*Acrocomia aculeata*), uma palmeira nativa da América Central e do Sul, cuja maior concentração populacional encontra-se no Brasil. A macaúba apresenta características multifuncionais que a tornam uma alternativa estratégica para aplicações industriais, especialmente no setor de biocombustíveis, onde se destaca pela elevada produtividade de óleo – que pode alcançar até 6 toneladas por hectare (Batista *et al.*, 2019). Além disso, seus subprodutos possuem ampla aplicabilidade, sendo utilizados para a produção de briquetes, carvão vegetal, alimentos, cosméticos e fertilizantes. Esses atributos tornam a macaúba uma espécie relevante não apenas para a economia sustentável, mas também para programas de recuperação de áreas degradadas, dada sua adaptabilidade a condições de solo e clima variados.

Entretanto, apesar de suas vantagens, a macaúba enfrenta barreiras técnicas e operacionais que limitam seu uso em larga escala. Um dos principais desafios está relacionado à quebra de dormência de suas sementes, um processo essencial para garantir taxas de germinação adequadas em cultivos comerciais. Além disso, há uma lacuna significativa no conhecimento fitotécnico da planta, incluindo práticas de manejo, métodos de propagação e estratégias de colheita, o que tem levado a promoção de diversas políticas e incentivo ao desenvolvimento de ciência e tecnologia em diversas partes do Brasil. Contudo, a ausência de informações padronizadas tem mantido o cultivo de macaúba a pequenas áreas. Esse fato abre uma lacuna para o potencial de práticas extrativistas, principalmente devido a ampla dispersão natural da planta em diversas partes do Brasil e em pequenas propriedades.

Para viabilizar esse tipo de atividade extrativista, o uso de tecnologias emergentes, como drones e inteligência artificial, pode ajudar nesse processo, revolucionando a forma como áreas nativas de vegetação são mapeadas e monitoradas. Essas tecnologias em conjunto são capazes de coletar dados em massa e transformá-los em informações. Para isso, diversos tipos de modelos de aprendizado de máquina estão disponíveis, os quais são capazes de aprender padrões e automatizar o processo de identificação e contagem de plantas de macaúba. Entre os modelos mais avançados de aprendizado profundo, a arquitetura YOLOv8 (You Only Look Once) tem se mostrado particularmente promissora na detecção de objetos em tempo real. A utilização do YOLOv8 para mapear populações de macaúba representa uma oportunidade de integrar avanços tecnológicos ao desenvolvimento de estratégias de manejo e conservação dessa espécie.

Assim, este trabalho tem como objetivo implementar e avaliar a eficácia do modelo YOLOv8 na tarefa de identificação e contagem de plantas de macaúba em áreas nativas. Para isso, foram comparadas diferentes versões do modelo (nano, small, medium, large e xlarge), com o intuito de identificar a configuração que oferece o melhor desempenho em termos de precisão e mAP (mean Average Precision). Os resultados demonstram as possibilidades do uso de técnicas de inteligência artificial aliadas a drones para a detecção em escala de plantas de macaúba em ambientes nativos, consolidando o papel de tecnologias inovadoras no contexto da agricultura digital e da conservação ambiental.

2 REFERENCIAL TEÓRICO

2.1 Cultura da macaúba

Parte do mundo encontra-se em um processo de transição, onde uma economia visando a produção intensiva está sendo substituída por um modelo de produção de baixa emissão de carbono. Neste contexto, a produção sustentável usando recursos renováveis torna-se importante pra suprir as necessidades humanas (Vargas-Carpintero *et al.*, 2022). Nessa linha de pensamento surgiu, na última década, a ideia de bioeconomia que é uma economia baseada em energias renováveis em detrimento a queima de combustíveis fósseis (Vargas-Carpintero *et al.*, 2021). Esse novo modelo econômico chamada bioeconomia carece de um suprimento sustentável de biomassa, e envolve a complexidade de vários fatores ligado ao uso da terra, biodiversidade, questões climáticas e ambientais (Vargas-Carpintero *et al.*, 2021).

Pensando nesse modelo é inevitável a procura de espécies vegetais cuja finalidade seja o mais plural possível, com indivíduos que possam ser aproveitados com o mínimo de perdas. A macaúba (*Acrocomia aculeata*) é uma palmeira nativa da América central e do sul (Souza *et al.*, 2016), de caráter perene que cresce até 15 metros de altura e é alternativa viável para a bioeconomia. A planta de macaúba possui estipe cilíndrico fusiforme e é coroado por até 40 folhas pinadas que variam entre 4 e 5 metros de comprimento. É uma espécie monóica que apresenta floração sazonal enquanto a sua frutificação ocorre durante o ano todo (Colombo *et al.*, 2018), e é encontrada em quase todo o território brasileiro, surgindo frequentemente em áreas de pastagem, floresta degradadas e em associação com outras culturas (Alfaro-Solís *et al.*, 2020). Além disso, é considerada uma alternativa promissora para substituir o óleo vegetal para combustível e para a indústria cosmética e alimentícia devido as suas especificidades (Sant'ana *et al.*, 2023).

A cultura da macaúba possui ampla aplicação de interesses econômicos, que abrange desde a alimentação, passando pela indústria ligada a cosméticos até a produção de biocombustível (Oliveira *et al.*, 2021; Sant'ana *et al.*, 2023). A planta resiste bem e é adaptada as variações edafoclimáticas do estado de Minas Gerais, e por isso tem sido usada em programas de recuperação de áreas degradadas em função das suas características de adaptabilidade (EPAMIG, 2011).

A macaúba tem importância na alimentação, tanto animal quanto humana. Os óleos produzidos pelo fruto da palmeira são divididos em dois grupos: o óleo da polpa e o óleo da amêndoa e ambos possuem características químicas e econômicas de grande relevância, uma vez que algumas de suas características assemelham-se ao azeite (Sant'ana *et al.*, 2023). No

que diz respeito a alimentação animal, alguns trabalhos mostram que a polpa da macaúba pode ser um bom substituto para alimentação de suínos em substituição ao milho sem reduzir o desempenho de ganho de peso e qualidades sensoriais da carne (Moreira *et al.*, 2022).

A polpa e a amêndoa da macaúba são as frações do fruto que despertam interesse industrial. Os grãos, que correspondem a 5-7% da massa do fruto, são ricos em óleo, proteínas possuindo entre 14,5 e 30,1% de matéria seca (MS) e fibras insolúveis (13,1 - 27,2% MS). O óleo extraído das sementes é composto principalmente de ácido láurico, que representa de 33% a 51% do total de ácidos graxos, tornando-o altamente adequado para aplicações alimentícias e cosméticas. Após a extração do óleo, é deixado um farelo rico em proteínas do caroço da macaúba, que é atualmente utilizado como ração animal de baixo valor ou descartado. No entanto, a farinha de caroço de macaúba sem óleo possui um alto teor de aminoácidos essenciais contendo enxofre e, portanto, pode ser uma nova fonte de proteínas vegetais (Toledo; Silva *et al.*, 2022).

No que tange a questão energética, a macaúba tem grande relevância, uma vez que a palmeira apresenta características apropriadas para a produção de biodiesel sendo que seus frutos possuem elevados teores de óleos (Souza *et al.*, 2016) e a planta possui produtividade alta chegando na casa de 6 toneladas de óleo por hectare (Batista *et al.*, 2019). Os resíduos da produção de biodiesel de macaúba podem ser aproveitados como alternativa ao pinus na produção de briquetes (Costa *et al.*, 2019) e o endocarpo pode ser usado na produção de carvão vegetal que é aproveitado alternativamente na siderurgia, metalurgia entre outros (Evaristo *et al.*, 2016).

A macaúba ainda não é domesticada, e seus atributos ainda precisam de pesquisas uma vez que foram estudados apenas genótipos silvestres no Brasil (Alfaro-Solís *et al.*, 2020). Apesar de a macaúba ser fonte promissora de matéria prima para a indústria de biocombustíveis nos próximos anos, ainda não temos tecnologias nas mais variadas áreas da produção da cultura (Villar *et al.*, 2016). Existem dificuldades específicas para a germinação da semente (Souza *et al.*, 2016) e pouco se sabe sobre métodos de produção de mudas, sistemas de produção, aspectos genéticos, fitossanidade, nutrição e materiais de origem (Pimentel *et al.*, 2016).

Pensando primeiramente em uma perspectiva extrativista e, posteriormente, em coleta de material genético, um primeiro passo nos estudos seria o mapeamento de áreas nativas da espécie usando drones e Inteligência Artificial.

2.2 Uso de drones na agricultura

A agricultura tem enfrentado desafios cada vez mais complexos, como o aumento da demanda por alimentos, a necessidade de práticas sustentáveis e as mudanças climáticas (Canicatti; Vallone, 2024). Nesse contexto, os drones emergem como ferramentas cruciais para transformar as práticas agrícolas, trazendo benefícios significativos em termos de eficiência, produtividade e sustentabilidade (Kim; Park; Lee, 2018). Sua capacidade de captar dados detalhados e fornecer informações em tempo real sobre grandes áreas agrícolas torna-os indispensáveis para o manejo moderno de culturas. Conforme informações da Agência Nacional de Aviação Civil (ANAC), o Brasil possui atualmente 184216 drones cadastrados (ANAC, 2025). O cadastro é obrigatório para aeronaves não tripuladas de uso recreativo (aeromodelos) ou uso não-recreativo (aeronaves remotamente pilotadas) das classes 2 e 3. O cadastramento é realizado por meio do Sistema de Aeronaves Não Tripuladas (SISANT).

No campo agrícola, é importante compreender os conceitos básicos e as definições que envolvem os drones. De acordo com a Organização Internacional de Aviação Civil (ICAO, 2015), um drone ou Veículo Aéreo Não Tripulado (UAV) é definido como uma aeronave operada sem a presença de um piloto a bordo. Já o termo Sistema de Aeronave Não Tripulada (UAS) refere-se ao conjunto composto pela aeronave, o controlador terrestre e os sistemas de comunicação entre ambos (Merwe *et al.*, 2020). Alternativamente, o termo Sistema de Aeronave Pilotada Remotamente (RPAS) descreve um sistema similar, mas que depende de um piloto remoto para operações diretas (Ayamga; Akaba; Nyaaba, 2021). Esses termos destacam diferentes nuances no uso de drones, que podem variar desde dispositivos controlados manualmente até sistemas autônomos programados para seguir rotas predefinidas (Nelson; Gorichanaz, 2019).

Os drones podem ser classificados em várias categorias, dependendo de suas características e funções. Entre os tipos mais comuns estão os multirrotores, que oferecem alta manobrabilidade, mas menor autonomia de voo, e as asas fixas, que são mais eficientes para cobrir grandes áreas devido à sua maior autonomia e capacidade de carga (Hogan *et al.*, 2017; Wallace; Sawyer; Shafazand, 2018). Além disso, existem drones híbridos, que combinam as características de ambos para oferecer flexibilidade e desempenho equilibrado. Essa diversidade permite que os drones sejam adaptados a uma ampla gama de aplicações agrícolas (Merwe *et al.*, 2020).

A funcionalidade dos drones é maximizada pelo uso de sensores, que possibilitam a coleta de dados detalhados sobre as condições das plantações. Dentre esses sensores que podem

ser acoplados aos drones, as câmeras multiespectrais, RGB, sensores térmicos (Haghighattalab *et al.*, 2016) e sensores LIDAR, são os mais usuais dentro do contexto de agricultura de precisão. De modo paralelo, os dados coletados por esses sensores podem ser incorporados a sistemas integrados, por meio de inteligência artificial (Kutyauripo; Rushambwa; Chiwazi, 2023).

Quanto às aplicações, os sensores RGB, por exemplo, são amplamente utilizados devido ao seu custo reduzido e à capacidade de fornecer imagens visuais de alta resolução (Haghighattalab *et al.*, 2016). Esses sensores são ideais para aplicações pontuais, como contagem de plantas e identificação de falhas de plantio, pois oferecem resolução espacial adequada para a identificação dos alvos (Khan *et al.*, 2024). Contudo, eles apresentam limitações importantes, como a ausência de calibração de luminosidade (Zarco-Tejada *et al.*, 2014). Isso significa que, em séries temporais, as variações nas condições de iluminação podem inviabilizar comparações confiáveis, reduzindo sua aplicabilidade em análises que demandam consistência ao longo do tempo (Cavalcant *et al.*, 2021). Por outro lado, é importante ressaltar que, os sensores multiespectrais, possuem melhores aplicações para análises temporais dentro do contexto de agricultura de precisão, além de permitir a captura de dados em diferentes comprimentos de onda do espectro eletromagnético (Grubinger *et al.*, 2025), o que possibilita o cálculo de índices (Pathak; Barzin; Bora, 2018).

É importante ressaltar que os sensores multiespectrais possuem melhores aplicações para análises temporais dentro do contexto de agricultura de precisão (Linero-Ramos *et al.*, 2024; Dong *et al.*, 2024). Esses sensores permitem a captura de dados em diferentes comprimentos de onda do espectro eletromagnético, como as faixas visível (VIS, 400-700 nm) e infravermelho próximo (NIR, 700-1000 nm) (Zhu *et al.*, 2024). Essa capacidade é essencial para calcular índices de vegetação, como NDVI (Normalized Difference Vegetation Index) e SAVI (Soil-Adjusted Vegetation Index), que fornecem informações indiretas sobre o vigor das plantas, conteúdo de clorofila e estresse hídrico (Agrawal; Arafat, 2024).

A interação da radiação eletromagnética com as plantas inclui processos como absorção, reflexão e transmissão (Roy; Behera; Srivastav, 2017). A absorção de energia luminosa em comprimentos de onda específicos ocorre devido à presença de moléculas como clorofila, que absorve fortemente luz azul (cerca de 450 nm) e vermelha (cerca de 670 nm), enquanto reflete mais luz verde, resultando na coloração típica das folhas (Taiz, 2013). No infravermelho próximo, as plantas refletem grande parte da luz devido à estrutura celular do mesofilo, permitindo a distinção entre vegetação saudável e estressada (Tian *et al.*, 2025).

A análise espectral de reflexões permite determinar características como biomassa, teor de água e estresse nutricional antes que esses problemas sejam visíveis a olho nu. Por exemplo, a transição entre os espectros visível e NIR, conhecida como "red edge", é particularmente sensível a mudanças na saúde das plantas e pode ser usada para detecção precoce de doenças ou deficiências (Dong *et al.*, 2024).

No sensoriamento remoto utilizando drones, a escolha da altura do voo é determinante para os resultados obtidos. Voos em altitudes mais baixas oferecem maior resolução espacial, permitindo análises detalhadas, como identificação de padrões específicos e avaliação de condições de plantas individuais (Cavalcanti *et al.*, 2023). Por outro lado, voos em altitudes mais altas cobrem uma área maior em cada sobrevoo, o que é vantajoso para análises de larga escala e economiza tempo operacional. No que tange a custos, sensores multiespectrais são mais caros, quando comparado com sensores RGB (Tsouros; Bibi; Sarigiannidis, 2019).

Dessa forma, quando se pensa no monitoramento de maciços de macaúba em ambiente nativo a escolha do sensor deve ser pensada com cautela, especialmente quando a aplicação é para auxiliar pequenos produtores. Assim, a escolha dos sensores e das estratégias de voo deve ser cuidadosamente considerada com base nos objetivos específicos do mapeamento agrícola (Tsouros; Bibi; Sarigiannidis, 2019). Todavia, apesar de algumas limitações, os drones, combinados com sensores RGB, continuam sendo ferramentas essenciais para otimizar o manejo das culturas, oferecendo uma abordagem prática e eficiente (Guebsi; Mami; Chokmani, 2024).

2.3 Inteligência artificial

O termo "Inteligência Artificial" (IA) foi inicialmente introduzido em 1956 e era usado em um sentido amplo para descrever o emprego de computadores na emulação de comportamento inteligente com a menor interferência humana possível. A Real Academia Espanhola define a IA como a área científica dedicada à criação de programas de computador que executam operações semelhantes às realizadas pela mente humana, como aprendizado e raciocínio lógico. Além disso, a IA envolve uma rede de computação com o propósito de capacitar máquinas a realizar tarefas de maneira similar a seres humanos (Aderemi *et al.*, 2023). Hoje, a IA é um conceito amplo que abrange várias definições dentre elas as redes neurais, aprendizado de máquina e deep learning (Atabecov, 2023). A inteligência artificial é descrita como máquinas inteligentes capazes de computar, automatizar, extrair padrões, detectar anomalias e prever informações de atividades com capacidade semelhante de um humano, mas com o poder de processamento de computadores (Aderemi *et al.*, 2023).

As máquinas aprendem basicamente de 3 formas: aprendizado supervisionado, não supervisionado e com reforço. Tanto abordagens supervisionadas quanto não supervisionadas desempenham um papel crucial na construção de sistemas de classificação. As abordagens supervisionadas empregam informações prévias sobre as classes para treinar um modelo de classificação. Alguns dos algoritmos populares para classificação supervisionada incluem modelos estatísticos tradicionais, máquinas de vetores de suporte, redes neurais artificiais, o algoritmo k-Nearest Neighbor, entre outros (Singh *et al.*, 2020).

As técnicas de aprendizado não supervisionadas usam algoritmos para agrupar um determinado objeto com base em suas características (Reyes; Villegas, 2018). Vários autores modelam classificação não supervisionada com base em fatores como métricas de similaridade ou dissimilaridade, características dos dados e a função a ser otimizada (Ouali *et al.*, 2020). A grande vantagem das técnicas de treinamento não supervisionado está no fato da economia de tempo para treinar uma rede, uma vez que o próprio algoritmo consegue extrair padrões de uma base de dados e classificar a informação (Guevara *et al.*, 2012).

Segundo Haykin (2005), a aprendizagem de uma Rede Neural Artificial (RNA) é caracterizada como um procedimento no qual os parâmetros ajustáveis são modificados por meio de um processo de interação com o ambiente no qual a rede está operando. Para problemas de regressão e classificação existem abordagens diferentes uma vez que no contexto de problemas de classificação, a finalidade consiste em designar novos inputs a um conjunto específico de classes ou categorias discretas.

2.4 Redes neurais convolucionais

As Redes Neurais Convolucionais (CNNs, do inglês Convolutional Neural Networks) são um tipo avançado de Rede Neural Profunda (DNN) projetadas para superar as limitações das Redes Neurais Feedforward (FFNNs). Elas se destacam por explorar características espaciais bidimensionais das entradas, como imagens, ao mesmo tempo em que reduzem a quantidade de parâmetros durante o treinamento (Zafar *et al.*, 2022).

O primeiro estudo relacionado ao uso de Rede Neural Convolucional (CNN) foi feito por Fukushima, que copiou o funcionamento do córtex visual de um organismo e propôs modelos de Neocognição (Liu *et al.*, 2021). Nos anos 90 foi desenvolvido um algoritmo de aprendizado de máquina, especificamente para a análise de imagens e tarefas de reconhecimento de padrões 2D, incluindo dígitos manuscritos. Com o tempo, a CNN demonstrou grande sucesso em diversas aplicações, tais como visão computacional, análise de dados e muitas outras. Portanto, a CNN se destaca como a principal abordagem para tarefas de

categorização e reconhecimento de imagens (Jhang; Cho, 2019). Cada parte da CNN é composta por três tipos de camadas: camadas convolucionais, camadas de pooling e camadas totalmente conectadas.

A camada convolucional tem como objetivo aprender representações de recursos das entradas e é composta por vários núcleos de convolução que calculam diferentes mapas de recursos aplicando diferentes filtros. Cada núcleo processa regiões locais das entradas de forma iterativa para gerar mapas de características, resultando na saída da camada convolucional, que é um objeto contendo mapas de características (Huang *et al.*, 2023).

A característica fundamental da camada convolucional está em suas conexões esparsa e no compartilhamento de pesos. Uma conexão esparsa resulta que neurônios em diferentes camadas estejam conectados localmente, ou seja, cada camada se conecta apenas com alguns neurônios na camada adjacente. O compartilhamento de pesos permite que cada núcleo de convolução na camada convolucional de um conjunto de recursos produza um novo conjunto de dados. Cada célula, no conjunto de dados, compartilha os mesmos parâmetros de peso e polarização (Guo; Han; Zhang, 2019).

Na camada de convolução ocorre a obtenção dos mapas de características (Momeny *et al.*, 2021) utilizando uma matriz (kernel) que convoluindo, extrai as principais características da imagem (Guo; Han; Zhang, 2019).

A representação matemática das operações feitas nos Kernels é descrita pela fórmula expressa pela equação (1):

$$F_a^q = (j = 1, 2, \dots Y) = \sum_{i=1}^X \sum_{k_1=1}^{K_1} \sum_{k_2=1}^{K_2} W_{[k_1, k_2], b, a} x_{[k_1, k_2], a}^q \quad (1)$$

Em que:

F_a^q : resultado da convolução (ou operação de filtro) para um dado kernel a na camada q da rede neural convolucional. É o valor que resulta da aplicação desse kernel a uma parte específica dos dados de entrada.

Y: É a dimensão do resultado da convolução. Em redes convolucionais, Y refere-se à altura da matriz de saída após a convolução.

X: É a dimensão da entrada. X representa a altura da matriz de entrada (ou mapa de características) que está sendo processada pelo kernel.

K1 e K2: São as dimensões espaciais do kernel. Eles indicam a altura e a largura do kernel. Os kernels são pequenas matrizes que deslizam sobre a entrada para realizar a convolução.

$W_{[K1,K2]b,a}$: Este é o peso associado ao kernel a, na posição [K1, K2], juntamente com um termo de viés b específico para o kernel a. Os pesos W são parâmetros aprendidos pela rede neural durante o treinamento, e o termo de viés b é um parâmetro que ajusta a saída do kernel.

$x_{[K1,K2],a}^q$: representa a entrada da rede neural na posição [K1, K2] da camada à camada q. Em outras palavras, é o valor de entrada da matriz de características da camada a na posição específica [K1, K2] que está sendo processada pelo kernel a.

As camadas de pooling são usadas para subamostragem após a aplicação da camada de convolução (Guo; Han; Zhang, 2019) e podem ser colocadas várias camadas de pooling entre as camadas de convolução. Essas camadas de pooling têm a finalidade de reduzir as dimensões da imagem de entrada, reduzindo assim o número de parâmetros e cálculos necessários. A função de pooling altera a saída da rede em uma localização específica pelo resumo estatístico das saídas das áreas vizinhas (Momeny *et al.*, 2021). Os métodos mais comuns de pooling são pooling máximo, pooling médio e o pooling aleatório (Tian, 2020).

2.5 Visão computacional

Modelos de visão computacional demandam muitos dados para realizar treinamento com o objetivo de realizar a aprendizagem supervisionada. O aprendizado de máquina e o Deep Learning (DL) realizam feitos importantes na localização e identificação de objetos, reconhecimento e representação facial. E diante desses resultados muitas técnicas têm sido utilizadas nas mais variadas aplicações práticas que vão desde a área médica (com diagnósticos precisos com imagens) até a direção autônoma de carros inteligentes (Zheng *et al.*, 2022).

Frequentemente, aplicações de visão computacional nesses cenários possui a capacidade de oferecer maior rapidez, acurácia, eficácia e uniformidade nesses resultados do que a ação humana isoladamente pode atingir (Crossley *et al.*, 2004).

Em agricultura o uso da visão computacional contorna o problema de que muitas vezes os métodos usados para estimar a produtividade são métodos destrutivos. Essas técnicas envolvem a colheita, coleta ou análise de amostras de plantas, solo, ou outros materiais agrícolas de uma maneira que danifica ou destrói a amostra original. Nesse contexto Pipitsunthonsan *et al.* (2023) usaram técnicas de visão computacional para a classificação dos

cachos de dendê levando em consideração a cor, forma e tamanho dos cachos. Este estudo propôs um modelo de aprendizado profundo para classificar os cachos de dendê em quatro categorias: muito maduros, maduros, pouco maduros e verdes. O modelo foi treinado e testado com um conjunto de dados abrangente de 1.575 imagens de 14 variedades de cachos de palmeiras coletadas em diferentes locais de comercialização. Os resultados mostraram que o modelo alcançou uma precisão de 90,26%, demonstrando sua eficácia na classificação dos cachos de dendê com base em características visuais e de tamanho.

Fernandes *et al.* (2022) desenvolveram metodologia de fenotipagem baseada na análise computacional de imagens, a fim de compará-la com a metodologia tradicional de avaliação. Eles avaliaram 16 famílias de meios-irmãos de batata-doce, usando imagens para medir o peso e o número de raízes. Os resultados demonstraram que a análise de imagens permitiu prever com precisão o peso das raízes, mantendo a classificação genotípica e, conseqüentemente, a similaridade entre os ganhos esperados com a seleção, destacando a eficiência dessa abordagem no melhoramento genético da batata-doce. Ainda falando sobre batata-doce Xu *et al.* (2024) desenvolveram um estudo com objetivo de criar um sistema de visão mecânica 3D para estimar o volume de raízes de batata-doce, que é um importante descritor de forma usado na avaliação da qualidade pós-colheita e programas de melhoramento. O sistema usa um sistema de transporte de rolos personalizado para girar as raízes de batata-doce e uma câmera do tipo LIDAR para adquirir imagens de pontos e de profundidade. Foram construídos modelos de regressão usando diferentes abordagens, incluindo regressão linear múltipla (MLR), rede neural rasa (SNN) e rede neural profunda (DNN), com base em características geométricas e imagens de profundidade. Os resultados demonstraram que o modelo DNN pré-treinado obteve a melhor precisão, com 97,9% de acurácia na estimativa de volume, em comparação com os modelos MLR e SNN. Esse sistema de visão mecânica 3D oferece uma medição rápida e online do volume de batata-doce e possui potencial para ser aplicado em outras frutas, oferecendo uma alternativa precisa e eficiente aos métodos tradicionais.

Li e Guan (2023) apresenta uma abordagem que combina um modelo de rede neural leve chamado M-Unet com o algoritmo Semi-Global Block Matching (SGBM) para a amostragem de grãos. Utilizando uma câmera binocular para capturar dados de imagem da área de carregamento de grãos, o método M-Unet é empregado para particionar a imagem e gerar pontos de amostragem aleatórios em regiões predefinidas. O algoritmo SGBM é utilizado para determinar o posicionamento espacial tridimensional desses pontos de amostragem. Resultados experimentais demonstram que essa abordagem oferece desempenho robusto em tempo real e

é adequada para implantação em dispositivos portáteis, contribuindo para melhorar a eficiência dos processos de amostragem de grãos e minimizar perdas de alimentos.

Ye *et al.* (2023) propuseram uma rede neural leve chamada WheatLFANet, projetada especificamente para detectar espigas de trigo de forma precisa e eficiente em dispositivos de baixo custo. A WheatLFANet superou métodos de última geração, alcançando uma alta precisão média AP de 0,900 e um valor R^2 de 0,949 entre valores previstos e valores reais. Além disso, ela foi significativamente mais rápida, mantendo a precisão e a capacidade de generalização, demonstrando a viabilidade da detecção leve e em tempo real de espigas de trigo em dispositivos acessíveis e destacando a utilidade de projetos de redes neurais simples, mas poderosos. Isso tem o potencial de melhorar significativamente o monitoramento de plantações de trigo e a análise de rendimento.

Os sistemas de visão computacional também são usados na detecção de doenças na agricultura. Abbasi, Martinez e Ahmad (2023) desenvolveram um sistema automático de diagnóstico de culturas que detecta estresses bióticos e gerencia doenças em quatro culturas de folhas verdes. O sistema possui três fases. Classificação de culturas, identificação de doenças e detecção de manchas doentes nas folhas, com altas taxas de precisão em cada fase. Além disso, o sistema é integrado a um modelo que fornece conhecimento sobre causas e tratamentos de diferentes doenças das culturas, permitindo que os agricultores tomem medidas preventivas. Essa aplicação se destaca como um sistema de apoio à decisão que automatiza o monitoramento da saúde das instalações aquapônicas e auxilia os profissionais agrícolas na tomada de decisões relacionadas ao manejo de culturas e doenças, contribuindo para a eficiência e a sustentabilidade da agricultura aquapônica.

Para citar trabalhos com qualidade de frutas, Sajitha *et al.* (2023) desenvolveram estudos na detecção da qualidade de bananas por meio do uso de Redes Neurais Convolucionais de Gráficos Embutidos de Conhecimento (KEGCNNs). Essa abordagem converte imagens de bananas em um gráfico de conhecimento, permitindo uma análise mais precisa da qualidade das frutas. Os KEGCNNs são especialmente eficazes para essa tarefa, uma vez que capturam interações contextuais entre as partes da banana, possibilitando um diagnóstico mais preciso da qualidade da fruta. Os resultados demonstram bom desempenho, indicando que essa técnica é adequada para a detecção de qualidade e maturação de bananas, oferecendo uma solução inovadora e precisa para a classificação dessas frutas com base na sua aparência e características.

Trabalhos semelhantes foram feitos em lavouras de palmeiras de óleo. Modelos aprimorados de detecção de plantas conseguiram bons resultados de mAP de 0,94, 0,92 e 0,85

para espécies classificadas em única, dupla e tripla e comparada com modelos do YOLOv5 (Lee *et al.*, 2024). Outro estudo usou o modelo YOLOv7 em 500 imagens de drone, obtendo 99,7% nos valores de mAP na detecção de palmeiras de óleo (Ariyadi; Pribadi; Widiyanto, 2023). Ainda falando de lavouras de palmeiras de óleo, trabalhos ligados ao gerenciamento de lavoura usando métodos de detecção para avaliar a saúde da lavoura foram propostos atingindo até 99,04% de F1 e superando métodos anteriores em até 21,32%, tornando-se promissora para o gerenciamento eficaz de plantações (Zheng *et al.*, 2021).

Trabalhos comparando modelos YOLOv7 e YOLOv8 na detecção de palmeiras de óleo, com o YOLOv8m obtendo a maior precisão (F1 de 99,31%) e o YOLOv8s destacando-se em velocidade de detecção, mostrando-se promissores para monitoramento ambiental eficiente e sustentável de plantações (Shaikh *et al.*, 2024). Além da detecção de palmeiras de óleo, outras plantas são objetos de estudo com a aplicação de deep learning. Redes de aprendizado profundo baseada no YOLOv5 aprimorada com camadas convolucionais alcança 96,1% de precisão e 94,5% de F1 na detecção de árvores de Abeto chinês em florestas densas, superando o YOLOv5 em até 2,6% em várias métricas (Wang *et al.*, 2024). Para a detecção e contagem de árvores *Camellia oleifera* com YOLOv8, usando imagens UAV RGB e um conjunto de dados recortado, mostrou-se eficiente, superando o YOLOv5–YOLOv10 em precisão e mAP 0,82, indicando potencial para estimativas de rendimento e manejo de pomares (Yang *et al.*, 2024). Foi feito trabalhos para a detecção da doença da murcha do Pinheiro (PWD) usando um modelo aprimorado de YOLOv8, obtendo 0,81 de mAP50 oferecendo suporte técnico eficaz para o monitoramento em larga escala de PWD (Wang *et al.*, 2023).

REFERÊNCIAS

- ABBASI, Rabiya; MARTINEZ, Pablo; AHMAD, Rafiq. Crop diagnostic system: A robust disease detection and management system for leafy green crops grown in an aquaponics facility. **Artificial Intelligence in Agriculture**, v. 10, p. 1-12, 2023.
- ADEREMI, Banjo A. *et al.* Groundwater levels forecasting using machine learning models: A case study of the groundwater region 10 at Karst Belt, South Africa. **Systems and Soft Computing**, v. 5, p. 200049, 2023.
- AGRAWAL, Juhi; ARAFAT, Muhammad Yeasir. Transforming Farming: A Review of AI-Powered UAV Technologies in Precision Agriculture. **Drones**, v. 8, n. 11, 2024.
- ALFARO-SOLÍS, Jose David *et al.* *Acrocomia aculeata* fruits from three regions in Costa Rica: an assessment of biometric parameters, oil content and oil fatty acid composition to evaluate industrial potential. **Agroforestry Systems**, v. 94, n. 5, p. 1913-1927, 2020.
- ANAC. Drones. **Agência Nacional de Aviação Civil**, 2025. Disponível em: < <https://www.anac.gov.br/acesso-a-informacao/dados-abertos/areas-de-atuacao/aeronaves/drones-cadastrados/painel-de-drones-cadastrados> >. Acesso em: 08 jan. de 2025.
- ARIYADI, M. Rama Nopan; PRIBADI, Muhammad Rizky; WIDIYANTO, Eka Puji. Unmanned Aerial Vehicle for Remote Sensing Detection of Oil Palm Trees Using You Only Look Once and Convolutional Neural Network. *In*: 2023 10th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI). **IEEE**, p. 226-230, 2023.
- ATABEKOV, Atabek. Artificial intelligence in contemporary societies: legal status and definition, implementation in public sector across various countries. **Social Sciences**, v. 12, n. 3, p. 178, 2023.
- AYAMGA, Matthew; AKABA, Selorm; NYAABA, Albert Apotele. Multifaceted applicability of drones: A review. **Technological Forecasting and Social Change**, v. 167, p. 120677, 2021.
- BATISTA, Cláudia Eliane Dias *et al.* Monitoring the composition in esters of the biodiesel from the macauba (*Acrocomia aculeata* (Jacq.) Lodd. ex Mart.) kernel oil put in direct contact with carbon steel and galvanized carbon steel. **Química Nova**, v. 42, p. 387-396, 2019.
- CANICATTÌ, Marco; VALLONE, Mariangela. Drones in vegetable crops: a systematic literature review. **Smart Agricultural Technology**, p. 100396, 2024.
- CAVALCANTI, Vytória Piscitelli *et al.* Use of RGB images from unmanned aerial vehicle to estimate lettuce growth in root-knot nematode infested soil. **Smart Agricultural Technology**, v. 3, p. 100100, 2023.
- COLOMBO, Carlos Augusto *et al.* Macauba: a promising tropical palm for the production of vegetable oil. **Ocl**, v. 25, n. 1, p. D108, 2018.
- COSTA, Sarah Esther de Lima *et al.* Briquettes quality produced with the macauba epicarp (*Acrocomia aculeata*) and Pinus sp. wood. **Revista Árvore**, v. 43, p. e430501, 2019.

CROSSLEY, S. *et al.* Improving accuracy, robustness and computational efficiency in 3D computer vision. **Image and Vision Computing**, v. 22, n. 5, p. 399-412, 2004.

DONG, Ping *et al.* Research on the Identification of Wheat Fusarium Head Blight Based on Multispectral Remote Sensing from UAVs. **Drones**, v. 8, n. 9, p. 445, 2024.

EPAMIG. Informe agropecuário. **Empresa de Pesquisa Agropecuária de Minas Gerais**, v. 32, n. 265, p. 41-51, 2011.

EVARISTO, Anderson Barbosa *et al.* Energy potential of the macaw palm fruit residues and their use in charcoal production. **Ciencia Florestal**, v. 26, n. 2, p. 571-577, 2016.

FERNANDES, Ana Clara G. *et al.* Viabilidade da visão computacional no melhoramento genético na produção de raízes de batata-doce. **Horticultura Brasileira**, v. 40, p. 378-383, 2023.

GRUBINGER, Samuel *et al.* Seasonal vegetation dynamics for phenotyping using multispectral drone imagery: Genetic differentiation, climate adaptation, and hybridization in a common-garden trial of interior spruce (*Picea engelmannii* × *glauca*). **Remote Sensing of Environment**, v. 317, p. 114512, 2025.

GUEBSI, Ridha; MAMI, Sonia; CHOKMANI, Karem. Drones in precision agriculture: A comprehensive review of applications, technologies, and challenges. **Drones**, v. 8, n. 11, p. 686, 2024.

GUEVARA, M. A. *et al.* Red neural artificial del sistema mesolímbico-cortical que simula el aprendizaje discriminativo y de inversión. **Revista mexicana de ingeniería biomédica**, v. 33, n. 1, p. 8-16, 2012.

GUO, Chenlong; HAN, YuXuan; ZHANG, HuiYing. SAR target recognition based on Gabor filter and convolutional neural network. *In*: 2019 International Conference on Image and Video Processing, and Artificial Intelligence. **SPIE**, p. 269-275, 2019.

HAGHIGHATTALAB, Atena *et al.* Application of unmanned aerial systems for high throughput phenotyping of large wheat breeding nurseries. **Plant Methods**, v. 12, p. 1-15, 2016.

HAYKIN, Simon. Neural networks: a comprehensive foundation. **Pearson Education**, 2. ed., 2005.

HOGAN, Sean D. *et al.* Unmanned aerial systems for agriculture and natural resources. **California Agriculture**, v. 71, n. 1, p. 5-14, 2017.

HUANG, Shui-Yuan *et al.* Image classification and adversarial robustness analysis based on hybrid quantum–classical convolutional neural network. **Optics Communications**, v. 533, p. 129287, 2023.

ICAO. Manual on Remotely Piloted Aircraft Systems (RPAS) (Doc 10019). **ICAO Store**, 2015. Disponível em: < <https://store.icao.int/en/manual-on-remotely-piloted-aircraft-systems-rpas-doc-10019> >.

JHANG, Kyoungson; CHO, Junsoo. CNN training for face photo based gender and age group prediction with camera. *In: 2019 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC)*. **IEEE**, 2019. p. 548-551.

KHAN, Sunawar *et al.* Future of sustainable farming: exploring opportunities and overcoming barriers in drone-IoT integration. **Discover Sustainability**, v. 5, n. 1, p. 1-22, 2024.

KIM, Hong Geun; PARK, Jong-Seok; LEE, Doo-Hyung. Potential of unmanned aerial sampling for monitoring insect populations in rice fields. **Florida Entomologist**, v. 101, n. 2, p. 330-334, 2018.

KUTYAUROPO, Innocent; RUSHAMBWA, Munyaradzi; CHIWAZI, Lyndah. Artificial intelligence applications in the agrifood sectors. **Journal of Agriculture and Food Research**, v. 11, p. 100502, 2023.

LEE, Sheng Siang *et al.* Oil palm tree detection in UAV imagery using an enhanced RetinaNet. **Computers and electronics in Agriculture**, v. 227, p. 109530, 2024.

LI, Jinming; GUAN, Wei. Patch merging refiner embedding UNet for image denoising. **Information Sciences**, v. 641, p. 119123, 2023.

LINERO-RAMOS, Rafael *et al.* Assessment of Dataset Scalability for Classification of Black Sigatoka in Banana Crops Using UAV-Based Multispectral Images and Deep Learning Techniques. **Drones**, v. 8, n. 9, p. 503, 2024.

LIU, Jing-Wei *et al.* Research on improved wavelet convolutional wavelet neural networks. **Applied Intelligence**, v. 51, p. 4106-4126, 2021.

MERWE, Deon van der *et al.* Drones in agriculture. **Advances In Agronomy**, v. 162, p. 1-30, 2020.

MOMENY, Mohammad *et al.* A noise robust convolutional neural network for image classification. **Results in Engineering**, v. 10, p. 100225, 2021.

MOREIRA, Vinicius E. *et al.* Growth performance, carcass and pork quality traits of growing-finishing pigs with high and low breeding values for residual feed intake fed diets with Macauba (*Acrocomia aculeata*) Pulp as alternative raw material. **Agriculture**, v. 12, n. 11, p. 1860, 2022.

NELSON, Jake; GORICHANAZ, Tim. Trust as an ethical value in emerging technology governance: The case of drone regulation. **Technology in Society**, v. 59, p. 101131, 2019.

OLIVEIRA, L. R. *et al.* Classificação do teor de biodiesel metílico de macaúba na mistura cin diesel, por meio da combinação de técnicas analíticas/quimiométricas de espectroscopia MIR e PSL-DA. **Revista Virtual Quim.**, v. 13, n. 1, p. 127-135, 2021.

OUALI, Mohammed *et al.* Controlling 2D Artificial Data Mixtures Overlap. **Computación y Sistemas**, v. 24, n. 3, p. 1075-1091, 2020.

PATHAK, Rohit; BARZIN, Razieh; BORA, Ganesh C. Data-driven precision agricultural applications using field sensors and Unmanned Aerial Vehicle. **International Journal of Precision Agricultural Aviation**, v. 1, n. 1, 2018.

PIMENTEL, Leonardo Duarte *et al.* Substratos, calagem, fosfatagem e adubação de cobertura para produção de mudas de macaúba. **Revista Árvore**, v. 40, v. 2, p. 235-244, 2016.

PIPITSUNTHONSAN, Pronthep *et al.* Palm bunch grading technique using a multi-input and multi-label convolutional neural network. **Computers and Electronics in Agriculture**, v. 210, p. 107864, 2023.

REYES, Patricio Tapia; VILLEGAS, Claudio Meneses. An empirical comparison of EM and K-means algorithms for binning metagenomics datasets. **Ingeniare: Revista Chilena de Ingeniería**, v. 26, p. 20-27, 2018.

ROY, P. S.; BEHERA, M. D.; SRIVASTAV, S. K. Satellite remote sensing: sensors, applications and techniques. **Proceedings of the National Academy of Sciences, India Section A: Physical Sciences**, v. 87, p. 465-472, 2017.

SAJITHA, P. *et al.* Smart farming application using knowledge embedded-graph convolutional neural network (KEGCNN) for banana quality detection. **Journal of Agriculture and Food Research**, v. 14, p. 100767, 2023.

SANT'ANA, Cíntia Tomaz *et al.* Macauba (*Acrocomia aculeata*) pulp oil prevents adipogenesis, inflammation and oxidative stress in mice fed a high-fat diet. **Nutrients**, v. 15, n. 5, p. 1252, 2023.

SHAIKH, Istiyak Mudassir *et al.* Enhancing sustainability in the production of palm oil: Creative monitoring methods using YOLOv7 and YOLOv8 for effective plantation management. **Biotechnology Reports**, v. 44, p. e00853, 2024.

SINGH, Pangambam Sendash *et al.* Local binary ensemble based self-training for semi-supervised classification of hyperspectral remote sensing images. **Computación y Sistemas**, v. 24, n. 2, p. 497-509, 2020.

SOUZA, Patrícia Pereira de *et al.* Tipo de armazenamento no vigor e na viabilidade de sementes de macaúba oriundas de duas localidades do Estado de Minas Gerais. **Ciência Rural**, v. 46, p. 1932-1937, 2016.

TAIZ, L. Fisiologia vegetal. **Artmed**, 5. ed., 952 p., 2013.

TIAN, Fengkai *et al.* Estimating corn leaf chlorophyll content using airborne multispectral imagery and machine learning. **Smart Agricultural Technology**, v. 10, p. 100719, 2025.

TIAN, Youhui. Artificial intelligence image recognition method based on convolutional neural network algorithm. **Ieee Access**, v. 8, p. 125731-125744, 2020.

TSOUROS, Dimosthenis C.; BIBI, Stamatia; SARIGIANNIDIS, Panagiotis G. A review on UAV-based applications for precision agriculture. **Information**, v. 10, n. 11, p. 349, 2019.

VARGAS-CARPINTERO, Ricardo *et al.* A collaborative, systems approach for the development of biomass-based value webs: the case of the *Acrocomia* palm. **Land**, v. 11, n. 10, p. 1748, 2022.

VARGAS-CARPINTERO, Ricardo *et al.* *Acrocomia* spp.: neglected crop, ballyhooed multipurpose palm or fit for the bioeconomy? A review. **Agronomy for sustainable development**, v. 41, n. 6, p. 75, 2021.

VILLAR, Flora Maria de Melo *et al.* Elasticity modulus and damping ratio of macaw palm rachillas. **Ciência Rural**, v. 47, n. 2, p. e20160289, 2016.

WALLACE, Douglas M.; SAWYER, A. M.; SHAFAZAND, S. Comorbid insomnia symptoms predict lower 6-month adherence to CPAP in US veterans with obstructive sleep apnea. **Sleep and Breathing**, v. 22, p. 5-15, 2018.

WANG, Jiansen *et al.* Tree-level chinese fir detection using uav rgb imagery and yolo-dcam. **Remote Sensing**, v. 16, n. 2, p. 335, 2024.

WANG, Shikuan *et al.* Detection of pine wilt disease using drone remote sensing imagery and improved yolov8 algorithm: A case study in weihai, china. **Forests**, v. 14, n. 10, p. 2052, 2023.

XU, Jiajun *et al.* Online volume measurement of sweetpotatoes by A LiDAR-based machine vision system. **Journal of Food Engineering**, v. 361, p. 111725, 2024.

YANG, Renxu *et al.* Camellia oleifera Tree Detection and Counting Based on UAV RGB Image and YOLOv8. **Agriculture**, v. 14, n. 10, p. 1789, 2024.

YE, Jianxiong *et al.* WheatLFANet: in-field detection and counting of wheat heads with high-real-time global regression network. **Plant Methods**, v. 19, n. 1, p. 103, 2023.

ZAFAR, Afia *et al.* A comparison of pooling methods for convolutional neural networks. **Applied Sciences**, v. 12, n. 17, p. 8643, 2022.

ZARCO-TEJADA, Pablo J. *et al.* Tree height quantification using very high resolution imagery acquired from an unmanned aerial vehicle (UAV) and automatic 3D photo-reconstruction methods. **European journal of agronomy**, v. 55, p. 89-99, 2014.

ZHENG, Juepeng *et al.* Growing status observation for oil palm trees using Unmanned Aerial Vehicle (UAV) images. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 173, p. 95-121, 2021.

ZHENG, Wenbo *et al.* Computational knowledge vision: Paradigmatic knowledge based prescriptive learning and reasoning for perception and vision. **Artificial intelligence review**, v. 55, n. 8, p. 5917-5952, 2022.

ZHU, Hongyan *et al.* Using Multi-Sensor Data Fusion Techniques and Machine Learning Algorithms for Improving UAV-Based Yield Prediction of Oilseed Rape. **Drones**, v. 8, n. 11, p. 642, 2024.

SEGUNDA PARTE

ARTIGO 1 – DETECÇÃO E CONTAGEM DE PLANTAS DE MACAÚBA EM AMBIENTES NATIVOS USANDO DRONES E MODELO YOLOV8

RESUMO

A macaúba (*Acrocomia aculeata*) é uma palmeira com elevado potencial econômico e ambiental com diversas utilizações de seus frutos, especialmente quando se pensa na substituição parcial ou total dos combustíveis fósseis convencionais. Este trabalho teve como objetivo explorar o uso de drones e algoritmos de visão computacional baseados na arquitetura YOLOv8 para identificar e quantificar plantas de macaúba em ambientes nativos, com o propósito de contribuir para a otimização de práticas de manejo e atividades extrativistas.. As imagens foram coletadas em áreas nativas utilizando drones, e diferentes versões do YOLOv8 foram treinadas e avaliadas quanto à sua precisão e eficiência. Os resultados mostraram que, independentemente da arquitetura utilizada, todas as redes alcançaram valores superiores a 95% de mean Average Precision (mAP) na etapa de validação, com diferenças na capacidade de generalização. Durante o teste, as redes mais leves, como a nano, demonstraram melhor eficiência computacional, mas menor precisão em relação às arquiteturas intermediárias, como a médium e large, que obtiveram taxas de acerto superiores a 94%. A rede x-large, mais robusta, apresentou sinais de overfitting, uma vez que ela atingiu precisão precoce às 35 épocas na etapa de treinamento e validação. Além disso na etapa de teste o seu desempenho foi inferior as demais redes sendo influenciada pelo fenômeno de dupla decida. Apesar disso, os resultados apresentaram que é possível utilizar drones e inteligência artificial para o monitoramento de plantas de macaúba em ambientes nativos por meio das redes médium e large, considerando a sua precisão e recursos computacionais.

Palavras-chave: Detecção de plantas; inteligência artificial; visão computacional.

ABSTRACT

The macaúba (*Acrocomia aculeata*) is a palm tree with high economic and environmental potential, offering diverse uses for its fruits, particularly in the partial or total replacement of conventional fossil fuels. This study explored the use of drones and computer vision algorithms based on the YOLOv8 architecture to identify and count macaúba plants in native environments, aiming to optimize management and extraction practices. Images were collected in native areas using drones, and different versions of YOLOv8 were trained and evaluated for their accuracy and efficiency. The results showed that all networks achieved mean Average Precision (mAP) values above 95% during validation, regardless of the architecture used, with variations in generalization capacity. During testing, lighter networks such as YOLOv8-nano demonstrated better computational efficiency, but lower accuracy compared to intermediate architectures like YOLOv8-medium and YOLOv8-large, which achieved accuracy rates above 94%. The more robust YOLOv8-xlarge network exhibited signs of overfitting, as it reached an early precision at 35 epochs during training and validation, and its performance during testing was inferior to the other networks, influenced by the double descent phenomenon. Nevertheless, the results demonstrated the feasibility of using drones and artificial intelligence to monitor macaúba plants in native environments through medium and large networks, considering their accuracy and computational resource requirements.

Keywords: Plant detection; artificial intelligence; computer vision.


1 INTRODUÇÃO

A macaúba (*Acrocomia aculeata*) é uma palmeira nativa das regiões tropicais e subtropicais da América Latina, especialmente México, Argentina, Paraguai, e Brasil e é amplamente reconhecida por seu elevado potencial econômico, social e ambiental (Ampese *et al.*, 2023; Aires; Carvalho Junior, 2023). Essa planta desempenha um papel crucial no fortalecimento dos princípios da agricultura circular, permitindo o aproveitamento integral de seus produtos e subprodutos em diversos setores industriais, enquanto promove a sustentabilidade e a geração de renda para comunidades rurais (Vargas-Carpintero *et al.*, 2022; Plath *et al.*, 2016). Por meio de práticas que combinam extrativismo sustentável e inovação tecnológica, a macaúba desponta como uma aliada estratégica na melhoria da qualidade de vida no campo, sendo o seu cultivo impulsionado por políticas públicas existentes, especialmente no Brasil, as quais buscam alternativas promissoras que permitam a substituição parcial ou total dos combustíveis fósseis convencionais (Demirbas, 2009; Demirbas, 2007; César *et al.*, 2015).

No âmbito energético, o óleo extraído dos frutos da macaúba é uma das fontes mais promissoras para a produção de biodiesel, com rendimentos que podem atingir até 6 t ha⁻¹ de óleo por ano (Souza *et al.*, 2016; Batista *et al.*, 2019). Além disso, resíduos do processo de biodiesel podem ser reaproveitados para a produção de briquetes, uma alternativa energética renovável e de baixo custo (Costa *et al.*, 2019), enquanto o endocarpo é utilizado na fabricação de carvão vegetal para siderurgia e metalurgia (Evaristo *et al.*, 2016), bem como na fabricação de bio-concretos (Andrade *et al.*, 2024). Essas possibilidades não apenas promovem o aproveitamento sustentável da planta, mas também criam oportunidades econômicas para pequenos produtores.

Além disso, os frutos da macaúba podem ser utilizados na alimentação animal e humana, bem como na produção de cosméticos, ampliando o potencial de diversificação de renda (Rôxo *et al.*, 2023). A farinha de amêndoas produzida pela castanha do fruto de macaúba, por exemplo, proporcionou menores concentrações de colesterol total e triglicerídeos em testes utilizando camundongos (Duarte *et al.*, 2022). Ainda, quando adicionado o óleo da amêndoa de macaúba para fabricação de maionese e margarina, a textura desses dois produtos foi mais firme e menos coesa que os produtos comerciais (Silva *et al.* 2020).

Figura 1 – Subprodutos da cadeia da macaúba.



Fonte: Do autor (2024).

Para a agricultura familiar, a macaúba apresenta-se como uma fonte valiosa de renda complementar por meio do extrativismo sustentável. A coleta de frutos em sistemas de manejo adequado pode ser realizada de forma não invasiva, preservando a biodiversidade local enquanto gera valor econômico, conforme mencionado nas diversas opções de subprodutos provenientes do fruto da planta. Todavia, para que o extrativismo aconteça, o acesso a informações sobre a localização das plantas é essencial para os agricultores, permitindo o planejamento eficiente das atividades extrativistas. Nesse contexto, técnicas de mapeamento com drones e tecnologias de inteligência artificial, como redes neurais para identificação e contagem de plantas, tornam-se ferramentas estratégicas. Essas técnicas possibilitam a criação de mapas precisos da distribuição de plantas em diferentes áreas, orientando os agricultores familiares sobre os locais para coleta e otimizando o uso sustentável dos recursos naturais.

A identificação de palmeiras utilizando imagens de drones já foi reportada por outros autores, entretanto, considerando o melhor do nosso conhecimento sobre o assunto, todas os algoritmos aplicados em palmeiras nenhum deles explorou a identificação de plantas de

macaúba. Dessa forma, com base nos resultados em que a taxa de precisão na detecção de palmeiras com potencial energético, como dendê, foi maior que 92% com capacidade de distinguir plantas duplas e triplas (Lee *et al.*, 2024), bem como nos trabalhos que utilizaram versões mais recentes do YOLO que encontraram precisão maior que 99% (Ariyadi; Pribadi; Widiyanto, 2023; Zheng *et al.*, 2021; Shaikh *et al.*, 2024) acredita-se que seja possível mapear plantas de macaúba em ambiente natural. Tão logo, esforços que combinam o manejo sustentável da macaúba com o uso de tecnologias inovadoras podem contribuir para alcançar metas de melhoria da vida no campo e a redução das desigualdades rurais. Além disso, o fortalecimento dessa cadeia produtiva pode atrair investimentos em infraestrutura, estimular a capacitação de agricultores e fomentar a economia local, além de integrar práticas sustentáveis às políticas de uso da terra.

Assim, este trabalho visa desenvolver e aplicar uma metodologia baseada em inteligência artificial para detectar e quantificar plantas de macaúba (*Acrocomia aculeata*) em ambientes nativos, utilizando imagens capturadas por câmeras RGB embarcadas em uma Aeronave Remotamente Tripulada (ARP). Além disso, visa avaliar o desempenho de diferentes versões do modelo YOLOv8 (nano, small, medium, large e extralarge) para determinar a configuração mais eficaz na detecção precisa das plantas.


2 MATERIAL E MÉTODOS

2.1 Área de estudo

O estudo foi conduzido na região de Lavras no estado de Minas Gerais, Brasil (Figura 2a). A região possui clima subtropical (Cwa de acordo com classificação de Koppen), caracterizado como por ter uma estação chuvosa no verão e uma estação seca no inverno, além disso, apresenta temperatura média de 20 °C e precipitação média anual de 1153 mm (Alvares *et al.*, 2013).

As duas áreas selecionadas estão sob as coordenadas 44°59'16,611"W, 21°11'55,634"S, 842 metros de altitude com 102 ha (Figura 2b) e 44°55'38,556"W, 21°15'25,755"S, 920 metros de altitude com 35 ha (Figura 2c). Essas áreas foram selecionadas devido a ampla ocorrência natural de plantas de macaúba e a possibilidade de aplicação em área nativa para detecção de plantas de macaúba e propor estratégias de extrativismo vegetal.

Figura 2 – Município de Lavras - MG (A) Localização das áreas (B) e (C) com presença de indivíduos de Macaúba.



Fonte: Do autor (2024).

2.2 Aquisição das imagens

As imagens foram coletadas próximo as 14:00 utilizando um drone DJI Mavic 3 enterprise (SZ DJI Technology Co., Shenzhen, China) voando a uma altura de 120 metros para maior cobertura de área, com sobreposição de imagens de 70% em todos os lados para melhor ajuste do mosaico final. A resolução espacial das imagens coletadas em cada um dos voos foi de 6 cm/pixel. Após cada voo, as imagens foram processadas utilizando o software Pix4D. 4.8.4. Pix4Dmapper. (Lausanne, Suíça). para obtenção dos ortomosaicos de alta precisão para imagens no espectro RGB (red, green, and blue).

2.3 Pós processamento


Após a aquisição os ortomosaicos, foi realizado um pós-processamento no QGIS-Hannover 3.16.01 (Berna, Suíça), onde foi criado um arquivo vetorial do tipo ponto no formato shapefile para identificar a localização de cada planta nos orthomosaicos. Em seguida, a partir desse ponto amostral foi criado um buffer retangular em cima de cada ponto para gerar as amostras que foram utilizadas no processo de treinamento, validação e teste.

Essa estratégia de amostragem resultou em plantas repetidas em diversas amostras, porém, em posições diferentes. Esse fato foi considerado como uma forma de aumento de dados (data augmentation), já que a mesma planta apareceu em posições diferentes em duas imagens, além disso, o background nessas imagens foi composto por outras espécies de árvores e demais elementos da paisagem.

2.4 Data set

Na Figura 3, são apresentada as etapas de processamento empregadas desde a aquisição das imagens, passando pela criação do dataset, etapa de treinamento validação e teste, até obtenção da identificação de plantas de macaúba utilizando YOLOv8.

Figura 3 – Representação esquemática de todo o processo desde a aquisição das imagens até o treinamento da rede para identificação e contagem de plantas de macaúba em ambientes nativos.




Fonte: Do autor (2024).

Antes de iniciar a etapa de rotulagem das imagens, essas passaram pelo processo de redimensionamento, em que foram gerados quatro conjuntos de imagens, de diferentes dimensões: 591 x 554 pixels, 595 x 595 pixels, 2187 x 2123 pixels e 13000 x 8400 pixels (Figura 4). Usar imagens de diferentes escalas na etapa de treinamento auxilia o processo de aprendizado de máquina para condições reais, ajudando a rede a aprender padrões que não variam em relação ao tamanho do objeto.

Após essa etapa, a rotulagem dos dados foi realizada utilizando a ferramenta Labellmg (Russell *et al.*, 2007), que permite a anotação manual das plantas de macaúba presentes nas imagens. Esse processo de rotulagem foi fundamental para criar as bases de dados e aplicar os modelos de inteligência artificial. As imagens processadas foram então divididas em três grupos: 70% (1.353 imagens) das imagens foram utilizadas para o treinamento dos modelos, 20% (386 imagens) para validação e 10% (193 imagens) que totaliza 908 plantas restantes para teste.

Figura 4 – Dimensões das imagens redimensionadas para serem utilizadas na etapa de rotulagem por meio da ferramenta LabelImg sendo: a) 591 x 554 pixels, b) 595 x 595 pixels, c) 2187 x 2123 pixels e d) 13000 x 8400 pixels.



Fonte: Do autor (2024).


2.5 Google colab

Em algumas aplicações de redes neurais artificiais, as exigências de processamento podem ultrapassar as capacidades de dispositivos domésticos, nesse sentido o Colab fornece acesso gratuito temporário a GPUs e TPUs, facilitando o treinamento e a execução de modelos complexos, tornando a computação em nuvem uma escolha mais eficaz e escalável. No presente trabalho foi usado uma GPU NVIDIA Tesla T4. A GPU funciona com o driver na versão 535.104.05 e suporta CUDA na versão 12.2.

2.6 Deep learning

A arquitetura YOLOv8 representa a mais recente evolução na família de modelos YOLO, que se destaca por sua eficiência na detecção de objetos em tempo real, obtendo um equilíbrio entre desempenho e hardwares limitados (Solimani *et al.*, 2024). Uma das inovações notáveis do YOLOv8 é a adoção de uma abordagem sem âncora, o que resulta em maior eficiência e precisão em comparação com os métodos tradicionais. Além disso, ele incorpora melhorias estruturais, como a substituição do módulo C3 pelo módulo C2F, que aumenta a precisão e reduz os tempos de processamento (Figura 5). Essas otimizações tornam o YOLOv8 uma escolha robusta e eficaz para diversas aplicações de visão computacional, mantendo sua reputação de ser um modelo rápido e preciso (Sapkota; Ahmed; Karkee, 2024).

Figura 5 – Esquema da arquitetura YOLOv8, destacando o Backbone, Head e Detect, elementos centrais detecção de objetos.



Fonte: Do autor (2024).

Assim, neste trabalho o modelo de detecção de objetos foi o YOLOv8, sendo feitas comparações entre diferentes versões da arquitetura YOLOv8: nano, small, medium, large e extralarge, sendo que em todas as versões foram treinadas 100 epochs.

Entre todas as versões testadas, a versão YOLOv8n (Nano) é a mais leve e compacta, ideal para dispositivos com baixa capacidade computacional e cenários que exigem alta velocidade de processamento. Enquanto a versão YOLOv8s (Small) oferece um equilíbrio entre precisão e desempenho, sendo adequada para implementações em dispositivos com recursos computacionais limitados. Já a versão YOLOv8m (Medium) é uma versão intermediária, com maior capacidade de detecção e precisão, enquanto a YOLOv8l (Large) é projetada para proporcionar alta precisão e exige maior capacidade computacional, especialmente em GPUs.

Por fim, a YOLOv8x (Extra Large) é a versão mais robusta, voltada para cenários que demandam máxima precisão e podem contar com recursos computacionais avançados (Terven; Córdova-Esparza, 2024).

2.7 Métricas de avaliação

Cada uma dessas versões foi treinada e avaliada com base nos conjuntos de dados de treino, validação e teste, utilizando métricas de precisão, loss e mAP (mean Average Precision) para o treino e validação (Bochkovskiy *et al.*, 2020) e Matriz de confusão para quantificar a precisão do teste (Apêndice A).

O parâmetro precision é uma métrica que avalia a proporção de instâncias positivas identificadas corretamente em relação ao total de instâncias positivas previstas pelo modelo. Isso significa que a precisão mede a qualidade das previsões positivas do modelo, indicando a proporção de casos positivos que são verdadeiramente positivos entre todas as previsões positivas (equação 1).

$$Precision = \frac{TP}{TP+FP} \quad (1)$$

Em que:

TP é Verdadeiros Positivos – o número de casos em que o modelo previu corretamente uma classe positiva.

FP é Falsos Positivos – o número de casos em que o modelo previu incorretamente uma classe positiva

O Mean Average Precision (mAP), é uma métrica de avaliação frequentemente usada em tarefas de detecção de objetos e classificação de múltiplas classes em visão computacional e processamento de imagens. Ela é usada para medir o desempenho de modelos que identificam a presença e localização de objetos em imagens (equação 2).

$$mAP = \frac{1}{C} \sum_{i=1}^C AP_i \quad (2)$$

Em que:

C é o número total de classes ou categorias no problema.,

AP Average Precision é a média da precisão obtida em diferentes pontos de recall (ou seja, em diferentes limiares de confiança).

i numero de classes


A matriz de confusão é uma ferramenta usada para avaliar o desempenho de um modelo de classificação, especialmente em tarefas de reconhecimento de padrões, como a identificação de plantas. Ela organiza os resultados das previsões do modelo em quatro categorias principais: Verdadeiros Positivos (VP), Falsos Positivos (FP), Verdadeiros Negativos (VN) e Falsos Negativos (FN). No contexto de identificação de plantas, a matriz de confusão ajuda a visualizar o quão bem o modelo consegue distinguir entre as plantas de interesse e o fundo (ou outras classes). Ela permite medir a precisão (quantas previsões corretas foram feitas) e a taxa de erros, fornecendo informações sobre onde o modelo está acertando e errando. No presente trabalho ela foi usada para avaliar o teste das classificações feitas pelos modelos onde temos apenas a parte positiva da matriz de confusão uma vez que possuía apenas uma classe, onde o TP é número de plantas identificadas e o FN seria as plantas não identificadas. A soma dos dois valores é o número de plantas na imagem.

3 RESULTADOS

3.1 Treinamento e validação

Na etapa de treinamento e validação das redes foi possível observar que independente da arquitetura do Yolov8 e das diferentes resoluções das imagens adquiridas por drone, os algoritmos foram capazes de detectar plantas de macaúba em ambientes nativos (Figura 6).


Figura 6 – Diferentes resoluções de imagens coletadas por drone para detecção de macaúba em ambiente nativo, em que 0 representa a classe a ser detectada.



Fonte: Do autor (2024).

Quando se analisa os resultados de Intersec over union (IoU), na etapa de validação percebe-se que a maioria dos resultados são acima de 80%, isso indica que a rede consegue fazer boa detecção do alvo procurado (Figura 7). Porém, alvos próximos da borda presentes na imagem ou aqueles que estão se sobrepondo tendem a reduzir a capacidade de identificação de plantas de macaúba. Especialmente na cultura da macaúba em condições de ambientes naturais a sobreposição de plantas umas nas outras pode acontecer, uma vez que essa tem habito de dispersão que ocorrem em maciços.


Figura 7 – Validação do processo de classificação em que (a) representa o alvo identificado e (b) representa o resultado do IoU.



Fonte: Do autor (2024).

Os resultados obtidos com diferentes arquiteturas do YOLOv8 para a identificação e contagem de plantas de macaúba revelaram padrões interessantes de desempenho e características distintas de cada modelo. De modo geral, todas as redes alcançaram valores elevados de mean Average Precision (mAP), com mais de 95% após 100 épocas de treinamento, evidenciando a robustez da abordagem e a capacidade das redes de lidar eficientemente com as imagens analisadas (Figura 8). No entanto, diferenças importantes foram observadas entre as arquiteturas, particularmente em termos de precisão e comportamento do loss, indicando possíveis impactos da complexidade da rede e da quantidade de parâmetros no processo de aprendizado.

Figura 8 – Métricas de avaliação (precision e mAP) das diferentes versões do Yolov8 sendo, a) nano, b) small, c) medium, d) large e, e) x-large, considerando a época de treinamento na etapa de treino e validação.



Fonte: Do autor (2024).

A rede nano destacou-se por atingir o maior valor de precisão (95%) em menos tempo, com apenas 55 épocas de treinamento. Essa eficiência pode ser atribuída à sua arquitetura leve e ao menor número de parâmetros, o que favorece a convergência inicial do modelo. No entanto, embora tenha apresentado o menor valor de loss entre todas as redes (1.42), esse resultado só foi alcançado na 75ª época, indicando que, apesar de rápida, sua otimização final demandou mais tempo. Esses resultados sugerem que a simplicidade da arquitetura nano contribui para uma convergência inicial rápida, mas que o ajuste fino dos pesos é mais gradual, especialmente em tarefas complexas como a identificação de plantas em imagens aéreas.

Por outro lado, a rede small apresentou um desempenho mais estável ao longo do treinamento, atingindo 95% de precisão próximo à 100ª época. Quando treinada por 75 épocas, o loss permaneceu relativamente alto (1.65), o que pode indicar que essa arquitetura requer mais tempo de treinamento para ajustar completamente os parâmetros e atingir o mesmo nível de otimização que a nano. Esse comportamento reflete o equilíbrio entre a maior complexidade da rede e a capacidade de evitar overfitting durante períodos de treinamento mais longos.

A rede médium, que representa uma arquitetura intermediária, alcançou sua precisão máxima de 96% por volta da 76ª época, indicando um desempenho consistente em tarefas de identificação. O menor valor de loss (1.63) foi observado próximo à 80ª época, um indicativo de que a rede conseguiu atingir um ponto de equilíbrio entre desempenho e generalização antes de períodos mais extensos de treinamento.

Em contrapartida, a rede large exibiu um comportamento similar à nano em termos de precisão, atingindo seu melhor desempenho de 95% após 75 épocas de treinamento. Contudo, o loss dessa rede permaneceu mais elevado (1.81 na 80ª época), o que sugere que o aumento na complexidade da arquitetura não resultou em ganhos substanciais de otimização, podendo estar relacionado a uma maior dificuldade na convergência de parâmetros devido ao maior número de camadas.

A rede x-large, a mais complexa testada, obteve o melhor desempenho em termos de precisão, alcançando 96% na 98ª época. Curiosamente, essa rede apresentou sinais precoces de overfitting, com o menor valor de loss (1.34) registrado na 30ª época, seguido por um aumento progressivo do loss nos treinamentos subsequentes. Esse comportamento é típico de modelos com alta capacidade de representação, que podem ajustar-se de forma excessiva aos dados de treinamento, especialmente em conjuntos de dados de tamanho limitado ou com alta redundância.

De maneira geral, os resultados evidenciam que redes menores, como a nano e a small, são mais eficientes em termos de tempo de treinamento, enquanto arquiteturas mais complexas, como a x-large, oferecem ganhos marginais de precisão ao custo de maior risco de overfitting. A escolha da arquitetura ideal, portanto, deve considerar o balanço entre recursos computacionais disponíveis, tempo de treinamento e a necessidade de precisão no contexto da aplicação específica.


3.2 Teste

Após o treinamento e validação, foi conduzida uma etapa de teste utilizando um banco de dados independente composto por imagens contendo aproximadamente 900 plantas de

macaúba. Essas imagens não foram previamente vistas pelas redes durante o treinamento ou validação, garantindo uma avaliação robusta da capacidade de generalização de cada arquitetura do YOLOv8. Os resultados dessa etapa revelaram diferenças significativas entre as redes em termos de precisão, taxas de falso negativo e falso positivo, além de expor limitações inesperadas de algumas arquiteturas.

A rede nano, a mais leve entre as testadas, foi capaz de identificar corretamente 847 plantas, mas deixou de detectar 61 delas, resultando em um desempenho consistente, porém inferior às redes mais complexas. Esses resultados refletem a limitação inerente da arquitetura nano em capturar padrões mais complexos em dados novos, no caso, redes mais simples podem não conseguir detectar apenas parte da planta ou plantas em que o fundo da imagem se confunde com a planta, apesar de sua eficiência em convergência inicial observada nas etapas de treinamento. Apesar desses bons resultados ocorreram casos em que a rede não detectou algumas plantas ou foram detectadas com baixa certeza quando comparada com as redes mais complexas (Figura 9).

Figura 9 – Exemplo da variação da classificação em cada rede. a-nano, b-small, c-medium, d-large, e x-large.



Fonte: Do autor (2024).

Por sua vez, a rede small apresentou uma taxa de acerto de 93,61%, indicando uma ligeira melhoria em relação à nano. Entretanto, o modelo gerou um falso positivo, identificando incorretamente um objeto que não era uma planta de macaúba. Esse comportamento pode ser atribuído ao balanceamento entre a complexidade do modelo e a generalização, sugerindo que a rede estava suficientemente treinada para evitar falsos negativos, mas mais suscetível a superestimar padrões semelhantes aos da macaúba.

A rede médio demonstrou um desempenho superior, identificando corretamente 859 plantas, o que corresponde a uma taxa de acerto de 94,6%. Esse resultado confirma sua capacidade intermediária de generalização, um equilíbrio que já havia sido evidenciado nas etapas de validação, onde apresentou precisão consistente sem sinais evidentes de overfitting.

A rede large apresentou resultados ligeiramente melhores, com uma taxa de acerto de 94,7%, identificando corretamente 860 plantas. O desempenho dessa rede reflete sua maior capacidade de modelar padrões complexos em comparação às redes menores, mantendo uma precisão elevada em um banco de dados totalmente novo.

Embora seja a estrutura de rede mais robusta, devido à sua complexidade arquitetural e maior número de parâmetros, a xlarge, apresentou uma taxa de acerto de apenas 92,07%. Este desempenho inferior pode ser atribuído ao overfitting observado durante o treinamento em que os valores da função loss foram os menores próximos a 30 épocas de treino esse fato comprometeu a capacidade de generalizar adequadamente as detecções em novos conjuntos de imagens obtidas por drones.

Os resultados também estão apresentados de forma gráfica no Apêndice B.

4 DISCUSSÃO

Os resultados encontrados neste estudo reforçam a importância de escolher o modelo certo com base no trade-off entre precisão, tempo de convergência e recursos computacionais quando se utiliza YOLOv8 para detecção de plantas de macaúba. O YOLOxlarge, com seu mAP de 98% e convergência da função loss em torno de 40 epochs, seria ideal para aplicações que exigem alta precisão e podem suportar tempos de treinamento e processamento mais longos. Por outro lado, o YOLOn pode ser uma opção mais adequada em cenários de tempo real, onde a eficiência e a velocidade são prioridades. Além disso, esses valores indicam que os modelos já na etapa de treinamento apresentam estar bem ajustados para a tarefa de identificação de plantas de macaúba, uma espécie de complexidade moderada em termos de estrutura visual, quando as imagens são coletadas em áreas de campo nativo.


Resultados similares foram encontrados quando a rede YOLOv8m foi utilizada para detecção de frutos de dendê, em que essa foi considerada a mais eficiente na detecção, especialmente quando se considerou os recursos computacionais envolvidos (Gunawan *et al.*, 2023). Além disso, a rede YOLOv8m obteve 99.31% de precisão ao identificar plantas de dendê, enquanto o YOLOv8s reduziu drasticamente os tempos de detecção (Shaikh *et al.*, 2024). Isso indica que é possível fazer detecção de plantas com potencial energético a campo e em tempo real. Por outro lado, quando se analisou a função loss durante o treino, nas redes YOLOv8 nano e YOLOv8 aprimorado, observou que a convergência da rede aprimorada é mais rápida. Isso comprova que o recurso computacional foi utilizado de forma mais eficiente (Ma *et al.*, 2024).

Vale enfatizar que quando as redes começam a entender a feição que deve ser identificada, essa começa a achar partes de plantas que estão nas bordas das imagens. Entretanto, observa-se comportamento diferente para as redes testadas nesse trabalho. Em que a nano em alguns casos não consegue detectar objetos alvo presente nas bordas (Figura 10A). De modo contrário, as redes que possuem estruturas mais robustas, quando aplicadas na identificação de plantas de macaúba em condições naturais, em alguns casos não conseguiram diferenciar a sobreposição de plantas em alguns casos (Figura 10D), assim como a nano. Resultados diferente foram encontrados por Wardana, Sianturi e Fatwa (2023), em que os autores relatam que as palmeiras nas bordas das imagens não foram contadas ou sofreram com algum tipo de distorção. Isso reforça o potencial da utilização das redes implementadas no YOLOv8 para o mapeamento de macaúba em ambientes naturais, exceto a rede small.

Um resultado inesperado ocorre na rede xlarge na etapa de teste. Quando se analisa os resultados obtidos através do treino e validação de uma rede, é notado que ao aumentar a complexidade da rede ocorre uma melhora nos resultados, porém quando se analisa os resultados dos testes, é visto que ocorre uma melhora até a rede large. Porém ao avaliar os resultados da rede xlarge é visto uma piora na detecção da planta. Resultados semelhantes foram encontrados por Solimani *et al.* (2024) que explica que quando os dados estão balanceados, ou seja, números de amostras semelhantes para cada classe, modelos menores podem ter desempenho semelhante ou melhores do que modelos mais robustos. Nessa situação, o YOLOv8l se destaca como o mais eficaz. Esse fenômeno é explicado por Nakkiran *et al.* (2021) que explica modelos de aprendizado de máquina buscam um equilíbrio entre viés e variância. Modelos mais complexos apresentam menor viés, mas maior variância. Após certo ponto, essa complexidade excessiva leva ao superajuste, onde a variância domina o erro de teste, prejudicando o desempenho.

Utilizando YOLOv5 e rede R-CNN, Lee *et al.* (2024) conseguiram diferenciar a sobreposição de plantas de dendê classificando-as em únicas, duplas e triplas alcançando valores de mAP de 94, 92 e 85%, respectivamente. De modo análogo e visando identificar palmeiras com potencial energético, os valores de mAP aumentaram substancialmente quando utilizado YOLOv7, com resultados de 99,7% (Ariyadi; Pribadi; Widiyanto, 2023). Essa comparação é um tanto quanto importante quando se pensa em plantas de macaúba em ambiente natural, uma vez que a dispersão e ocorrência das plantas acontece em maços, o que pode ocasionar sobreposição de plantas. Assim, considerando esse aspecto, redes que possuem capacidade de identificação de plantas que estão se sobrepondo são mais vantajosas, tais como as small, médium e x-large, que foram testadas neste trabalho utilizando YOLOv8 e alcançaram mAP 95% após 100 épocas de treinamento (Figura 10).

Figura 10 – Exemplo da variação da classificação em cada rede em diferentes escalas. a-nano, b-small, c-medium, d-large, e x-large..



Fonte: Do autor (2024).

Ao passo que aumenta a complexidade das redes, os resultados se mostram estáveis, porém, ocorre redução quando se usa uma rede complexa para identificar uma feição relativamente mais simples. Quando o treinamento foi realizado com 100 épocas em uma rede mais robusta, a taxa de aprendizado é mais rápida, porém, tem mais tendência de entrar em overfitting. Nesse sentido, o ideal para a identificação de plantas de macaúba em áreas nativas é reduzir o número de epochs ou usar uma rede com características mais complexa para treinar o reconhecimento de feições mais complexas e com mais classes.

Além disso, vale ressaltar que a altura de voo durante a aquisição das imagens pode ter contribuído nos resultados da detecção de plantas de macaúba. No nosso estudo, os voos foram realizados a uma altura de 120 metros, o que permitiu a coleta de imagens de uma área maior em cada sobrevoo, o que consequentemente acarretou perda de resolução espacial. Isso pode

ter comprometido a precisão da identificação de feições menores e mais detalhadas, como folhas ou ramos mais finos, dificultando o desempenho dos modelos mais complexos, como o YOLOxlarge, que depende de detalhes mais refinados para sua classificação (Zhong *et al.*, 2024). Por outro lado, é importante destacar que, apesar da perda de resolução, voos mais altos também apresentam vantagens significativas, como o aumento da área de coleta. Ao cobrir uma maior extensão em cada voo, o processo de aquisição de imagens se torna mais eficiente, especialmente em áreas amplas, como aquelas com plantios nativos, que é o objeto de estudo do nosso trabalho.

Voos realizados a 36 metros de altura e com imagens de maior resolução, contribuíram para a alta precisão do YOLOv8m com 98% de acerto (Shaikh *et al.*, 2024). Em contrapartida, redes mais robustas, como a YOLOxlarge utilizada no nosso trabalho, pode ter apresentado overfitting devido à menor resolução espacial das imagens, levando a um desempenho inferior em comparação a redes mais leves ou a treinos com imagens de maior resolução.

Apesar disso, diversos autores têm relatado alta eficiência na identificação de palmeiras com potencial energético, entretanto, nenhum deles aplicados a identificação de plantas de macaúba visando extrativismo vegetal em ambientes nativos. Métodos de detecção para o gerenciamento da saúde de plantações de palmeiras de óleo apresentaram até 99,04% de F1-score, ultrapassando abordagens anteriores em até 21,32%, tornando-se ferramentas promissoras para um gerenciamento eficaz de plantações (Zheng *et al.*, 2021). Comparações entre YOLOv7 e YOLOv8 na detecção de palmeiras mostraram que o YOLOv8m atingiu a maior precisão, com F1 de 99,31%, enquanto o YOLOv8s se destacou em velocidade de detecção, reforçando sua adequação ao monitoramento ambiental eficiente (Shaikh *et al.*, 2024).

Além de palmeiras de óleo, outras espécies vegetais foram investigadas com o uso de deep learning. Em florestas densas, um modelo YOLOv5 aprimorado, com camadas convolucionais específicas, alcançou 96,1% de precisão e 94,5% de F1 na detecção de árvores de abeto chinês, superando o YOLOv5 em até 2,6% em diversas métricas (Wang *et al.*, 2024). Na detecção e contagem de árvores *Camellia oleifera* o YOLOv8 e imagens de drone RGB, utilizando um conjunto de dados recortado mostrou-se eficiente, superando YOLOv5 e YOLOv10 em precisão e mAP de 86%, sugerindo seu potencial para estimativas de rendimento e manejo de pomares (Yang *et al.*, 2024). Estudos também foram realizados para detectar a Doença da Murcha do Pinheiro (PWD) usando um modelo aprimorado de YOLOv8, que atingiu 0,81 de mAP50, oferecendo suporte técnico eficaz para o monitoramento de PWD em larga escala (Wang *et al.*, 2023). Esses resultados sugerem que trabalhos futuros podem ser

desenvolvidos para cultura da macaúba, especialmente para identificação de outros padrões que possa acometer as plantas em cultivos comerciais.

5 CONCLUSÕES

Este trabalho demonstrou o potencial das técnicas de inteligência artificial como ferramenta para a detecção de plantas de macaúba em ambiente natural. Foi observado que a depender da aplicação, não é necessário usar uma arquitetura complexa e que demande muito recurso computacional.

Para a detecção de palmeiras de macaúba em ambiente nativo o melhor custo benefício foi a rede médium e large em função dos melhores resultados e demanda computacional. Redes muito complexas como a xlarge tiveram seu desempenho prejudicado por excesso de treinamento o que pode ter ocasionado overfitting. Redes muito simples tiveram problemas em identificar feições sobrepostas e feições em bordas das imagens. Para trabalhos futuros serão feitas modificações em parâmetros e adição de novas classes para observar o comportamento da rede.

REFERÊNCIAS

- AIRES, Giselle Cristine Melo; CARVALHO JUNIOR, Raul Nunes de. Potential of supercritical acrocomia aculeata oil and its technology trends. **Applied Sciences**, v. 13, n. 15, p. 8594, 2023.
- ALVARES, Clayton Alcarde *et al.* Köppen's climate classification map for Brazil. **Meteorologische zeitschrift**, v. 22, n. 6, p. 711-728, 2013.
- AMPESE, Larissa Castro *et al.* Macaúba's world scenario: a bibliometric analysis. **Biomass Conv. Bioref.** v. 13, p. 3329–3347, 2023.
- ANDRADE, Gabriele Melo de *et al.* Macauba (*Acrocomia aculeata*) endocarp as a coarse aggregate for bio-concretes. **Construction and Building Materials**, v. 451, p. 138667, 2024.
- ARIYADI, M. Rama Nopan; PRIBADI, Muhammad Rizky; WIDIYANTO, Eka Puji. Unmanned aerial vehicle for remote sensing detection of oil palm trees using you only look once and convolutional neural network. *In: 2023 10th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI)*. **IEEE**, p. 226-230, 2023.
- BATISTA, Cláudia Eliane Dias *et al.* Monitoring the composition in esters of the biodiesel from the macauba (*Acrocomia aculeata* (Jacq.) Lodd. ex Mart.) kernel oil put in direct contact with carbon steel and galvanized carbon steel. **Química Nova**, v. 42, p. 387-396, 2019.
- CÉSAR, Aldara da Silva *et al.* The prospects of using *Acrocomia aculeata* (macaúba) a non-edible biodiesel feedstock in Brazil. **Renewable and Sustainable Energy Reviews**, v. 49, p. 1213-1220, 2015.
- COLOMBO, Carlos Augusto *et al.* Macauba: a promising tropical palm for the production of vegetable oil. **Ocl**, v. 25, n. 1, p. D108, 2018.
- COSTA, Sarah Esther de Lima *et al.* Briquettes quality produced with the macauba epicarp (*Acrocomia aculeata*) and Pinus sp. wood. **Revista Árvore**, v. 43, p. e430501, 2019.
- DEMIRBAS, Ayhan. Importance of biodiesel as transportation fuel. **Energy policy**, v. 35, n. 9, p. 4661-4670, 2007.
- DEMIRBAS, Ayhan. Political, economic and environmental impacts of biofuels: A review. **Applied energy**, v. 86, p. S108-S117, 2009.
- DUARTE, Fátima Ladeira Mendes *et al.* Macauba (*Acrocomia aculeata*) kernel has good protein quality and improves the lipid profile and short chain fatty acids content in Wistar rats. **Food & Function**, v. 13, n. 21, p. 11342-11352, 2022.
- EVARISTO, Anderson Barbosa *et al.* Energy potential of the macaw palm fruit residues and their use in charcoal production. **Ciencia Florestal**, v. 26, n. 2, p. 571-577, 2016.
- GUNAWAN, Teddy Surya *et al.* Palm fruit ripeness detection and classification using various yolov8 models. *In: 2023 IEEE 9th International Conference on Smart Instrumentation, Measurement and Applications (ICSIMA)*. **IEEE**, p. 193-198, 2023.

- LEE, Sheng Siang *et al.* Oil palm tree detection in UAV imagery using an enhanced RetinaNet. **Computers and electronics in Agriculture**, v. 227, p. 109530, 2024.
- MA, Na *et al.* Chili pepper object detection method based on improved YOLOv8n. **Plants**, v. 13, n. 17, p. 2402, 2024.
- NAKKIRAN, Preetum *et al.* Deep double descent: Where bigger models and more data hurt. **Journal of Statistical Mechanics: Theory and Experiment**, v. 2021, n. 12, p. 124003, 2021.
- PLATH, Mirco *et al.* A novel bioenergy feedstock in Latin America? Cultivation potential of *Acrocomia aculeata* under current and future climate conditions. **Biomass and Bioenergy**, v. 91, p. 186-195, 2016.
- RÔXO, Aryane dos Santos *et al.* Formulations based on oil extract in macaúba (*Acrocomia aculeata* (Jacq.) Lodd ex Martius): a review of the literature. **Revista Foco**, v. 16, n. 8, p. e1786-e1786, 2023.
- SAPKOTA, Ranjan; AHMED, Dawood; KARKEE, Manoj. Comparing YOLOv8 and Mask R-CNN for instance segmentation in complex orchard environments. **Artificial Intelligence in Agriculture**, v. 13, p. 84-99, 2024.
- SHAIKH, Istiyak Mudassir *et al.* Enhancing sustainability in the production of palm oil: Creative monitoring methods using YOLOv7 and YOLOv8 for effective plantation management. **Biotechnology Reports**, v. 44, p. e00853, 2024.
- SILVA, Gislene Carvalho *et al.* Óleo de amêndoa de macaúba tem potencial como ingrediente lipídico em margarina e maionese. **Agrarian**, v. 13, n. 47, p. 122-129, 2020.
- SOLIMANI, Firozeh *et al.* Optimizing tomato plant phenotyping detection: Boosting YOLOv8 architecture to tackle data complexity. **Computers and Electronics in Agriculture**, v. 218, p. 108728, 2024.
- SOUZA, Patrícia Pereira de *et al.* Tipo de armazenamento no vigor e na viabilidade de sementes de macaúba oriundas de duas localidades do Estado de Minas Gerais. **Ciência Rural**, v. 46, p. 1932-1937, 2016.
- TERVEN, Juan; CÓRDOVA-ESPARZA, Diana-Margarita; ROMERO-GONZÁLEZ, Julio-Alejandro. A comprehensive review of yolo architectures in computer vision: From yolov1 to yolov8 and yolo-nas. **Machine learning and knowledge extraction**, v. 5, n. 4, p. 1680-1716, 2023.
- VARGAS-CARPINTERO, Ricardo *et al.* A collaborative, systems approach for the development of biomass-based value webs: the case of the *Acrocomia* palm. **Land**, v. 11, n. 10, p. 1748, 2022.
- WANG, Jiansen *et al.* Tree-level chinese fir detection using uav rgb imagery and yolo-dcam. **Remote Sensing**, v. 16, n. 2, p. 335, 2024.
- WANG, Shikuan *et al.* Detection of pine wilt disease using drone remote sensing imagery and improved yolov8 algorithm: A case study in weihai, china. **Forests**, v. 14, n. 10, p. 2052, 2023.

WARDANA, Deny Praselia Taruma; SIANTURI, Riswan Septriayadi; FATWA, Ramdani. Detection of oil palm trees using deep learning method with high-resolution aerial image data. *In: Proceedings of the 8th International Conference on Sustainable Information Engineering and Technology*. p. 90-98, 2023.

YANG, Renxu *et al.* Camellia oleifera Tree Detection and Counting Based on UAV RGB Image and YOLOv8. **Agriculture**, v. 14, n. 10, p. 1789, 2024.

ZHENG, Juepeng *et al.* Growing status observation for oil palm trees using Unmanned Aerial Vehicle (UAV) images. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 173, p. 95-121, 2021.

CONSIDERAÇÕES FINAIS

Este trabalho estabelece uma base sólida para novos estudos sobre o mapeamento automatizado de macaúba utilizando inteligência artificial e drones. Os resultados obtidos destacam o potencial de explorar a relação entre diferentes configurações de modelos de IA e a precisão na identificação e contagem das plantas. A utilização de redes YOLOv8 para detecção automática traz uma perspectiva promissora para o aprimoramento de técnicas de mapeamento, que podem ser replicadas tanto por pesquisadores quanto por profissionais do setor agropecuário. A constatação de que versões menores do modelo, como a YOLOv8 Nano, apresentam rapidez sem comprometer a precisão abre espaço para estudos futuros sobre o balanceamento entre desempenho e eficiência computacional. Além disso, os resultados sugerem que modelos mais robustos, como o YOLOv8 Large, são vantajosos em cenários que demandam maior precisão na detecção, especialmente em áreas de maior densidade de vegetação. Esses resultados reforçam a importância de adaptar as configurações de IA ao contexto específico do mapeamento, otimizando tanto o tempo de processamento quanto a acurácia na detecção das plantas de macaúba.

Para futuras pesquisas envolvendo a macaúba, destaca-se o potencial de personalizar as redes de aprendizado, ajustando hiperparâmetros para explorar melhorias nos resultados obtidos. Além disso, há possibilidades promissoras em estudos voltados a parâmetros fitotécnicos das plantas, como a utilização de drones para estimar a altura e o diâmetro da copa. O uso de dados multiespectrais também poderia ser integrado para avaliar a saúde e a produtividade das plantas. Outra abordagem relevante seria o aumento do banco de dados para incluir imagens de outras espécies de palmeiras, permitindo o treinamento de algoritmos capazes de diferenciar a macaúba de outras palmeiras, o que ampliaria as aplicações e a precisão em estudos de identificação e monitoramento dessas espécies.


APÊNDICES

Apêndice A - Matrix de confusão para avaliação dos testes das redes.

Nano		Small																							
Confusion Matrix <table><tr><td rowspan="2">Actual</td><td>Macabba</td><td>847</td><td>61</td></tr><tr><td>Absent</td><td>0</td><td>0</td></tr><tr><td colspan="2"></td><td>Background</td><td>Class Present</td></tr></table>		Actual	Macabba	847	61	Absent	0	0			Background	Class Present	Confusion Matrix <table><tr><td rowspan="2">Actual</td><td>Macabba</td><td>850</td><td>58</td></tr><tr><td>Absent</td><td>1</td><td>0</td></tr><tr><td colspan="2"></td><td>Background</td><td>Class Present</td></tr></table>		Actual	Macabba	850	58	Absent	1	0			Background	Class Present
Actual	Macabba		847	61																					
	Absent	0	0																						
		Background	Class Present																						
Actual	Macabba	850	58																						
	Absent	1	0																						
		Background	Class Present																						
Medium		Large																							
Confusion Matrix <table><tr><td rowspan="2">Actual</td><td>Macabba</td><td>859</td><td>49</td></tr><tr><td>Absent</td><td>0</td><td>0</td></tr><tr><td colspan="2"></td><td>Background</td><td>Class Present</td></tr></table>		Actual	Macabba	859	49	Absent	0	0			Background	Class Present	Confusion Matrix <table><tr><td rowspan="2">Actual</td><td>Macabba</td><td>860</td><td>48</td></tr><tr><td>Absent</td><td>0</td><td>0</td></tr><tr><td colspan="2"></td><td>Background</td><td>Class Present</td></tr></table>		Actual	Macabba	860	48	Absent	0	0			Background	Class Present
Actual	Macabba		859	49																					
	Absent	0	0																						
		Background	Class Present																						
Actual	Macabba	860	48																						
	Absent	0	0																						
		Background	Class Present																						
Xlarge																									
Confusion Matrix <table><tr><td rowspan="2">Actual</td><td>Macabba</td><td>838</td><td>70</td></tr><tr><td>Absent</td><td>0</td><td>0</td></tr><tr><td colspan="2"></td><td>Background</td><td>Class Present</td></tr></table>		Actual	Macabba	838	70	Absent	0	0			Background	Class Present													
Actual	Macabba		838	70																					
	Absent	0	0																						
		Background	Class Present																						

Fonte: Do autor (2025).

Apêndice B - Sintetização dos resultados obtidos nos treinos, validação e testes para as 5 redes.



Fonte: Do autor (2025).