

UNIVERSIDADE FEDERAL DE VIÇOSA

**Visão computacional na detecção de plantas de eucalipto recém
transplantadas**

Jhonata Santos Santana
Doctor Scientiae

**VIÇOSA - MINAS GERAIS
2025**

JHONATA SANTOS SANTANA

**Visão computacional na detecção de plantas de eucalipto recém
transplantadas**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Doctor Scientiae*.

Orientador: Domingos S. M. Valente

Coorientadores: Daniel M. de Queiroz
Andre L. de F. Coelho

**VIÇOSA - MINAS GERAIS
2025**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade
Federal de Viçosa - Campus Viçosa**

T

Santana, Jhonata Santos, 1989-
S232v Visão computacional na detecção de plantas de eucalipto
2025 recém transplantadas / Jhonata Santos Santana. – Viçosa, MG,
2025.

1 tese eletrônica (110 f.): il. (algumas color.).

Orientador: Domingos Sárvio Magalhães Valente.
Tese (doutorado) - Universidade Federal de Viçosa,
Departamento de Engenharia Agrícola, 2025.

Inclui bibliografia.

DOI: <https://doi.org/10.47328/ufvbbt.2025.206>

Modo de acesso: World Wide Web.

1. Irrigação agrícola. 2. Inteligência artificial. 3. Eucalipto.
I. Valente, Domingos Sárvio Magalhães, 1978-. II. Universidade
Federal de Viçosa. Departamento de Engenharia Agrícola.
Programa de Pós-Graduação em Engenharia Agrícola. III. Título.

CDD 22. ed. 631.587

JHONATA SANTOS SANTANA

**Visão computacional na detecção de plantas de eucalipto recém
transplantadas**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Doctor Scientiae*.

APROVADA: 13 de fevereiro de 2025.

Assentimento:

Jhonata Santos Santana
Autor

Domingos Sarvio Magalhaes Valente
Orientador

Essa tese foi assinada digitalmente pelo autor em 22/04/2025 às 12:44:55 e pelo orientador em 22/04/2025 às 14:07:04. As assinaturas têm validade legal, conforme o disposto na Medida Provisória 2.200-2/2001 e na Resolução nº 37/2012 do CONARQ. Para conferir a autenticidade, acesse <https://siadoc.ufv.br/validar-documento>. No campo 'Código de registro', informe o código **KRRQ.4UL5.GEXJ** e clique no botão 'Validar documento'.

A todos que me apoiaram e acreditaram em mim ao longo desta jornada, minha mais profunda gratidão e apreço. Sem vocês, este momento não seria possível.

AGRADECIMENTOS

A Deus, pela dádiva da vida, pela força nos momentos difíceis e pela sabedoria concedida ao longo de toda esta jornada.

Aos meus pais, pelo amor incondicional, pelos valores transmitidos e pelo constante apoio que sustentaram minha trajetória acadêmica e pessoal.

À minha querida Alice, por caminhar ao meu lado durante todo esse período, oferecendo carinho, paciência e apoio nos momentos mais desafiadores.

Ao professor Domingos Sárvio Magalhães Valente, pela orientação firme e incentivo constante, fundamentais para a realização deste trabalho.

Aos meus coorientadores, pelas contribuições essenciais:

Professor André Luiz de Freitas Coelho, pelo apoio contínuo e sugestões valiosas;

Professor Daniel Marçal de Queiroz, pelas orientações que enriqueceram esta pesquisa;

Professor Michel Castro Moreira, pelo suporte técnico e dedicação ao longo do processo.

Aos amigos que tornaram esta caminhada mais leve e significativa:

José Antonio Lima Rocha Junior, pelos momentos de descontração e amizade sincera;

Igor Barbosa, pelo auxílio na coleta de dados;

Igor Rodrigues Quintão, pelo suporte prestado na Eldorado Brasil Celulose.

Ao Cassio Fagundes Gomes e à Eldorado Brasil Celulose, pelo acesso aos dados e pelo apoio técnico imprescindível ao desenvolvimento do trabalho.

Aos professores e colegas do Departamento de Engenharia Agrícola da Universidade Federal de Viçosa, pela troca de conhecimentos e pelas experiências compartilhadas.

À Universidade Federal de Viçosa, pela oportunidade de cursar esta pós-graduação.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Também agradeço ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão da bolsa de estudos, e à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), pelo suporte financeiro.

A todos que, de alguma forma, contribuíram para a concretização deste trabalho, expresso minha mais profunda gratidão.

“Quando chega o momento da ação, o momento da
preparação já se foi.”
(Ditado Popular)

RESUMO

SANTANA, Jhonata Santos, D.Sc., Universidade Federal de Viçosa, fevereiro de 2025. **Visão computacional na detecção de plantas de eucalipto recém transplantadas**. Orientador: Domingos Sarvio Magalhaes Valente. Coorientadores: Daniel Marcal de Queiroz e Andre Luiz de Freitas Coelho.

A presente tese aborda o desenvolvimento e aplicação de modelos de inteligência artificial para a detecção de mudas de eucalipto, com o objetivo de aprimorar a automação da irrigação e a eficiência no manejo dessas plantações. A pesquisa foi estruturada em três capítulos, cada um focando em diferentes aspectos do desenvolvimento e avaliação de modelos de detecção de mudas de eucalipto para aplicações em automação agrícola. No Capítulo 1, foi desenvolvido um sistema automático para a detecção de plantas de eucalipto utilizando redes neurais YOLOv8 e YOLOv5. Dois modelos de detecção em tempo real foram construídos e treinados com base em imagens obtidas em campo. O desempenho dos modelos foi comparado por meio de métricas como precisão, recall, mAP50 e mAP50-95. Os resultados mostraram que ambos os modelos foram eficazes na detecção de mudas de eucalipto, com o YOLOv8 apresentando uma precisão média de detecção de 0,958 e um recall médio de 0,935, enquanto o YOLOv5 apresentou uma precisão média de 0,951 e um recall médio de 0,944. Esses modelos podem ser utilizados como ferramentas de apoio na automação da irrigação localizada, contribuindo para a otimização dos processos e redução de custos. No Capítulo 2, foi proposto o uso de técnicas de inteligência artificial para detectar sintomas de estresse hídrico em plantas jovens de eucalipto sob condições de campo. Modelos baseados nas redes neurais YOLOv5 e YOLOv8 foram desenvolvidos e avaliados por meio de métricas de precisão, recall, mAP50, mAP50-95 e índice de confiança. Os modelos apresentaram elevado índice de confiança na detecção de plantas com e sem estresse hídrico, tanto em imagens quanto em vídeos. Os resultados indicaram um alto potencial para a automação da irrigação localizada, permitindo o controle da aplicação de água em taxa variada e em tempo real. No Capítulo 3 foi desenvolvido um modelo de detecção em tempo real utilizando YOLOv5, com base em imagens de vistas superiores de plantas jovens de eucalipto. Diferentemente do modelo descrito no Capítulo 1, que utilizou um conjunto de imagens mais restrito, o modelo do Capítulo 3 foi treinado com um volume expressivamente maior de dados, totalizando 13.750 imagens, proporcionando maior robustez e precisão na detecção. Além disso, esse modelo foi otimizado para consumir menos recursos computacionais, permitindo uma execução mais eficiente em

dispositivos com capacidades limitadas. Essa versão otimizada foi implementada em uma NVIDIA Jetson Nano, que foi posteriormente instalada em uma plataforma robótica para realizar a detecção em tempo real. A implementação demonstrou resultados promissores, com uma precisão de 91%, recall de 100% e F1-score de 0,95, apresentando uma velocidade média de inferência de 46,49 milissegundos e uma taxa de captura média de 2,73 FPS. Embora um hardware mais potente possa aumentar a eficiência operacional, os resultados indicam que o modelo é capaz de detectar mudas de eucalipto em tempo real, demonstrando seu potencial para aplicações futuras na automação agrícola. Dessa forma, esta tese contribui para o avanço de modelos de detecção em tempo real, oferecendo uma base sólida para o desenvolvimento de sistemas embarcados que possam integrar a identificação das mudas a processos automatizados de manejo agrícola.

Palavras-chave: detecção em tempo real; automação da irrigação; inteligência artificial

ABSTRACT

SANTANA, Jhonata Santos, D.Sc., Universidade Federal de Viçosa, February, 2025.
Computer Vision in the Detection of Recently Transplanted Eucalyptus Plants.
Adviser: Domingos Sarvio Magalhaes Valente. Co-advisers: Daniel Marcal de Queiroz and Andre Luiz de Freitas Coelho.

This thesis addresses the development and application of artificial intelligence models for the detection of eucalyptus seedlings, aiming to enhance irrigation automation and efficiency in the management of these plantations. The research was structured into three chapters, each focusing on different aspects of the development and evaluation of eucalyptus seedling detection models for applications in agricultural automation. In Chapter 1, an automatic system was developed for the detection of eucalyptus plants using YOLOv8 and YOLOv5 neural networks. Two real-time detection models were built and trained based on field-acquired images. The performance of the models was compared using metrics such as precision, recall, mAP50, and mAP50-95. The results showed that both models were effective in detecting eucalyptus seedlings, with YOLOv8 achieving an average detection precision of 0.958 and an average recall of 0.935, while YOLOv5 achieved an average detection precision of 0.951 and an average recall of 0.944. These models can be used as support tools in the automation of localized irrigation, contributing to process optimization and cost reduction. In Chapter 2, the use of artificial intelligence techniques was proposed to detect symptoms of water stress in young eucalyptus plants under field conditions. Models based on the YOLOv5 and YOLOv8 neural networks were developed and evaluated using precision, recall, mAP50, mAP50-95, and confidence index metrics. The models presented a high confidence index in detecting plants with and without water stress, both in images and videos. The results indicated a high potential for localized irrigation automation, allowing for real-time, variable-rate water application control. In Chapter 3, a real-time detection model using YOLOv5 was developed, based on images captured from top views of young eucalyptus plants. Unlike the model described in Chapter 1, which used a more limited set of images, the model in Chapter 3 was trained with a significantly larger dataset, totaling 13,750 images, providing greater robustness and accuracy in detection. Additionally, this model was optimized to consume fewer computational resources, allowing for more efficient execution on devices with limited capabilities. This optimized version was implemented on an NVIDIA Jetson Nano, which was subsequently installed on a robotic platform to perform real-time detection. The implementation demonstrated promising results, with an

accuracy of 91%, a recall of 100%, and an F1-score of 0.95, achieving an average inference speed of 46.49 milliseconds and an average capture rate of 2.73 FPS. Although more powerful hardware could enhance operational efficiency, the results indicate that the model is capable of detecting eucalyptus seedlings in real time, demonstrating its potential for future applications in agricultural automation. Thus, this thesis contributes to the advancement of real-time detection models, providing a solid foundation for the development of embedded systems that can integrate seedling identification into automated agricultural management processes.

Keywords: real-time detection; irrigation automation; artificial intelligence

SUMÁRIO

INTRODUÇÃO GERAL	12
REFERÊNCIAS	16
CAPÍTULO 1: DESENVOLVIMENTO DE MODELOS DE DETECÇÃO DE PLANTAS JOVENS DE EUCALIPTO EM TEMPO REAL	19
RESUMO.....	19
ABSTRACT	20
1 INTRODUÇÃO.....	21
2 MATERIAIS E MÉTODOS	23
3 RESULTADOS	29
4 DISCUSSÃO.....	35
5 CONCLUSÃO	40
REFERÊNCIAS	41
CAPÍTULO 2: MODELO DE DETECÇÃO DE ESTRESSE HÍDRICO EM PLANTAS JOVENS DE EUCALIPTO VISANDO A IRRIGAÇÃO LOCALIZADA E EM TEMPO REAL	45
RESUMO.....	45
ABSTRACT	46
1 INTRODUÇÃO.....	47
2 MATERIAL E MÉTODOS	49
2.1 Área de estudo	49
2.2 Obtenção e processamento dos dados	50
2.3 Treinamento dos modelos	51
2.4 Análise dos modelos.....	54
3 RESULTADOS E DISCUSSÃO	56
4 CONCLUSÃO	70
REFERÊNCIAS	71
CAPÍTULO 3: SISTEMA PARA DETECÇÃO DE PLANTAS JOVENS DE EUCALIPTO UTILIZANDO YOLOV5	76
RESUMO.....	76
ABSTRACT	77
1 INTRODUÇÃO.....	78
2 MATERIAL E MÉTODOS	81
2.1 Área de estudo	81
2.2 Obtenção e processamento das imagens.....	82

2.3	Desenvolvimento do modelo.....	82
2.4	Ensaio em campo	86
2.4.1	Detecção de plantas jovens de eucalipto utilizando plataforma robótica remotamente controlada	86
2.4.2	Avaliação de desempenho do sistema de detecção em tempo real em testes de campo na área experimental	88
3	RESULTADOS E DISCUSSÃO	89
3.1	Ensaio em campo.....	95
4	CONCLUSÕES.....	103
	REFERÊNCIAS.....	104
	CONCLUSÃO GERAL	109

INTRODUÇÃO GERAL

A silvicultura é a base para o desenvolvimento das indústrias de madeira, papel e celulose, fornecendo a matéria-prima essencial para esses setores (Brainer, 2022). Entre as espécies cultivadas, o eucalipto se destaca por sua alta produtividade e rápido crescimento, tornando-se a principal escolha para plantações comerciais (Silva et al., 2024). Essa preferência resulta tanto da eficiência na produção de madeira quanto da facilidade de mecanização das práticas de manejo florestal (Ferigolo et al., 2024). Contudo, a valorização crescente das terras agrícolas tem pressionado o cultivo de eucalipto para áreas menos favoráveis, onde baixos índices pluviométricos e solos com limitada capacidade de retenção de água expõem as plantas jovens a déficits hídricos, prejudicando seu estabelecimento (Navroski et al., 2014; Tadeu, 2014).

A propagação de mudas clonais de eucalipto, amplamente utilizada para intensificar os plantios comerciais (Masiero et al., 2022), demanda cuidados especiais em regiões de baixa pluviosidade, onde a irrigação nas primeiras semanas após o plantio é essencial para garantir a sobrevivência e o vigor das mudas (Teixeira, 2023). Embora a irrigação localizada na cova seja eficaz, os elevados custos operacionais, associados à mão de obra e equipamentos especializados, impulsionam a busca por soluções automatizadas para aumentar a eficiência e reduzir os custos (Fontes, 2013).

O uso de tecnologias mecanizadas e automáticas na irrigação de mudas de eucalipto tem mostrado avanços significativos na eficiência operacional (Marques et al., 2019). Sistemas automatizados que identificam e irrigam plantas jovens em campo aumentam a precisão do processo e otimizam a utilização dos recursos hídricos, promovendo o crescimento saudável das mudas (Nunes, 2022). Para viabilizar essa automação, técnicas de visão computacional têm sido empregadas para detectar plantas em tempo real, utilizando aprendizado de máquina e redes neurais profundas (Oudah et al., 2024).

Entre essas técnicas, destaca-se o algoritmo YOLO (*You Only Look Once*), amplamente reconhecido por sua velocidade e precisão na identificação de objetos, sendo adequado para aplicações em tempo real (Akagić et al., 2024). A aplicação do YOLO na identificação de mudas recém-transplantadas pode transformar o manejo da irrigação, ajustando a quantidade de água aplicada conforme a necessidade de cada planta, otimizando o uso dos recursos hídricos (Zhang et al., 2024).

No Brasil, onde o eucalipto ocupa vastas áreas de florestas plantadas, o uso eficiente da água é essencial. A identificação precisa de estresse hídrico em mudas permite implementar estratégias de manejo mais sustentáveis, otimizando o consumo de água (Neupane & Guo, 2019). Além disso, a integração de geotecnologias com visão computacional permite a criação de mapas detalhados de estresse hídrico ao associar as detecções das mudas a módulos GPS. Dessa forma, é possível georreferenciar cada muda identificada e correlacionar sua localização com características visuais indicativas da presença ou ausência de estresse hídrico, possibilitando a aplicação de estratégias de irrigação mais precisas e direcionadas.

A irrigação realizada de forma uniforme e sem considerar as necessidades específicas de cada planta, é ineficaz e leva ao desperdício de água (Lakhtiar et al., 2019). A adoção de sistemas automatizados que monitoram o estado hídrico das plantas em tempo real, utilizando inteligência artificial, proporciona um controle preciso da irrigação, melhorando a eficiência do uso da água e a saúde das plantas (Wei et al., 2024). A automação também contribui para a redução dos custos operacionais e do uso de mão de obra, promovendo uma abordagem mais sustentável e econômica a longo prazo (Ferrarezi et al., 2021; Mokhtari et al., 2022).

A detecção de estresse hídrico por meio de técnicas de visão computacional, como o YOLO, tem demonstrado grande potencial para melhorar o manejo agrícola, oferecendo uma solução automatizada para a detecção do estresse em plantas. Sistemas como o WS-YOLO utilizam imagens infravermelhas e *deep learning* para identificar sinais de estresse hídrico em mudas, permitindo ajustes eficientes e oportunos na irrigação (Wolter-Salas et al., 2023; Kamarudin et al., 2021).

A aplicação de técnicas avançadas, como a combinação de robótica, sensores e aprendizado profundo, tem possibilitado melhorias na detecção de plantas em campo, permitindo intervenções específicas como irrigação direcionada, controle de pragas e manejo de nutrientes (Zhang & Qiao, 2024). Esses sistemas automatizados promovem uma abordagem mais eficiente e sustentável para a agricultura, reduzindo a dependência de mão de obra e otimizando o uso de recursos (Karunathilake et al., 2023).

Para atender às demandas computacionais de algoritmos avançados como o YOLO, o uso de hardware especializado, como as GPUs da família NVIDIA Jetson, tem se mostrado eficaz. Essas plataformas oferecem processamento paralelo eficiente e baixo consumo de energia, permitindo a execução de modelos de

aprendizado de máquina em tempo real, essenciais para a automação agrícola (Mittal et al., 2019).

Os algoritmos YOLOv5 e YOLOv8 são amplamente reconhecidos pela sua rapidez e precisão na detecção de objetos, o que os torna adequados para aplicações agrícolas que demandam respostas rápidas e acuradas (Chitrangrum et al., 2024). A integração desses algoritmos com plataformas como a NVIDIA Jetson amplia as possibilidades de automação, permitindo que sistemas robóticos operem de forma autônoma em campo, capturando e processando imagens em tempo real para a tomada de decisões (Fan et al., 2023).

No entanto, apesar desses avanços, ainda existem lacunas importantes a serem preenchidas. A maioria dos estudos se concentra na detecção de outras culturas, frequentemente por meio de imagens aéreas e com finalidades distintas, não abordando a detecção com câmeras proximais voltada para a automação da irrigação localizada em tempo real. Além disso, a irrigação de mudas jovens de eucalipto em larga escala ainda carece de soluções eficazes que possam operar de forma robusta em condições reais de campo. Também há uma escassez de estudos que comparem diretamente diferentes versões do YOLO para essa aplicação específica, avaliando seu desempenho em termos de acurácia, velocidade de inferência e viabilidade em hardware embarcado. Neste contexto, esta pesquisa se propõe a investigar essas lacunas, desenvolvendo e avaliando modelos de detecção de mudas de eucalipto para aplicação na automação da irrigação, contribuindo para a otimização dos processos agrícolas.

Dentre as diversas versões do YOLO, o YOLOv5 e o YOLOv8 apresentam características que os tornam adequados para a detecção de mudas de eucalipto em tempo real, permitindo sua aplicação na automação da irrigação localizada. Esses modelos de redes neurais convolucionais foram desenvolvidos para equilibrar precisão, velocidade de inferência e eficiência computacional, tornando-os viáveis para dispositivos embarcados e operações em campo. A escolha entre diferentes versões do YOLO impacta diretamente o desempenho do sistema, já que cada uma possui particularidades estruturais que influenciam sua capacidade de generalização e consumo de recursos. Dessa forma, comparar o YOLOv5 e o YOLOv8 torna-se essencial para determinar qual modelo oferece maior confiabilidade e eficiência na automação da irrigação.

Com base nessas considerações, o YOLOv5 e o YOLOv8 foram selecionados para esta pesquisa devido às suas vantagens em termos de desempenho e adaptabilidade a aplicações em tempo real. O YOLOv5, amplamente utilizado na comunidade de visão computacional, destaca-se por sua boa relação entre precisão e velocidade de inferência, além de ser altamente otimizado para execução em dispositivos embarcados como a NVIDIA Jetson Nano. O YOLOv8, por sua vez, representa a versão mais recente da família e incorpora avanços que melhoram a precisão, segmentação e generalização do modelo, tornando-o mais robusto para a detecção de mudas em diferentes condições de campo. A comparação entre essas duas versões possibilita avaliar o impacto das melhorias mais recentes em relação a um modelo consolidado, permitindo a escolha da abordagem mais eficiente para a automação da irrigação localizada. A seleção do YOLOv5 e do YOLOv8 não apenas demonstra sua viabilidade para essa aplicação, mas também reforça seu potencial para implementação prática em sistemas agrícolas de larga escala.

Desta forma, esta tese se estrutura em três capítulos principais. No Capítulo 1, desenvolve-se um sistema automático de detecção de mudas de eucalipto em tempo real, utilizando as redes neurais YOLOv8 e YOLOv5, comparando o desempenho dos modelos em termos de precisão, recall e outras métricas relevantes para a automação da irrigação. No Capítulo 2, propõe-se o uso de técnicas de inteligência artificial para identificar sintomas de estresse hídrico em mudas de eucalipto, possibilitando o controle da irrigação em tempo real com base nas necessidades hídricas das plantas. O Capítulo 3 aborda o desenvolvimento de um sistema de detecção em tempo real testado em campo com a placa NVIDIA Jetson Nano, demonstrando seu potencial para otimizar práticas de manejo, como irrigação, adubação e controle de pragas. Assim, esta tese contribui de forma significativa para a automação e a eficiência do manejo hídrico em plantações de eucalipto, promovendo o uso racional dos recursos e garantindo a sustentabilidade do cultivo em áreas comerciais.

REFERÊNCIAS

AKAGIĆ, A.; SARIĆ, R.; BUZA, E.; KECMAN, S.; LEWSEY, M. G.; ČUSTOVIĆ, E.; & WHELAN, J. Rosette Plant Centre Detection and Tracking Using YOLO: An Efficient Deep Learning Approach. In: **2024 IEEE 3rd International Conference on Computing and Machine Intelligence (ICMI)**. IEEE, p. 1-6, 2024.

BRAINER, M. S. C. P. PRODUTOS FLORESTAIS: v. 7 n. 213 (2022). **Caderno Setorial ETENE**, v. 7, 2022.

CHITRANINGRUM, N.; BANOWATI, L.; HERDIANA, D.; MULYATI, B.; SAKTI, I.; FUDHOLI, A.; ... & ANDRIA, A. Comparison Study of Corn Leaf Disease Detection based on Deep Learning YOLO-v5 and YOLO-v8. **Journal of Engineering and Technological Sciences**, v. 56, n. 1, p. 61-70, 2024.

FAN, X.; CHAI, X., ZHOU, J.; & SUN, T. Deep learning based weed detection and target spraying robot system at seedling stage of cotton field. **Computers and Electronics in Agriculture**, v. 214, p. 108317, 2023.

FERIGOLO, L. A.; NOLASCO, B. G.; BRANDELERO, C.; DA SILVA, E. F. C.; NUNES, É. J. A.; RUSSINI, A.; & SCHLOSSER, J. F. Tempos e movimentos em operações de colheita florestal mecanizada no Brasil: uma revisão sistemática. **OBSERVATÓRIO DE LA ECONOMÍA LATINOAMERICANA**, v. 22, n. 8, p. e6450-e6450, 2024.

FERRAREZI, R. S.; PENG, T. W. Smart system for automated irrigation using internet of things devices. **HortTechnology**, v. 31, n. 6, p. 642-649, 2021.

FONTES, Luiz Felipe Pereira. **Irrigating eucalyptus at the initial development phase in soils of the Rio Doce watershed**. 70 f. Dissertação (Mestrado em Agrometeorologia; Climatologia; Micrometeorologia) - Universidade Federal de Viçosa, Viçosa, 2013.

KAMARUDIN, M. H.; ISMAIL, Z. H.; SAIDI, N. B. Deep learning sensor fusion in plant water stress assessment: A comprehensive review. **Applied Sciences**, v. 11, n. 4, p. 1403, 2021.

KARUNATHILAKE, E. M. B. M.; LE, A. T.; HEO, S.; CHUNG, Y. S.; MANSOOR, S. The path to smart farming: Innovations and opportunities in precision agriculture. **Agriculture**, v. 13, n. 8, p. 1593, 2023.

LAKHIAR, I. A.; YAN, H.; ZHANG, C.; WANG, G.; HE, B.; HAO, B.; & RAKIBUZZAMAN, M. A Review of Precision Irrigation Water-Saving Technology under Changing Climate for Enhancing Water Use Efficiency, Crop Yield, and Environmental Footprints. **Agriculture**, v. 14, n. 7, p. 1141, 2024.

MARQUES, M.; OGURI, G.; DUARTE, T.; VASCONCELOS, T.; GUERRA, S. Assessing automated mechanized irrigation / Avaliação da automação do irrigador mecanizado. In: **XXV IUFRO WORLD CONGRESS: FOREST RESEARCH AND**

COOPERATION FOR SUSTAINABLE DEVELOPMENT. Pesq. flor. bras., Colombo, v. 39, e201902043, Special issue, p. 1-768, 2019.

MASIERO, M. A.; DE OLIVEIRA, V. H. D.; DA SILVA, L. S.; DA SILVA, E. C.; CORDEIRO, N. K.; DOS SANTOS ALMEIDA, J.; PINHEIRO, J. F. Aspectos sobre o melhoramento genético do eucalipto no Brasil. In: **PESQUISAS AGRÁRIAS E AMBIENTAIS** [livro eletrônico]: Volume XII. Nova Xavantina, MT: Pantanal Editora, 2022. 143 p.

MITTAL, S. A survey on optimized implementation of deep learning models on the nvidia jetson platform. **Journal of Systems Architecture**, v. 97, p. 428-442, 2019.

MOKHTARI, H., BENZAOUIA, M., BEKKAY, H., & CHAABANE, K. A Review on Precision Irrigation Techniques and Controls for Better Water Use Efficiency in Agriculture. In: **International Conference on Electronic Engineering and Renewable Energy Systems**. Singapore: Springer Nature Singapore, p. 707-716, 2022.

NAVROSKI, M. C.; ARAUJO, M. M.; SILVA CUNHA, F.; BERGHETTI, A. L. P.; DE OLIVEIRA P. M., Influência do polímero hidrorretentor na sobrevivência de mudas de *Eucalyptus dunnii* sob diferentes manejos hídricos. **Nativa**, v. 2, n. 2, p. 108-113, 2014.

NEUPANE J, GUO W. Agronomic basis and strategies for precision water management: A review. **Agronomy**, v. 9, n. 2, p. 87, 2019.

NUNES, Karolina dos Reis. **Avaliação da irrigação mecanizada automatizada por câmera RGB em diferentes condições operacionais em plantio de eucalipto.** Orientador. Álvaro Augusto Vieira Soares. 2022. 21 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Florestal) – Universidade Federal de Uberlândia, Monte Carmelo, 2023.

OUDAH, M.; AL-NAJI, A.; AL-JANABI, T. Y; NAMAA, D. S.; & CHAHL, J. Automatic Irrigation System Based on Computer Vision and an Artificial Intelligence Technique Using Raspberry Pi. **Automation**, v. 5, n. 2, p. 90-105, 2024.

SILVA, L. F.; BRAGA, R. S. S.; PAES, J. B.; BRITO, F. M. S.; CORREIA, N. P. C. M.; & FERREIRA, G. Tensões de crescimento, desdobro, secagem natural e desafios da industrialização da madeira de eucalipto. **Editora Licuri**, p. 61-72, 2024

TADEU, Natalia Dias. **Avaliação dos impactos hídricos da monocultura de eucalipto cultivado no trecho paulista da Bacia Hidrográfica do rio Paraíba do Sul (Brasil).** 2014. 176 f. Dissertação (Mestrado em Ciência Ambiental) – Programa de Pós-Graduação em Ciência Ambiental, Universidade de São Paulo, São Paulo, 2014.

TEIXEIRA, Camila Macedo. **Redução do volume de irrigação de plantio de eucalipto para ganhos operacionais, sociais e ambientais.** 2022. 38 f. Dissertação de Mestrado em Planejamento e Uso de Recursos Renováveis, Universidade Federal de São Carlos, Sorocaba, 2022.

WEI, H.; XU, W.; KANG, B.; EISNER, R.; MULEKE, A.; RODRIGUEZ, D.; ... & HARRISON, M. T. Irrigation with Artificial Intelligence: Problems, Premises, Promises. **Human-Centric Intelligent Systems**, p. 1-19, 2024.

WOLTER-SALAS, S.; CANESSA, P.; CAMPOS-VARGAS, R.; OPAZO, M. C. V; SEPULVEDA, R.; & AGUAYO, D. WS-YOLO: An Agronomical and Computer Vision-Based Framework to Detect Drought Stress in Lettuce Seedlings Using IR Imaging and YOLOv8. In: **International Conference on Advanced Research in Technologies, Information, Innovation and Sustainability**. Cham: Springer Nature Switzerland, 2023. p. 339-351.

ZHANG, B.; & QIAO, Y. Sensors, and Robotics for Smart Agriculture. **Agronomy**, v. 14, n. 6, p. 1180, 2024.

ZHANG, T.; ZHOU, J.; LIU, W.; YUE, R.; YAO, M.; SHI, J.; & HU, J. Seedling-YOLO: High-Efficiency Target Detection Algorithm for Field Broccoli Seedling Transplanting Quality Based on YOLOv7-Tiny. **Agronomy**, v. 14, n. 5, p. 931, 2024.

CAPÍTULO 1: DESENVOLVIMENTO DE MODELOS DE DETECÇÃO DE PLANTAS JOVENS DE EUCALIPTO EM TEMPO REAL

RESUMO

Os plantios florestais, especialmente de eucalipto, são a base da indústria de madeira e celulose, fornecendo matéria-prima essencial para a produção em larga escala. Um dos desafios enfrentados pelas empresas florestais na produção de eucalipto é a mortalidade das mudas após o transplante devido ao déficit hídrico. Uma solução para mitigar esse problema é a irrigação das plantas por meio de sistemas semi-mecanizados, que combinam o uso de máquinas com trabalho manual. Entretanto, isso torna a operação onerosa. Uma forma de resolver o problema é por meio da adoção de sistemas automáticos de irrigação totalmente mecanizados, reduzindo a dependência de trabalho manual e aumentando a eficiência operacional. Para que essa automação seja eficaz, a detecção precisa das mudas em tempo real torna-se essencial, garantindo que a irrigação seja aplicada de forma direcionada e otimizada. Diante disso, este estudo teve como objetivo avaliar e comparar modelos de inteligência artificial para a detecção de mudas de eucalipto, visando sua aplicação na automação da irrigação. Foram construídos e treinados dois modelos de detecção em tempo real de plantas de eucalipto usando imagens obtidas em campo e as redes neurais YOLOv8 e YOLOv5. Métricas de avaliação, como precisão, recall, mAP50 e mAP50-95, foram utilizadas para comparar o desempenho dos modelos e identificar a abordagem mais adequada para futuras aplicações em sistemas de irrigação localizada em tempo real. O YOLOv8 apresentou melhor desempenho na detecção de mudas de eucalipto em comparação ao YOLOv5, com maior precisão (0,958 contra 0,951), mAP50 (0,974 contra 0,972) e mAP50-95 (0,836 contra 0,791). O YOLOv5, por outro lado, foi mais rápido no treinamento, com 4,10 iterações por segundo contra 3,68 do YOLOv8, além de exigir menor poder computacional. Apesar das diferenças, ambos os modelos demonstraram eficácia na detecção das mudas. Assim, a escolha entre os dois dependerá do equilíbrio entre precisão e eficiência computacional necessário para a aplicação específica.

Palavras-chave: inteligência artificial; irrigação; eficiência operacional.

ABSTRACT

Planted forests, especially eucalyptus, form the foundation of the wood and pulp industry, providing essential raw material for large-scale production. One of the challenges faced by forestry companies in eucalyptus production is seedling mortality after transplanting due to water deficit. A solution to mitigate this problem is plant irrigation using semi-mechanized systems, which combine machine use with manual labor. However, this makes the operation costly. One way to address this issue is through the adoption of fully mechanized automatic irrigation systems, reducing reliance on manual labor and increasing operational efficiency. For this automation to be effective, real-time accurate seedling detection becomes essential, ensuring that irrigation is applied in a targeted and optimized manner. Given this, this study aimed to evaluate and compare artificial intelligence models for eucalyptus seedling detection, aiming at their application in irrigation automation. Two real-time eucalyptus seedling detection models were built and trained using field-acquired images and YOLOv8 and YOLOv5 neural networks. Evaluation metrics such as precision, recall, mAP50, and mAP50-95 were used to compare the performance of the models and identify the most suitable approach for future applications in real-time localized irrigation systems. YOLOv8 outperformed YOLOv5 in eucalyptus seedling detection, achieving higher precision (0.958 vs. 0.951), mAP50 (0.974 vs. 0.972), and mAP50-95 (0.836 vs. 0.791). YOLOv5, on the other hand, was faster in training, with 4.10 iterations per second compared to 3.68 for YOLOv8, and required lower computational power. Despite these differences, both models demonstrated effectiveness in seedling detection. Thus, the choice between the two will depend on the balance between accuracy and computational efficiency required for the specific application.

Keywords: artificial intelligence; irrigation; operational efficiency.

1 INTRODUÇÃO

Os plantios florestais desempenham papel estratégico para o setor industrial de madeira e papel e celulose. Dentre as espécies florestais cultivadas, o eucalipto se destaca perante as demais, em que mais de 77 % das áreas são plantadas com espécies desse gênero (Calazans et al., 2021). O motivo para esse predomínio no cultivo de eucaliptos se deve ao fato da rapidez com que as plantas se desenvolvem, resultando em elevadas produtividades de madeira, e pela facilidade com que se mecaniza as principais atividades de cultivo.

A principal forma de propagação do eucalipto é por meio de mudas clonais. Isso tem permitido a intensificação comercial dos plantios. Entretanto, com a valorização das áreas de uso agrícola, o eucalipto passou a ocupar as áreas marginais, de baixa pluviosidade e solos com baixa capacidade de retenção de água. Isso faz com que as plantas recém transplantadas estejam constantemente submetidas a déficit hídrico (Tadeu, 2014), sendo essa a principal causa de mortalidade das mudas após o transplantio (Navroski et al., 2014).

Para garantir uma maior sobrevivência e vigor das mudas em regiões com baixo índice pluviométrico, é indispensável a irrigação nas primeiras semanas após o plantio (Gonçalves et al. 2017; Bernardino et al, 2017). Uma alternativa para o suprimento de água é a irrigação feita de forma localizada na cova (Balieiro, 2021). Essa operação de irrigação de mudas de eucaliptos recém transplantadas é uma prática de alto custo para as empresas florestais, uma vez que necessita intensamente de mão de obra, caminhões pipas ou tratores adaptados (Fontes, 2013). Assim, para reduzir custos, viabilizar a atividade e economizar água, é necessário buscar a automação do processo (Ramos et al., 2021; Inamasu et al., 2011). A automação permite a aplicação precisa da quantidade necessária de água diretamente nas mudas, reduzindo desperdícios por evaporação, escoamento superficial e infiltração excessiva. Além disso, sistemas automáticos podem operar de forma contínua e em tempo real, ajustando a irrigação de acordo com a demanda hídrica das plantas, evitando irrigações excessivas ou desnecessárias.

Em se tratando de automação de irrigação localizada em mudas por meio tratores adaptados, uma alternativa é recorrer a técnicas que permitam a detecção do objeto de interesse em imagens obtidas em tempo real. Por meio de técnicas de visão

artificial é possível localizar objetos em imagens capturadas por câmeras, essa técnica é denominada de detecção de objetos (Mittal et al., 2020).

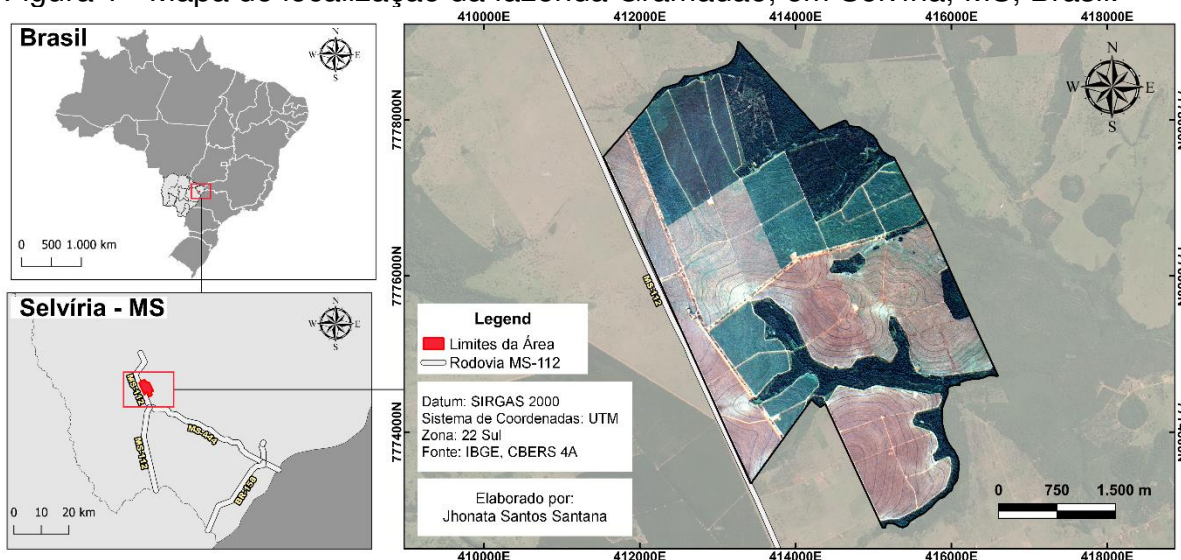
Os principais métodos de detecção de objetos são desenvolvidos com base em aprendizado de máquina e utilizam redes neurais artificiais (RNA) profundas (Tulbure et al., 2022). Os métodos que utilizam RNA profundas vêm sendo utilizados com sucesso na detecção e classificação de objetos (Majchrowska et al., 2022). Dentre as diversas RNA existentes, uma que se destaca atualmente é a YOLO (*You Only Look Once*) (Padala & Malathi, 2022). Com base no equilíbrio entre velocidade e qualidade de detecção, a YOLO é a tecnologia mais recente em reconhecimento de objetos em tempo real (Wang et al., 2022). Devido ao seu elevado poder de detecção, a YOLO está sendo utilizado com sucesso na identificação de objetos em atividades agrícolas, como detecção de frutas (Maceachern et al., 2023; Tang et al., 2023) animais (Reddy, 2021, Yang et al., 2023), doenças de plantas (Seth et al., 2023; Ganesan et al., 2022), plantas daninhas (Dang et al., 2022; Wang et al., 2022a) e raízes (Yang et al., 2022). Logo, em razão de suas características, a YOLO apresenta potencial para detecção rápida e precisa de mudas de eucaliptos recém transplantadas em tempo real. Neste contexto, a YOLO poderia ser aplicada na identificação de mudas de eucalipto recém transplantadas, em imagens obtidas por câmeras proximais, permitindo a identificação em tempo real em sistemas automatizados de irrigação.

Assim, o presente estudo teve como objetivo avaliar a viabilidade dos modelos YOLOv8 e YOLOv5 para a detecção eficiente de mudas de eucalipto recém-transplantadas em tempo real, com potencial aplicação na automação da irrigação localizada. Para isso, comparou-se o desempenho dos modelos por meio das principais métricas de avaliação, com o intuito de identificar a alternativa mais adequada para apoiar a automação da irrigação localizada em sistemas mecanizados.

2 MATERIAIS E MÉTODOS

O estudo foi conduzido em plantios comerciais da Eldorado Brasil Celulose, na Fazenda Gramadão, Selvíria, MS, sob o sistema de cultivo mínimo. Nesse método, o preparo do solo é restrito às linhas de plantio, enquanto os resíduos vegetais da colheita, como cascas, galhos e folhas, são mantidos no local para proteger o solo e contribuir para sua fertilidade. A eliminação da matocompetição foi realizada em etapas pré e pós-emergentes para favorecer o desenvolvimento das mudas. O local de realização do trabalho é indicado no mapa apresentado na Figura 1.

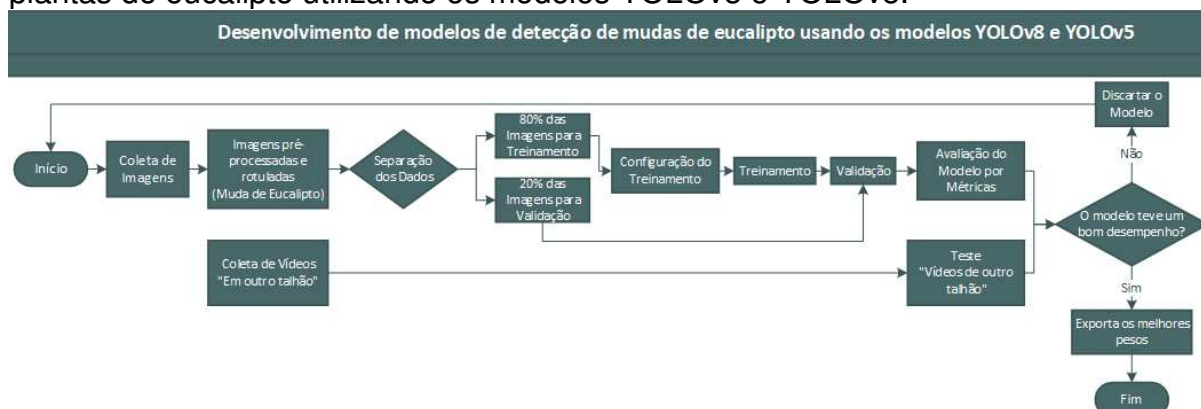
Figura 1 - Mapa de localização da fazenda Gramadão, em Selvíria, MS, Brasil.



Fonte: O autor, (2024).

A Figura 2 apresenta, de forma integrada e estruturada, as etapas e técnicas empregadas no desenvolvimento dos modelos YOLOv8 e YOLOv5 para a detecção de mudas de eucalipto em condições de campo, facilitando o entendimento das metodologias adotadas.

Figura 2 - Etapas envolvidas no desenvolvimento dos modelos de detecção de plantas de eucalipto utilizando os modelos YOLOv8 e YOLOv5.




Fonte: O autor, (2024)..

As imagens obtidas sob condições de campo foram utilizadas para construir e treinar dois modelos personalizados de detecção de mudas de eucalipto em tempo real usando as redes neurais YOLOv8 e YOLOv5. O conjunto de dados consistiu em 10.000 imagens de mudas de eucalipto recém-transplantadas, com três ou mais pares de folhas, capturadas por um operador usando um smartphone Samsung A20s com uma câmera traseira de 13 MP, em cinco diferentes talhões. As imagens foram obtidas em plantios comerciais que seguiam as mesmas práticas de manejo, sendo cultivados com os clones E13 e E50, sob condições semelhantes de solo e manejo. As imagens foram obtidas na primeira semana após o transplante das mudas, durante o período de irrigação localizada na cova. Para proteger as mudas contra danos causados pela radiação solar intensa, algumas plantas receberam protetor solar agrícola, um produto à base de partículas refletoras que reduzem o estresse térmico e minimizam a perda de água por evaporação nas folhas. Esse tratamento visa aumentar a taxa de sobrevivência das mudas nos primeiros dias após o transplante, período crítico para o seu estabelecimento.

Na Figura 3, apresenta-se uma representação visual das variadas condições das mudas de eucalipto observadas em campo durante a aquisição das imagens. Os talhões eram compostos pelos clones E13 e E50, cultivados sob as mesmas práticas de manejo. Durante a aquisição das imagens, foi possível observar uma pequena presença de plantas daninhas nas entrelinhas, porém as linhas de plantio estavam livres de matocompetição devido ao controle realizado nas fases pré e pós-emergente.

Figura 3 - Diferentes clones de eucaliptos e condições das plantas observadas em campo. (a–h) apresentam imagens de diferentes clones de eucalipto capturadas em campo, utilizadas no processo de treinamento do modelo. (g–h) mostram plantas com protetor solar, que ajuda a mitigar os efeitos da exposição excessiva ao sol nos tecidos foliares.




Fonte: O autor, (2024).

Na Figura 3 (a–h) são apresentadas imagens capturadas a uma altura de 1 metro, com a câmera posicionada perpendicularmente ao solo (ângulo de 90° em relação à superfície do terreno), mostrando diferentes clones de eucalipto e as condições das plantas observadas no campo. Essas imagens foram empregadas no processo de treinamento dos modelos. A Figura 3 (g–h) exibe plantas de eucalipto com protetor solar, um produto utilizado para mitigar os efeitos do excesso de radiação solar sobre os tecidos foliares.

O conjunto de dados foi dividido em dois bancos de dados: o banco de dados 1, com 5.000 imagens de plantas de eucalipto capturadas em condições de dia ensolarado (Figura 4e-h), e o banco de dados 2, com 5.000 imagens de plantas de eucalipto capturadas em condições de dia nublado (Figura 4a-d). Em seguida, as imagens foram combinadas em um único banco de dados e divididas em conjuntos de treinamento e validação, na proporção de 80% e 20%, respectivamente. O conjunto de treinamento foi composto por 8.000 imagens, enquanto o conjunto de validação foi composto por 2.000 imagens. Além disso, o conjunto de validação foi organizado de maneira randomizada para manter a mesma proporção de imagens em diferentes condições de iluminação, conforme mostrado na Figura 4.

Figura 4 - Imagens de mudas obtidas em campo sob diferentes condições de iluminação. Imagens de plantas de eucalipto capturadas em dias nublados (a–d) e em dias ensolarados (e–h).



Fonte: O autor, (2024).

A Figura 4a-d apresenta plantas de eucalipto capturadas em dias nublados com céu encoberto por nuvens. Por outro lado, a Figura 4f-h retrata plantas de eucalipto capturadas sob condições de dia ensolarado e céu limpo.

Na etapa seguinte foi realizada a rotulação das imagens de mudas de eucaliptos, para efetuar esta etapa, foi utilizado o software *opensource* LabelImg versão 1.4.0 (Labelimg, 2023). O LabelImg é uma ferramenta de notações gráficas em que se pode demarcar as regiões de interesses tanto para YOLO quanto para outras redes neurais convolucionais. O treinamento dos modelos desenvolvidos utilizando YOLOv8 e YOLOv5 foi conduzido utilizando a placa gráfica NVIDIA A100-SXM4-40GB no ambiente do Google Colab Pro (Bisong, 2019).

Os hiperparâmetros pertencentes aos modelos foram alterados, de acordo com os valores padrões sugeridos nas implementações do YOLOv8 e YOLOv5, ambos desenvolvidos pela empresa Ultralytics (Ultralytics, 2023). Os hiperparâmetros foram mantidos idênticos para ambos os modelos, garantindo uma comparação justa entre eles. O treinamento foi realizado com 600 épocas, tamanho de imagem de 640 pixels, lote de 16, taxa de aprendizado (*learning rate*) de 0,001 e *patience* ajustado para 50. Para minimizar o risco de *overfitting*, foi aplicada a estratégia de *early stopping*, interrompendo o treinamento caso não houvesse melhora no desempenho após 50 épocas. Ao usar os mesmos hiperparâmetros para treinar ambos os modelos, foi possível garantir que qualquer diferença no desempenho é devida às diferenças intrínsecas entre os modelos e não às diferenças nos hiperparâmetros usados.

Após a configuração e implementação dos hiperparâmetros, os modelos foram treinados individualmente, com seus pesos iniciais (treinados em outro conjunto de dados) e posteriormente com seus pesos ajustados, que foram refinados para se adequarem ao conjunto de dados específico de mudas de eucaliptos. A utilização de pesos iniciais para otimização do treinamento é chamada de transferência de aprendizagem, normalmente utilizada na inicialização dos pesos da rede YOLO. Esse procedimento permite ganhos de performance, aproveitando o conhecimento de modelos previamente treinados com grande volume de dados (Menegola et al., 2017).

Nos pesos iniciais foram utilizados o modelo YOLOv8n.pt (YOLOv8 nano) para o treinamento do YOLOv8 e YOLOv5n.pt (YOLOv5 nano) para o treinamento do YOLOv5. Os modelos nanos YOLOv8n.pt e YOLOv5n.pt são ideais para implementação em sistemas embarcados, pois possuem vantagens significativas em relação aos modelos originais quando utilizados para fins de detecção em tempo real em plataformas móveis. Esses modelos foram otimizados para operação em dispositivos com recursos limitados, como sistemas embarcados de máquinas agrícolas, mantendo o equilíbrio entre necessidade de recursos computacionais e a precisão e velocidade de detecção de objetos (Wong et al., 2019).

O progresso do treinamento foi realizado individualmente, adotando-se os seus pesos parciais a cada a retomada do treinamento. Para avaliar e comparar os desempenhos dos modelos, foram utilizadas as métricas: precisão (P), *recall* (R), mAP-50 e mAP50-95 (Lou et al., 2023).

A precisão (P), dada pela Equação (1), é a proporção de detecções verdadeiras em relação ao total de detecções realizadas pelo modelo. O *recall* (R), dado pela Equação (2), é a proporção de detecções verdadeiras em relação ao total de amostras da classe verdadeira.

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

$$R = \frac{(TP)}{(TP) + (FN)} \quad (2)$$

Nas Equações (1) e (2), verdadeiro positivo (TP) corresponde ao número de instâncias positivas que foram corretamente previstas. Falso negativo (FN) representa

o número de instâncias positivas que foram erroneamente previstas como negativas. Falso positivo (FP) denota o número de instâncias negativas que foram erroneamente previstas como positivas.

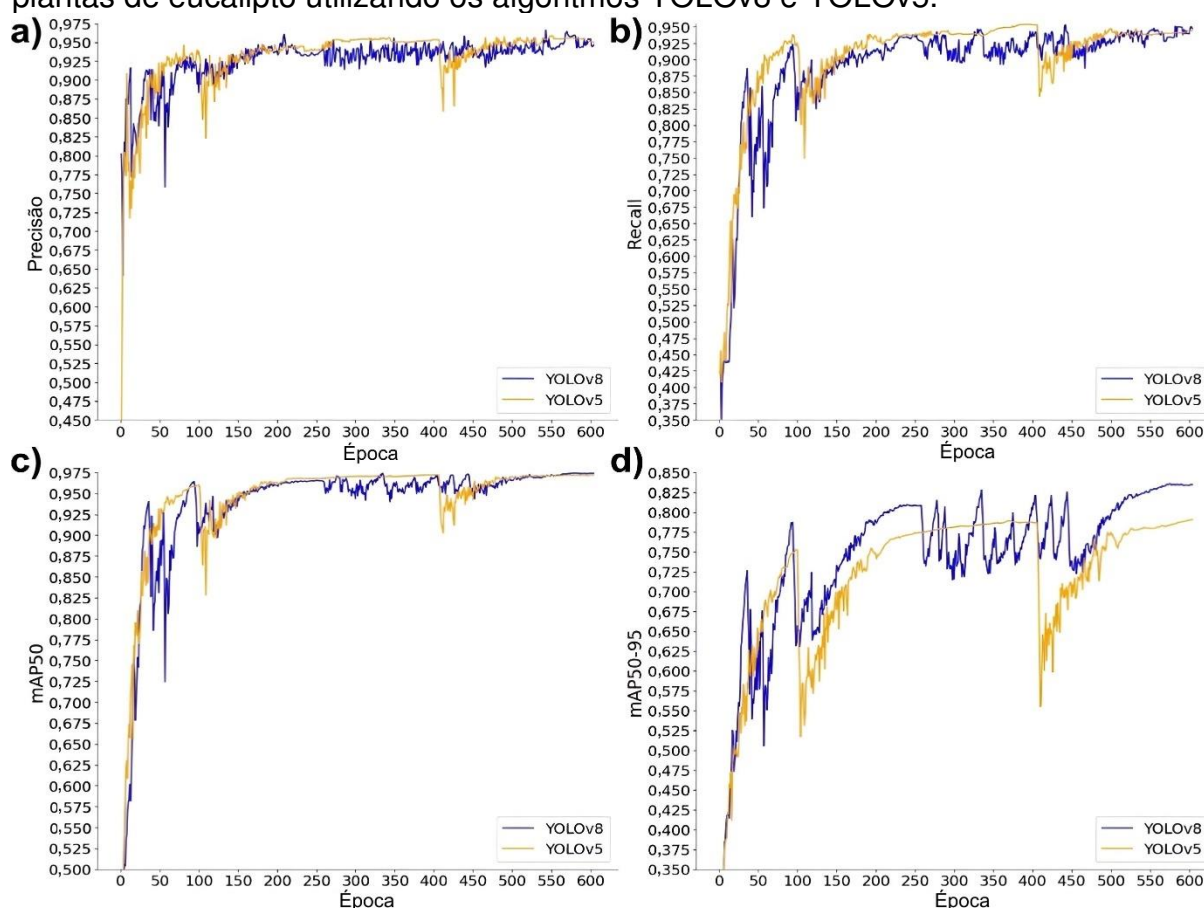
O mAP50 (*mean Average Precision at 50*) calcula um *threshold* de IoU (*Intersection over Union*) de 0,5, ou seja, um objeto é considerado detectado corretamente se a sobreposição entre a caixa delimitadora predita e a caixa delimitadora verdadeira for maior ou igual a 50% (El-Ghoussani et al., 2022). Já o mAP50-95 (*mean Average Precision at 95*) é calculado com um *threshold* de IoU de 0,95, o que significa que o modelo precisa ser mais preciso para considerar um objeto detectado corretamente. Neste caso, a sobreposição entre a caixa delimitadora predita e a caixa delimitadora verdadeira precisa ser maior ou igual a 95% (Ward et al., 2023).

Outra variável utilizada para avaliar o desempenho dos modelos na classificação das imagens foi a pontuação de confiança. A pontuação de confiança é expressa como um valor numérico, geralmente entre 0 e 1, onde valores mais próximos de 1 indicam uma maior confiança. Essencialmente, é uma medida de quão certo o modelo está de que encontrou um objeto e de que o classificou corretamente (Birogul et al., 2020). Quanto maior a pontuação de confiança, maior a probabilidade de a detecção ser correta (Zainuddin et al., 2022). Para validar a detecção das mudas em condições dinâmicas, foram utilizados vídeos capturados em diferentes talhões. Esses vídeos foram obtidos movendo a câmera perpendicularmente, posicionada a um metro de altura sobre as linhas de plantio, simulando o deslocamento de um trator em terceira marcha reduzida. Esse procedimento permitiu avaliar a consistência da detecção em um cenário mais próximo da aplicação real, garantindo que os modelos fossem testados em situações similares às encontradas em campo.

3 RESULTADOS

Ambos os modelos foram capazes de detectar as plantas de eucaliptos recém transplantadas com precisão e *recall* acima de 90%. A diferença no desempenho entre os modelos, para as métricas avaliadas, foi abaixo de 4,5%. Em particular, as diferenças foram mais notáveis no início do treinamento, com o modelo YOLOv5 tendo uma vantagem inicial, mas essa diferença diminuiu ao longo do tempo. A Figura 5 mostra a comparação das métricas de precisão (P), *recall* (R), mAP-50 e mAP50-95 entre os modelos YOLOv8 e YOLOv5, após serem treinados por 600 épocas no conjunto de dados de 8.000 imagens de plantas jovens de eucaliptos.

Figura 5 - Comparação das métricas a) precisão (P); b) *recall* (R); c) mAP50; e d) mAP50-95 para os dados de validação durante a fase de treinamento para detectar plantas de eucalipto utilizando os algoritmos YOLOv8 e YOLOv5.



Fonte: O autor, (2024).

Ao analisar os resultados da métrica de precisão, Figura (5a), entre os modelos YOLOv8 e YOLOv5, nota-se que, durante a maior parte do treinamento, o YOLOv5 exibiu uma precisão superior ao YOLOv8, com um desempenho particularmente

destacado em intervalos específicos, como entre as épocas 210 e 405, e 460 e 590, em que a precisão do YOLOv5 foi até três pontos percentuais maior que a do YOLOv8. Ao atingir 550 épocas, ambos os modelos se estabilizaram com uma precisão entre 94% e 95%. Complementando essa análise, a Figura (5b) ilustra a comparação da métrica de *recall* (R) entre os mesmos modelos, após 600 épocas de treinamento no conjunto de dados composto por 8.000 imagens de plantas de eucaliptos, fornecendo uma perspectiva mais abrangente sobre o desempenho dos modelos em diferentes métricas de avaliação. Em relação à métrica de *recall*, o modelo YOLOv5 apresenta um *recall* maior que o modelo YOLOv8 em praticamente todas as épocas de treinamento. A diferença foi mais expressiva nas primeiras épocas. Além disso, nota-se que a partir da época 150, o YOLOv5 teve maior estabilidade durante o treinamento em relação ao YOLOv8. No entanto, ambos os modelos apresentaram uma Recall entre 93 e 95% ao alcançar as 550 épocas.

Ao analisar a métrica de mAP50 (Figura (5c)), é possível observar que o modelo YOLOv5 apresentou um melhor desempenho em relação ao YOLOv8 durante a maior parte do treinamento, com uma maior diferença nas primeiras épocas, mas que diminui à medida que o número de épocas aumenta. Além disso, o YOLOv5 apresenta uma curva mais suave e consistente em relação ao número de épocas, enquanto o YOLOv8 apresenta uma curva mais instável. No entanto, ambos os modelos mantiveram um desempenho elevado, com um mAP50 de 97%, ao alcançar as 495 épocas.

Após a análise da métrica de mAP50-95, Figura (5d), foi constatado que o modelo YOLOv5 apresentou uma pequena vantagem em relação ao YOLOv8 nas primeiras épocas de treinamento, mas que diminui à medida que o número de épocas aumenta. E a partir da época 105, o YOLOv8 demonstrou um desempenho superior, alcançando uma diferença de até quatro pontos percentuais em relação ao YOLOv5 ao atingir as 600 épocas.

Na Tabela 1 é apresentado os números de verdadeiros positivos e falsos negativos observados na matriz de confusão dos modelos desenvolvidos usando YOLOv8 e YOLOv5, em que a classe prevista foi "muda eucalipto", para um conjunto de validação de 2000 imagens, após 600 épocas de treinamento.

Tabela 1 - Resultados de verdadeiros positivos e falsos positivos nos modelos YOLOv8 e YOLOv5

Observado/Predito	YOLOv8 Predito como Sim (Positivo)	YOLOv5 Predito como Sim (Positivo)
Mudas de Eucalipto Rotuladas como Sim (Positivo)	0,96 1920 (verdadeiro positivo)	0,95 1900 (verdadeiro positivo)
Mudas de Eucalipto Rotuladas como Não (Negativo)	0,04 80 (falso positivo)	0,05 100 (falso positivo)

Fonte: O autor, (2024).

Pode-se verificar que os modelos YOLOv8 e YOLOv5 apresentaram desempenho satisfatório ao serem treinados para reconhecer a classe "Mudas Eucalipto". O modelo YOLOv8 acertou 96% das vezes ao identificar corretamente a classe "Mudas Eucalipto", mas 4% das amostras positivas foram classificadas incorretamente como negativas. Não foram encontrados valores na matriz de confusão de amostras negativas que foram classificadas incorretamente como positivas.

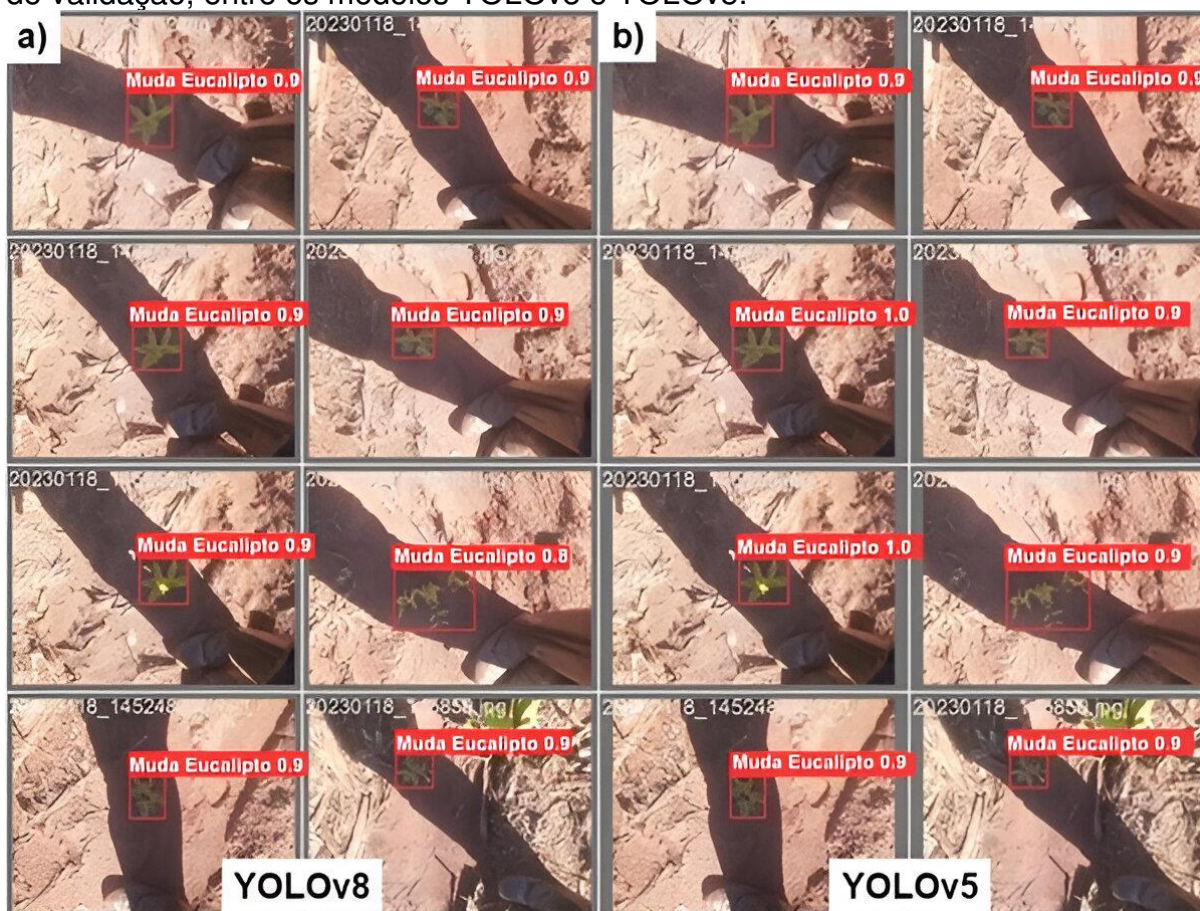
Já o modelo YOLOv5 classificou corretamente 96% das amostras positivas, identificando-as corretamente como mudas de eucalipto. O valor (0,05) na célula inferior indica que 5% das amostras positivas foram classificadas incorretamente como negativas. Como todas as imagens utilizadas no estudo continham uma ou mais mudas de eucalipto, não havia amostras negativas na base de dados. Conseqüentemente, a matriz de confusão não apresentou registros de amostras negativas classificadas erroneamente como positivas.

Foram comparados os resultados da pontuação de confiança dos modelos YOLOv8 e YOLOv5 na classificação de oito imagens de plantas de eucaliptos. Quanto maior for o valor da pontuação de confiança, mais confiante o modelo está que a detecção foi realizada corretamente.

Na Figura 6 são apresentados os resultados da pontuação de confiança realizada pelos dois modelos, no mesmo conjunto de 8 imagens, para as 600 épocas de treinamento. O modelo YOLOv8 obteve uma pontuação de confiança de 90% na classificação de sete das oito imagens, enquanto que, uma imagem foi classificada com a pontuação de confiança de 80%. Já o modelo YOLOv5 obteve uma pontuação de confiança de 100% na classificação de duas das oito imagens, e as outras seis imagens foram classificadas com pontuação de confiança de 90%. Observa-se que

as imagens do conjunto de validação foram capturadas sob diferentes condições de iluminação, incluindo variações causadas pela projeção de sombra do operador sobre a área de interesse. Apesar dessas variações, ambos os modelos demonstraram alta confiabilidade na detecção das mudas, evidenciando sua capacidade de generalização para diferentes condições de campo.

Figura 6 - Comparação da pontuação de confiança em algumas imagens do conjunto de validação, entre os modelos YOLOv8 e YOLOv5.



Fonte: O autor, (2024).

Os resultados apresentados na Tabela 2, se referem à avaliação de desempenho dos modelos de detecção de objetos, YOLOv8 e YOLOv5, após serem treinados por 600 épocas no conjunto de dados de 8.000 imagens de plantas de eucaliptos. O YOLOv8 obteve uma arquitetura com 168 camadas e 8,1 GFLOPs (*Giga Floating-point Operations Per Second*), um indicador de desempenho que representa a quantidade de operações de ponto flutuante realizadas por segundo. Durante a validação, foram utilizadas 2.000 imagens e o modelo foi capaz de detectar 2018 instâncias de plantas de eucaliptos, com uma precisão (P) de 0,958, o que significa

que de todas as detecções positivas, 95,8% estavam corretas. A informação de que o modelo YOLO detectou 2018 instâncias de mudas de eucalipto em um conjunto de 2.000 imagens sugere que, em algumas dessas imagens, o modelo identificou mais de uma planta de eucalipto. A taxa de *recall* (R) foi de 0,935, ou seja, o modelo foi capaz de detectar corretamente 93,5% das instâncias de plantas de eucaliptos presentes nas imagens. O valor de mAP50 foi de 0,974, indica que o modelo alcançou 97,4% de precisão média, considerando um limiar de IoU de 0,5. Já o valor de mAP50-95 foi de 0,836, que representa a precisão média considerando um limiar de IoU entre 50% e 95%. A taxa de processamento do modelo durante a validação foi de 3,68 iterações por segundo. O YOLOv5, por sua vez, teve uma arquitetura com 206 camadas e 4,2 GFLOPs. Durante a validação, foram utilizadas as mesmas 2000 imagens e o modelo detectou 2018 instâncias de mudas de eucaliptos, com uma precisão de 0,951 e recall de 0,944. O valor de mAP50 foi de 0,972 e o de mAP50-95 foi de 0,791. A taxa de processamento do modelo durante a validação foi de 4,10 iterações por segundo.

Tabela 2 - Comparação da predição final entre os modelos YOLOv8 e YOLOv5.

Desempenho do YOLOv8							
Classe	Imagens	Instâncias	P	R	mAP50	mAP50-95	It/s
Muda Eucalipto	2.000	2018	0,958	0,935	0,974	0,836	3,68
Resumo do Modelo: 168 <i>layers</i> , 8,1 GFLOPs							
Desempenho do YOLOv5							
Classe	Imagens	Instâncias	P	R	mAP50	mAP50-95	It/s
Muda Eucalipto	2.000	2018	0,951	0,944	0,972	0,791	4,10
Resumo do Modelo: 206 <i>layers</i> , 4,2 GFLOPs							

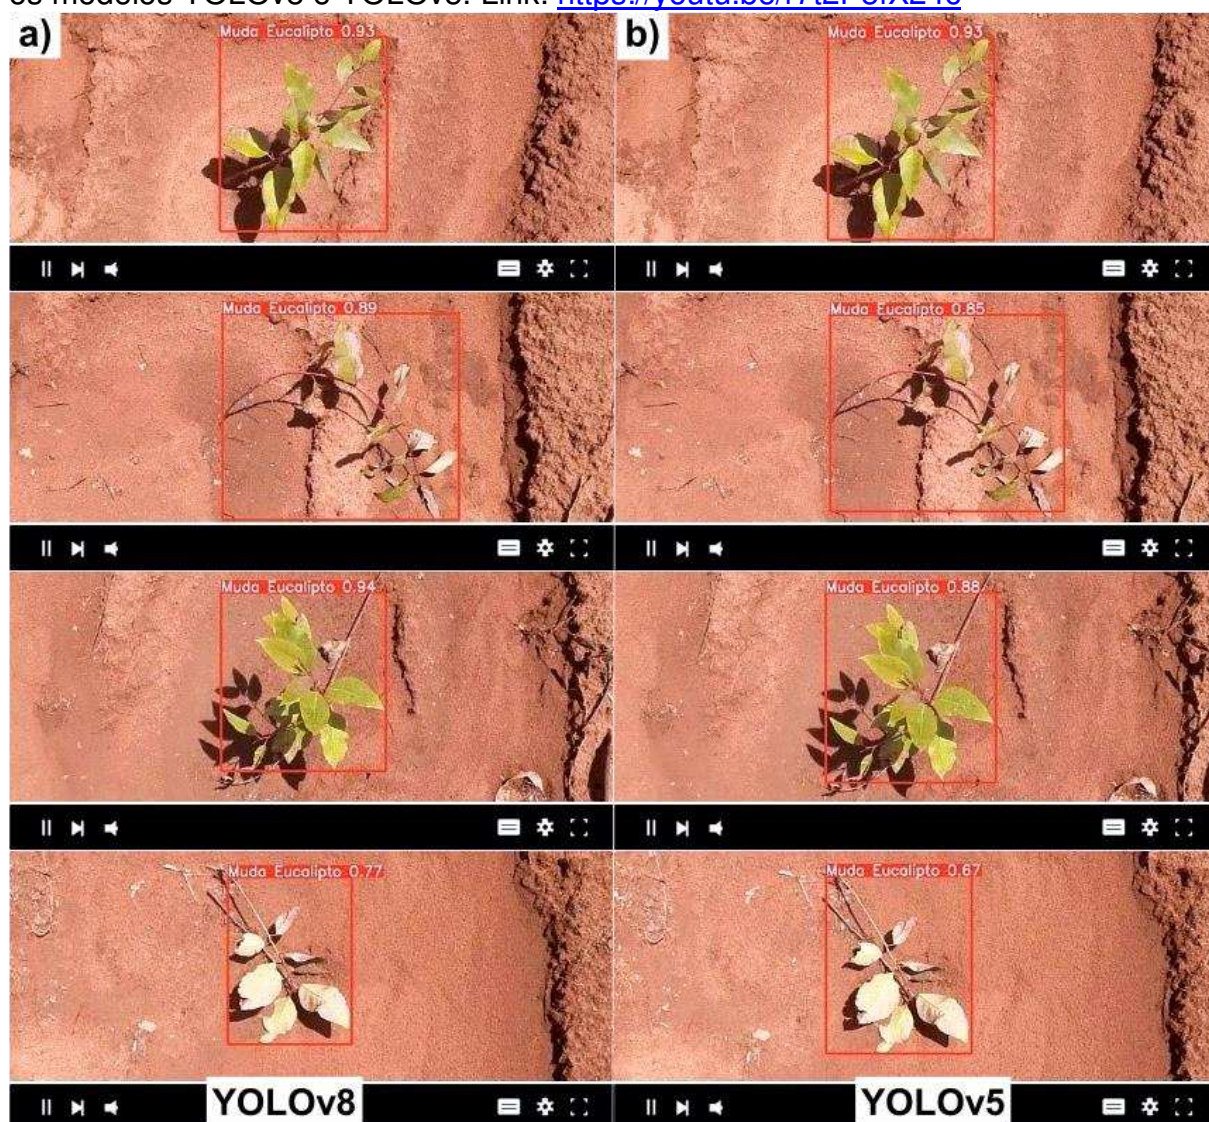
Fonte: O autor, (2024).

A Figura 7 exibe resultados da avaliação de confiança nas detecções de plantas de eucalipto, realizadas em vídeos de teste capturados em diferentes talhões. Estes vídeos foram obtidos movendo a câmera perpendicularmente, posicionada a um metro de altura sobre as linhas de plantio, simulando o movimento de um trator em terceira marcha reduzida.

Ao comparar o desempenho dos modelos YOLOv8 e YOLOv5 nos vídeos de teste, Figura 7, observa-se que ambos os modelos tiveram desempenhos variados.

Em algumas instâncias, os modelos alcançaram pontuações de confiança similares, enquanto em outras, o YOLOv8 apresentou uma pontuação superior ao YOLOv5. Esta variação indica que o desempenho dos modelos pode flutuar dependendo da posição e situação específica de cada planta, refletindo a complexidade e os desafios inerentes ao reconhecimento de imagens em aplicações de aprendizado de máquina.

Figura 7 - Comparação da pontuação de confiança em alguns vídeos de teste, entre os modelos YOLOv8 e YOLOv5. Link: <https://youtu.be/r7t2P8fX24c>



Fonte: O autor, (2024).

4 DISCUSSÃO

Ao analisar a Figura 5(a), em que se observa a comparação da métrica de precisão (P) entre os modelos YOLOv8 e YOLOv5, pode-se observar que mesmo com diferenças iniciais de desempenho, ao alcançar as 600 épocas, ambos os modelos atingiram um patamar aproximado de precisão, mantendo-se entre de 94% a 95%. Uma precisão entre 94% e 95% pode ser considerada satisfatória em muitos contextos de aplicação. Essa faixa de precisão indica que os modelos YOLOv8 e YOLOv5 são capazes de fazer previsões precisas na detecção de plantas de eucaliptos sob condições de campo.

A taxa de *recall* entre 93% e 95% obtida pelos modelos YOLOv8 e YOLOv5 durante as primeiras 600 épocas de treinamento é considerada satisfatória na maioria dos cenários de detecção de objetos. Isso indica que os modelos têm a capacidade de detectar corretamente a maioria das plantas de eucaliptos presentes nos dados de validação. O *recall* é uma métrica importante, pois mede a capacidade do modelo em encontrar todos os exemplos positivos de uma determinada classe.

Uma *mAP50* (*Mean Average Precision at IoU 0,5*) de 97% alcançada pelos modelos YOLOv8 e YOLOv5 ao atingir as 600 épocas de treinamento é considerado um bom desempenho na detecção de plantas de eucaliptos. Uma alta *mAP50* próximo de 100% é desejável em tarefas de detecção de objetos, pois demonstra a eficácia do modelo em realizar a tarefa proposta.

Com base nos valores observados, uma *mAP50-95* de 79% para o YOLOv5 e 83% para o YOLOv8, ao alcançar as 600 épocas de treinamento, pode ser considerado um desempenho satisfatório na detecção de objetos. Isso implica que ambos os modelos são capazes de localizar e identificar corretamente as plantas de eucaliptos com uma precisão significativa, mesmo em casos de maior sobreposição entre as caixas delimitadoras. Valores de *mAP50-95* acima de 70% geralmente são considerados bons e indicam uma capacidade razoável de detecção.

Entretanto, o desempenho do modelo YOLOv5 sofre uma queda notável no cenário mais rigoroso do *mAP50-95* em comparação com o modelo YOLOv8. Essa tendência também foi observada no estudo realizado por Mercado et al. (2023). O *mAP50-95* é uma métrica mais abrangente que avalia a precisão do modelo considerando diferentes limiares de interseção sobre união (IoU), o que reflete sua capacidade de generalização para diferentes níveis de sobreposição entre as

detecções e os objetos reais. A queda no desempenho do YOLOv5 nesse critério sugere que ele pode ter mais dificuldade em manter alta precisão quando exigido um alinhamento mais rigoroso com as verdadeiras localizações das mudas. Por outro lado, o YOLOv8 demonstrou melhor desempenho, indicando maior robustez em cenários onde a exatidão da detecção é essencial para aplicações de automação agrícola.

Com base nos valores de verdadeiros positivos e falsos positivos, resultantes da matriz de confusão, Tabela 1, pode-se verificar que o modelo YOLOv8 apresentou um desempenho ligeiramente melhor do que o YOLOv5 na tarefa de reconhecimento de objetos da classe "Muda Eucalipto". O YOLOv8 acertou 96% das vezes, enquanto o YOLOv5 acertou 95%. Uma possível explicação para essa pequena vantagem do YOLOv8 pode estar relacionada à diferença nas arquiteturas das redes e diferenças nos pesos finais. Quanto à arquitetura das redes, embora os dois modelos sejam baseados na arquitetura YOLO, eles possuem pequenas diferenças na configuração da rede, o que pode levar a diferenças sutis no desempenho. E por fim, sabe-se que o ajuste dos pesos de uma rede pode ter um impacto significativo no desempenho do modelo (Desai, 2024). É possível que os melhores pesos finais do YOLOv8 tenham sido mais adequados para a tarefa em questão, resultando em uma melhor performance.

Com base na Figura 6, observa-se que os modelos YOLOv8 e YOLOv5 apresentaram um desempenho satisfatório na classificação das imagens, com altas pontuações de confiança na maioria dos casos. O YOLOv8 classificou sete das oito imagens com uma pontuação de confiança de 90%, enquanto uma imagem recebeu 80%. Essa pequena variação pode estar associada a fatores como diferenças nas condições de iluminação, sobreposição de objetos ou variações na aparência das mudas, aspectos que podem afetar a certeza do modelo em suas predições. Já o YOLOv5 apresentou pontuações de confiança de 100% em duas imagens e 90% nas demais, sugerindo que o modelo teve um alto grau de certeza na detecção das mudas. No entanto, a obtenção de confiança máxima em algumas imagens não necessariamente indica um desempenho superior, pois pode estar relacionada a um ajuste mais conservador dos limiares de detecção, reduzindo a sensibilidade a variações sutis nas amostras. Esses resultados corroboram com a pesquisa realizada por Dang et al. (2023), que destacaram o potencial dos modelos YOLO, especialmente o YOLOv5n e YOLOv5s, para aplicações de detecção de plantas daninhas em tempo

real. No entanto, a diferença no comportamento entre o YOLOv8 e o YOLOv5 em relação à variação das pontuações de confiança sugere que a escolha do modelo pode depender da necessidade de um equilíbrio entre robustez e sensibilidade à variabilidade do ambiente.

As razões exatas para as menores pontuações de confiança do YOLOv8 (versão mais recente) em relação ao YOLOv5 ainda precisam ser investigadas. Embora, o YOLOv8 tenha um desempenho visivelmente melhor durante o treinamento e validação, o YOLOv5 consegue prever um número maior de imagens com um maior nível de confiança. Essa facilidade de detecção do YOLOv5 em relação ao YOLOv8 também foi observada nos estudos realizados por Yang et al. (2023a).

As imagens analisadas na Figura 6, foram geradas automaticamente pelo modelo ao final do treinamento como uma prévia dos resultados, utilizando um subconjunto aleatório do conjunto de validação. No entanto, é importante ressaltar que a comparação baseada em um número limitado de imagens pode não ser suficiente para determinar com precisão qual modelo apresenta o melhor desempenho geral. Assim, a avaliação definitiva apresentada na Tabela 2, foi conduzida em um conjunto de 2.000 imagens de validação, garantindo uma análise mais abrangente e estatisticamente representativa do desempenho dos modelos.

Ao avaliar os resultados da Tabela 2, o YOLOv8 alcançou uma precisão de 95,8%, um *recall* de 93,5% e um mAP50 de 97,4%. Já o YOLOv5 obteve uma precisão de 95,1%, um *recall* de 94,4% e um mAP50 de 97,2%. Esses resultados mostram que os modelos YOLOv8 e YOLOv5 apresentam desempenho superior em comparação com versões anteriores da família YOLO, o que reforça sua evolução para aplicações agrícolas. Por exemplo, Santana et al. (2023) reportaram uma precisão de 93,3%, um *recall* de 55,5% e um mAP50 de 77,7% na detecção de plantas de café usando o YOLOv3, enquanto Wiggers et al. (2022) obtiveram uma precisão de 84,8%, *recall* de 89,00% e um mAP50 de 65,2% para a detecção de plantas de feijão com o YOLOv4. Comparativamente, os modelos testados neste estudo atingiram maior precisão e *recall*, o que sugere que as melhorias incorporadas ao YOLOv8 e YOLOv5 resultam em maior eficácia para a detecção de mudas de eucalipto em tempo real.

Ao contrapor o YOLOv8 e YOLOv5, uma possível razão para a diferença nos resultados é a arquitetura dos modelos. O YOLOv8 tem uma arquitetura mais complexa que o YOLOv5, permitindo que ele capture mais dados e detalhes relevantes para a detecção da classe "planta de eucaliptos". Além disso, o YOLOv8

foi treinado por mais tempo devido à sua complexidade, o que pode explicar seu desempenho ligeiramente superior em relação ao YOLOv5 nas métricas de precisão (P), mAP50 e mAP50-95. Isso sugere que o YOLOv8 pode ser mais eficiente para a tarefa em questão, desde que o hardware não seja um fator limitante. Modelos mais complexos exigem maior capacidade de processamento e recursos computacionais para executar inferência em tempo real. Se o *hardware* utilizado não for poderoso o suficiente, pode haver restrições de velocidade e desempenho, resultando em tempos de inferência mais lentos (Lee & Hwang, 2022; Xia et al., 2021).

Em relação à análise de desempenho, o YOLOv8 possui menor número de *layers* e uma maior quantidade de GFLOPs em relação ao YOLOv5. Isso indica que o YOLOv8 tem maior capacidade de processamento, pois, quanto maior o número de FLOPs, maior será a quantidade de operações de ponto flutuante realizadas e, conseqüentemente, maior será a carga computacional necessária durante a inferência (YABE & AZUMI, 2021). O YOLOv5 apresentou um processamento mais rápido, realizando 4,10 iterações por segundo, enquanto o YOLOv8 processou a uma taxa de 3,68 iterações por segundo. Além disso, o YOLOv5 possui valores menores de GFLOPs em comparação com o YOLOv8. Essas diferenças indicam que o YOLOv5 pode ter uma vantagem em termos de eficiência computacional, realizando mais tarefas por segundo com menor carga de processamento.

De acordo com os resultados de Dang et al. (2023), o modelo YOLOv5n apresenta tempos de inferência mais rápidos em comparação com as versões anteriores, como o YOLOv4. Esses achados estão alinhados com os resultados deste estudo, que também indicam que o YOLOv5n é mais rápido que o YOLOv8. O YOLOv5 é mais rápido que o YOLOv8 porque possui uma arquitetura mais simples e eficiente em termos de processamento. Isso significa que o YOLOv5 pode processar informações mais rapidamente com menos recursos computacionais, o que pode ser vantajoso em situações em que é necessário realizar detecções em tempo real ou em dispositivos com recursos limitados, como em sistemas embarcados de máquinas agrícolas. Além disso, o menor consumo de energia do YOLOv5 também pode ser uma vantagem em aplicações de dispositivos móveis. O YOLOv5 foi projetado com a otimização de velocidade em mente, o que o torna uma opção mais rápida para tarefas de detecção de objetos em tempo real ou em grandes conjuntos de dados (Thuan, 2021).

Ao analisar os resultados da Figura 7, que apresentam a detecção de mudas de eucalipto em vídeos de teste obtidos em diferentes talhões, observa-se que a posição da planta na cova influencia significativamente as pontuações de confiança dos modelos YOLOv8 e YOLOv5. As plantas identificadas como 'corretamente posicionadas' (plantas 1 e 3) referem-se àquelas que estavam verticalizadas e centralizadas na cova, ou seja, transplantadas de maneira alinhada com o solo e sem inclinação acentuada. Nessas condições, ambos os modelos obtiveram pontuações elevadas, com o YOLOv8 alcançando 93% e 94% de confiança, enquanto o YOLOv5 obteve 93% e 88%, respectivamente. Por outro lado, nas mudas inclinadas ou tombadas dentro da cova (plantas 2 e 4), observou-se uma queda considerável nas pontuações de ambos os modelos. O YOLOv8 registrou 89% e 77% de confiança, enquanto o YOLOv5 obteve 85% e 67%, respectivamente. Essa redução pode estar relacionada à menor semelhança entre essas plantas e aquelas predominantes no conjunto de treinamento, indicando que a variação na posição da muda afeta a robustez dos modelos na detecção. Para lidar com esse problema e aprimorar a detecção das plantas em posições inadequadas, é recomendado aumentar a quantidade de imagens de treinamento que representem essas situações específicas (Dang et al., 2022). Isso permitirá que os modelos YOLOv8 e YOLOv5 aprendam a reconhecer e classificar corretamente as plantas deitadas ou tortas, resultando em pontuações elevadas de confiança para esses casos.

Ambos os modelos apresentaram um bom desempenho em termos de precisão, *recall* e mAP50, mas podem ser aprimorados em relação ao mAP50-95. O YOLOv8 parece ter uma leve vantagem em relação ao modelo YOLOv5 na maioria das métricas avaliadas. Entretanto, o YOLOv5 apresentou um tempo de processamento mais rápido em comparação com o YOLOv8.

5 CONCLUSÃO

Os resultados deste estudo confirmam que tanto o YOLOv8 quanto o YOLOv5 são modelos eficazes para a detecção de mudas de eucalipto em tempo real, demonstrando alta precisão e confiabilidade na identificação das plantas. O YOLOv8 se destaca por apresentar um desempenho ligeiramente superior nas métricas avaliadas, indicando que sua arquitetura mais avançada permite uma melhor detecção sob diferentes condições de campo. Apesar dessa vantagem, ambos os modelos oferecem um desempenho robusto, o que sugere que a escolha entre eles deve considerar não apenas a precisão, mas também fatores como requisitos computacionais e velocidade de inferência. O YOLOv5, por ser menos exigente em termos de hardware, pode ser uma alternativa viável para aplicações onde os recursos computacionais são limitados. Dessa forma, este estudo reforça a aplicabilidade dos modelos YOLO para a automação da detecção de mudas de eucalipto, fornecendo subsídios para futuras implementações em sistemas mecanizados de irrigação e manejo agrícola.

REFERÊNCIAS

- BALIEIRO, F. D. C.; SANTOS, F.; CHAER, G.; & DA COSTA, C. T. R. C. Benefícios dos plantios mistos de eucalipto e acácia em solo arenoso. **Embrapa Solos-Comunicado Técnico (INFOTECA-E)**, Rio de Janeiro: Embrapa Solos, 2021. 14p.
- BERNARDINO, L. T.; BONOM, R.; & SOUZA, J. M. Desenvolvimento inicial de mudas de eucalipto sob diferentes lâminas de irrigação. **Revista Brasileira de Agricultura Irrigada**, v. 13, n. 1, p. 3169-3179, 2019.
- BIROGUL, S.; TEMÜR, G.; & KOSE, U. YOLO object recognition algorithm and “buy-sell decision” model over 2D candlestick charts. **IEEE access**, v. 8, p. 91894-91915, 2020.
- BISONG, E. **Building machine learning and deep learning models on google cloud platform: a comprehensive guide for beginners**, Berkeley, CA: Apress, 59-64p, 2019.
- CALAZANS, C. C.; NUNES, V. V.; SOUZA, J. L.; & SILVA-MANN, R., 2021. Perspectivas Tecnológicas para Eucalyptus: uma Meta-Análise. **In 11th International Symposium on Technological Innovation**. Proceeding of ISTI/SIMTEC, p.1544-1553, 2021.
- DANG, F.; CHEN, D.; LU, Y.; LI, Z.; & ZHENG, Y. DeepCottonWeeds (DCW): a novel benchmark of YOLO object detectors for weed detection in cotton production systems. In: **2022 ASABE Annual International Meeting**. American Society of Agricultural and Biological Engineers, p. 1. 2022.
- DANG, F.; CHEN, D.; LU, Y.; & LI, Z. YOLOWeeds: A novel benchmark of YOLO object detectors for weed detection in cotton production systems. **Computers and Electronics in Agriculture**, July. Volume 205, February, 107655, 2023.
- DESAI, C. Impact of weight initialization techniques on neural network efficiency and performance: A case study with MNIST dataset. **International Journal Of Engineering And Computer Science**, v. 13, n. 04, 2024.
- EL-GHOSSANI, A.; RODRÍGUEZ-SALAS, D.; SEURET, M.; & MAIER, A. GAN-based Augmentation of Mammograms to Improve Breast Lesion Detection. In **Bildverarbeitung für die Medizin 2022: Proceedings, German Workshop on Medical Image Computing**, Heidelberg, Wiesbaden: Springer Fachmedien Wiesbaden, June 26-28, pp. 321-326, 2022.
- FONTES, Luiz Felipe Pereira. **Irrigating eucalyptus at the initial development phase in soils of the Rio Doce watershed**. 70 f. Dissertação (Mestrado em Agrometeorologia; Climatologia; Micrometeorologia) - Universidade Federal de Viçosa, Viçosa, 2013.
- GANESAN, G.; & CHINNAPPAN, J. Hybridization of ResNet with YOLO classifier for automated paddy leaf disease recognition: An optimized model. **Journal of Field Robotics**, v. 39, n. 7, p. 1085-1109, 2022.

GONÇALVES, J. L.; ALVARES, C. A.; ROCHA, J. H.; BRANDANI, C. B.; & HAKAMADA, R. Eucalypt plantation management in regions with water stress. **Southern Forests: a Journal of Forest Science**, v. 79, n. 3, p. 169-183, 2017.

INAMASU, R. Y.; BELLOTE, A.; LUCHIARI JUNIOR, A.; SHIRATSUCHI, L.; DE OLIVEIRA, P. A. V.; & BERNARDI, A. D. C. Agricultura de precisão para a sustentabilidade de sistemas produtivos do agronegócio brasileiro. In: **Inamasu, R.Y. et al. (org.). Agricultura de precisão: um novo olhar**. São Carlos: Embrapa Instrumentação, p. 14-26, 2011.

LABELIMG. 2023. **heartexlabs/labelimg-GitHub**. <https://github.com/tzutalin/labelimg>

LEE, J.; HWANG, K. I. YOLO with adaptive frame control for real-time object detection applications. **Multimedia tools and applications**, v. 81, n. 25, p. 36375-36396, 2022.

LOU, H.; DUAN, X.; GUO, J.; LIU, H.; GU, J.; BI, L.; & CHEN, H. DC-YOLOv8: small-size object detection algorithm based on camera sensor. **Electronics**, v. 12, n. 10, p. 2323, 2023.

MACEACHERN, C. B.; ESAU, T. J.; SCHUMANN, A. W.; HENNESSY, P. J.; & ZAMAN, Q. U. Detection of fruit maturity stage and yield estimation in wild blueberry using deep learning convolutional neural networks. **Smart Agricultural Technology**, v. 3, p. 100099, 2023.

MAJCHROWSKA, S.; MIKOŁAJCZYK, A.; FERLIN, M.; KLAWIKOWSKA, Z.; PLANTYKOW, M. A.; KWASIGROCH, A.; & MAJEK, K. Deep learning-based waste detection in natural and urban environments. **Waste Management**, v. 138, p. 274-284, 2022.

MATOS, P. F.; LOMBARDI, L.; CIFERRI, R.; PARDO, T.; CIFERRI, C.; & VIEIRA, M. **Relatório técnico “métricas de avaliação”**. Universidade Federal de São Carlos (UFSCar), 2009. 15p.

MENEGOLA, A.; FORNACIALI, M.; PIRES, R.; BITTENCOURT, F. V.; AVILA, S.; & VALLE, E. Knowledge transfer for melanoma screening with deep learning. In: **2017 IEEE 14th international symposium on biomedical imaging (ISBI 2017)**. IEEE, p. 297-300, 2017.

MERCALDO, F.; BRUNESE, L.; MARTINELLI, F.; SANTONE, A.; & CESARELLI, M. Object detection for brain cancer detection and localization. **Applied Sciences**, v. 13, n. 16, p. 9158, 2023.

MITTAL, P.; SINGH, R.; & SHARMA, A. Deep learning-based object detection in low-altitude UAV datasets: A survey. **Image and Vision computing**, v. 104, p. 104046, 2020.

NAVROSKI, M. C.; ARAUJO, M. M.; SILVA CUNHA, F.; BERGHETTI, A. L. P.; & PEREIRA, M. O. Influência do polímero hidrorretentor na sobrevivência de mudas de Eucalyptus dunnii sob diferentes manejos hídricos. **Nativa**, v. 2, n. 2, p. 108-113, 2014.

NOBRE, S. R. Forest plantations in Brazil: the race toward sustainability with the help of operations research. **ORMS Today**, v. 4, p. 1-9, 2020.

PADALA, A. K. R.; & MALATHI, P., 2022. An Optimized Object Detection System Using You Only Look Once Algorithm and Compare with Tiny-Yolo algorithm with Increased Accuracy. In: **2022 2nd International Conference on Innovative Practices in Technology and Management (ICIPTM)**. IEEE, 2022. p. 606-610.

RAMOS, M. P. S.; STROPARO, T. R.; & CORDEIRO, G. Inovações tecnológicas em empresas madeireiras do município de Imituva/PR: uma análise sob à égide da teoria evolucionária. **Revista Ibero-Americana de Humanidades, Ciências e Educação**, v. 7, n. 11, p. 859-878, 2021.

REDDY, B. K.; BANO, S.; REDDY, G. G.; KOMMINENI, R.; & REDDY, P. Y. Convolutional network based animal recognition using YOLO and Darknet. In: **2021 6th international conference on inventive computation technologies (ICICT)**. IEEE, p. 1198-1203, 2021.

SANTANA, L. S.; FERRAZ, G. A. E. S.; SANTOS, G. H. R. D.; BENTO, N. L.; & FARIA, R. D. O. Identification and Counting of Coffee Trees Based on Convolutional Neural Network Applied to RGB Images Obtained by RPA. **Sustainability**, v. 15, n. 1, p. 820, 2023.

SETH, V.; PAULUS, R.; & KUMAR, A. Tomato leaf diseases detection using deep learning—a review. **Intelligent Systems and Smart Infrastructure**, p. 118-131, 2023.

TADEU, Natalia Dias. **Avaliação dos impactos hídricos da monocultura de eucalipto cultivado no trecho paulista da Bacia Hidrográfica do rio Paraíba do Sul (Brasil)**. 2014. 176 f. Dissertação (Mestrado em Ciência Ambiental) – Programa de Pós-Graduação em Ciência Ambiental, Universidade de São Paulo, São Paulo, 2014.

TANG, Y.; ZHOU, H.; WANG, H.; & ZHANG, Y. Fruit detection and positioning technology for a Camellia oleifera C. Abel orchard based on improved YOLOv4-tiny model and binocular stereo vision. **Expert systems with applications**, v. 211, p. 118573, 2023.

THUAN, Do. **Evolution of YOLO algorithm and YOLOv5: The state-of-the-art object detection algorithm**. 2021. 61 p. Bachelor's Thesis (Bachelor's Degree in Information Technology) – Oulu University of Applied Sciences, Oulu, 2021. Available at: <https://www.theseus.fi/handle/10024/452552>. Accessed on: May 11, 2023.

TULBURE, A. A.; TULBURE, A. A.; & DULF, E. H. A review on modern defect detection models using DCNNs—Deep convolutional neural networks. **Journal of Advanced Research**, v. 35, p. 33-48, 2022.

ULTRALYTICS. 2023. **Ultralytics YOLOv8 Docs**, 2023. Acesso em: 10 mai. 2023.

WANG, Q.; CHENG, M.; HUANG, S.; CAI, Z.; ZHANG, J.; & YUAN, H. A deep learning approach incorporating YOLO v5 and attention mechanisms for field real-time detection of the invasive weed *Solanum rostratum* Dunal seedlings. **Computers and Electronics in Agriculture**, v. 199, p. 107194, 2022.

WANG, Z.; JIN, L.; WANG, S.; & XU, H. Apple stem/calyx real-time recognition using YOLO-v5 algorithm for fruit automatic loading system. **Postharvest Biology and Technology**, v. 185, p. 111808, 2022.

WARD, T.; RASHAD, S.; & ELGAZZAR, H. Machine Learning Based Pedestrian Detection and Tracking for Autonomous Vehicles. In: **2023 IEEE 13th Annual Computing and Communication Workshop and Conference (CCWC)**. IEEE, p. 1294-1299, 2023.

WIGGERS, K. L.; POHLOD, C. D.; ORLOVSKI, R.; FERREIRA, R.; & SANTOS, T. A. Detection and counting of plants via deep learning using images collected by RPA. **Revista Brasileira de Ciências Agrárias**, v. 17, n. 2, p. e1353, 2022.

WONG, A.; FAMUORI, M.; SHAFIEE, M. J.; LI, F.; CHWYL, B.; & CHUNG, J. YOLO nano: A highly compact you only look once convolutional neural network for object detection. In: **2019 Fifth Workshop on Energy Efficient Machine Learning and Cognitive Computing-NeurIPS Edition (EMC2-NIPS)**. IEEE, p. 22-25, 2019.

XIA, C.; REN, M.; WANG, B.; DONG, M.; XU, G.; XIE, J.; & ZHANG, C. Infrared thermography-based diagnostics on power equipment: State-of-the-art. **High Voltage**, v. 6, n. 3, p. 387-407, 2021.

YABE, T.; & AZUMI, T. Exploring the performance of deep neural networks on embedded many-core processors. In: **2022 ACM/IEEE 13th International Conference on Cyber-Physical Systems (ICCPS)**. IEEE, p. 193-202, 2022.

YANG, G.; WANG, J.; NIE, Z.; YANG, H.; & YU, S. A lightweight YOLOv8 tomato detection algorithm combining feature enhancement and attention. **Agronomy**, v. 13, n. 7, p. 1824, 2023a.

YANG, J.; ZHANG, T.; FANG, C.; & ZHENG, H. A defencing algorithm based on deep learning improves the detection accuracy of caged chickens. **Computers and Electronics in Agriculture**, v. 204, p. 107501, 2023.

YANG, K.; PENG, B.; GU, F.; ZHANG, Y.; WANG, S.; YU, Z.; & HU, Z. Convolutional neural network for object detection in garlic root cutting equipment. **Foods**, v. 11, n. 15, p. 2197, 2022.

ZAINUDDIN, Z.; TULURAN, J.; ACHMAD, A.; ARENI, I. S.; & TAHIR, Z. The Waste Detection System of Shrimp Feeding with a Waterproof Camera using Yolo Algorithm. In: **Journal of Physics: Conference Series**. IOP Publishing, p. 012083, 2022.

CAPÍTULO 2: MODELO DE DETECÇÃO DE ESTRESSE HÍDRICO EM PLANTAS JOVENS DE EUCALIPTO VISANDO A IRRIGAÇÃO LOCALIZADA E EM TEMPO REAL

RESUMO

Os cultivos de eucalipto são fundamentais no setor de celulose, papel e madeira no Brasil, contribuindo significativamente para a economia do país. No manejo do eucalipto, o estresse hídrico representa um grande desafio, resultando em alta taxa de mortalidade das plantas jovens após o transplante. Para enfrentar esse problema, este estudo propôs o uso de técnicas de inteligência artificial para detectar os sintomas de estresse hídrico nas plantas jovens de eucalipto sob condições de campo, visando otimizar os métodos de irrigação ao permitir a aplicação de água em taxa variada e em tempo real. Para o desenvolvimento dos modelos baseados nas redes neurais YOLOv5 e YOLOv8, foram utilizadas imagens de plantas jovens coletadas em campo. Os modelos foram avaliados pelas métricas de precisão, *recall*, mAP50, mAP50-95 e o índice de confiança. O modelo desenvolvido com o YOLOv8 apresentou precisão de 92,4%, *recall* médio de 91,4%, mAP50 de 94,3% e mAP50-95 de 77,8%. Já no modelo desenvolvido com o YOLOv5 foram obtidos uma precisão de 92,5%, *recall* médio de 91,3%, mAP50 de 92,9% e mAP50-95 de 71,3%. Os modelos tiveram índice de confiança elevado na detecção de plantas jovens com e sem estresse hídrico, tanto em imagens quanto em vídeos. Os resultados indicam que os modelos desenvolvidos têm um alto potencial como ferramentas para a automação da irrigação localizada de plantas jovens de eucalipto em condições de campo, permitindo controlar a aplicação de água em taxa variada e em tempo real.

Palavras-chave: inteligência artificial; automação da irrigação; YOLOv8.

ABSTRACT

Eucalyptus cultivation is essential in the pulp, paper, and wood sectors in Brazil, contributing significantly to the country's economy. In eucalyptus management, water stress represents a major challenge, resulting in a high mortality rate of young plants after transplantation. To address this issue, this study proposed the use of artificial intelligence techniques to detect water stress symptoms in young eucalyptus plants under field conditions, aiming to optimize irrigation methods by enabling variable-rate and real-time water application. For the development of models based on the YOLOv5 and YOLOv8 neural networks, images of young plants collected in the field were used. The models were evaluated using precision, recall, mAP50, mAP50-95, and confidence score metrics. The YOLOv8-based model achieved a precision of 92.4%, an average recall of 91.4%, a mAP50 of 94.3%, and a mAP50-95 of 77.8%. Meanwhile, the YOLOv5-based model obtained a precision of 92.5%, an average recall of 91.3%, a mAP50 of 92.9%, and a mAP50-95 of 71.3%. Both models demonstrated a high confidence score in detecting young plants with and without water stress, in both images and videos. The results indicate that the developed models have high potential as tools for automating the localized irrigation of young eucalyptus plants under field conditions, enabling variable-rate and real-time water application control.

Keywords: artificial intelligence; irrigation automation; YOLOv8.

1 INTRODUÇÃO

As espécies pertencentes ao gênero *Eucalyptus* abrangem 76% da área de florestas plantadas no Brasil, totalizando 7,6 milhões de hectares (IBÁ, 2023). O domínio do eucalipto na silvicultura brasileira é impulsionado pela necessidade de suprir a demanda por matéria-prima nas indústrias de celulose, papel e madeira (Campos et al., 2022). Apesar de sua importância, devido à valorização crescente das terras de uso agrícola e à redução das áreas disponíveis, os cultivos de eucalipto têm sido levados a ocupar áreas marginais, muitas das quais são caracterizadas com baixa pluviosidade e solos com pouca capacidade de retenção de água, expondo as plantas a um risco constante de déficit hídrico (Felippe et al., 2020).

O déficit hídrico é a principal causa de mortalidade das plantas jovens após o transplântio (Navroski et al., 2014). A identificação precisa de estresse hídrico é crucial não apenas para determinar o momento apropriado para a irrigação, mas também para permitir a aplicação da água em taxa variada. A identificação precisa do estresse hídrico em plantas individuais, aliada ao uso de geotecnologias, permite criar mapas detalhados de áreas com maior estresse hídrico. Essa estratégia facilita o entendimento de como os atributos do solo afetam o crescimento das plantas e auxilia na gestão eficiente da água, promovendo práticas de cultivo mais sustentáveis e produtivas.

O diagnóstico visual, em tempo real, dos sintomas característicos de deficiência hídrica em plantas sob condições de campo, utilizando máquinas agrícolas equipadas com sistemas avançados de inteligência artificial, pode ser uma ferramenta eficaz. Esta abordagem permite não só uma resposta imediata, mas também uma ação mais precisa e eficiente, maximizando a precisão na detecção de estresse hídrico e, por conseguinte, otimizando o manejo de irrigação. A correta identificação do déficit hídrico de cada planta, no momento da irrigação, permitiria o uso de sistemas mecanizados que aplicassem água em taxas variáveis e em tempo real. Essa abordagem tornaria a irrigação mais eficiente, garantindo que cada planta receba apenas a quantidade de água necessária, evitando tanto o desperdício quanto a subirrigação. Além disso, a aplicação de água sob demanda pode contribuir para a sustentabilidade da produção, reduzindo o consumo hídrico e os custos operacionais, ao mesmo tempo em que melhora o desenvolvimento das mudas e reduz a mortalidade após o transplântio.

Atualmente a prática de cultivo de eucalipto após o transplântio das plantas jovens é realizada de forma morosa e imprecisa, por trabalhadores que percorrem toda a área irrigando as plantas. Neste processo, não é possível identificar o estado de déficit hídrico de cada planta, de modo que é aplicada a mesma quantidade de água para todas as plantas. A correta identificação do déficit hídrico de cada planta, no momento da irrigação, permitiria o uso de sistemas mecanizados que irrigassem em taxas variáveis e em tempo real.

Uma abordagem promissora para identificar plantas sob estresse hídrico é o uso de modelos de detecção de objetos, como o YOLO (*You Only Look Once*). O YOLO é um algoritmo de aprendizado profundo que é capaz de detectar objetos em imagens em tempo real (Garg et al., 2023). Devido à sua capacidade de detecção, o YOLO tem sido aplicado com sucesso na identificação de plantas em várias áreas de pesquisa na agricultura, incluindo contagem e medição da altura de plantas, identificação de plantas infectadas por doenças e identificação dos estágios de crescimento das plantas (Feng et al., 2023; Wu et al., 2023; Yuan et al., 2022).

Além de sua aplicação na detecção e contagem de plantas, o YOLO tem sido empregado com sucesso na fenotipagem de plantas. A fenotipagem abrange a análise de características físicas e morfológicas das plantas, e vários estudos mostraram que o uso do YOLO permite a identificação automatizada e precisa dessas características (Hati & Singh, 2023; Jiang & Li, 2020; Li, 2020). O YOLO é capaz de extrair os dados de tamanho, forma, cor, textura e outras características relevantes das plantas, acelerando o processo de seleção de genótipos com características desejáveis.

Jain et al. (2022), por exemplo, utilizaram o YOLO para identificar, contar e medir características foliares em plantas de *Arabidopsis thaliana*, mostrando assim sua aplicabilidade para estimativa de crescimento em tempo real das plantas. No estudo conduzido por Cardellicchio et al. (2023), o YOLO foi empregado com sucesso na detecção de características fenotípicas de plantas de tomate, como nós, frutos e flores, permitindo uma avaliação mais precisa do impacto do estresse abiótico no desenvolvimento da cultura.

A detecção de estresse hídrico em plantas jovens florestais é um campo de pesquisa em crescimento, e a aplicação de técnicas de visão computacional, como o YOLO, pode ser uma solução promissora. Embora a detecção de estresse hídrico seja uma área importante na agricultura e na gestão de recursos hídricos, a maioria dos estudos de visão computacional, até o momento, tem se concentrado em métodos

tradicionais de monitoramento, como a detecção de frutas (Maceachern et al., 2023; TANG et al., 2023), doenças de plantas (Ganesan et al., 2022; Seth et al., 2023), plantas daninhas (Dang et al., 2022; Wang et al., 2022a) e raízes (Yang et al., 2022).


Diante desse cenário, o presente estudo teve como objetivo desenvolver dois modelos, YOLOv5 e YOLOv8, utilizando técnicas de aprendizagem de máquina, para a detecção de estresse hídrico em plantas jovens de eucalipto, visando encontrar a melhor alternativa para a irrigação em taxa variada e em tempo real, a fim de otimizar o manejo da irrigação localizada durante a fase inicial de implantação dessa cultura.

2 MATERIAL E MÉTODOS

2.1 Área de estudo

Para a realização deste estudo foram utilizadas imagens obtidas da vista superior de plantas jovens de eucalipto coletadas em plantação comercial localizada no município de Selvíria, no Estado do Mato Grosso do Sul (Figura 1). A região é caracterizada por seu clima subtropical úmido, com estações bem definidas e solos predominantemente arenosos.

Figura 1 - Mapa de localização da área de estudo, no município de Selvíria, Mato Grosso do Sul.



Fonte: O autor, (2024).

2.2 Obtenção e processamento dos dados

As imagens das plantas jovens de eucalipto foram obtidas em cinco talhões distintos, na mesma semana do transplântio. Foram coletadas 10.000 imagens, sendo 5.000 registradas sob condições de sol e céu limpo, e 5.000 sob condições nubladas ou com algum tipo de sombra. A captura das imagens foi realizada utilizando uma câmera RGB de 13 megapixels, posicionada a uma altura de um metro e com um ângulo de 90 graus.

A Figura 2 apresenta exemplos das plantas utilizadas no treinamento e validação dos modelos. As imagens da Figura 2a correspondem a mudas sem sintomas visuais de estresse, enquanto as da Figura 2b mostram mudas que exibem sinais típicos de estresse hídrico, como murchamento das folhas, perda de turgidez, coloração mais opaca e, em alguns casos, enrolamento das bordas foliares. No entanto, é importante destacar que algumas doenças do trato radicular, como aquelas causadas por bactérias e fungos do solo, podem gerar sintomas semelhantes ao estresse hídrico, tornando a distinção entre os fatores desencadeantes um desafio. Essa semelhança pode impactar a interpretação dos modelos e exige cuidados adicionais na validação dos resultados em campo.

Figura 2 - Plantas jovens de eucalipto: a) sem sintomas de estresse hídrico; e b) com sintomas de estresse hídrico.



Fonte: O autor, (2024).

Após a coleta das imagens das plantas jovens de eucalipto foi realizada, utilizando o software LabelImg versão 1.4.0 (Labelimg, 2023), a rotulação de cada planta, indicando a condição “sem sintomas” ou “com sintomas” de estresse hídrico. As imagens foram então utilizadas no desenvolvimento dos modelos de detecção de sintomas de estresse hídrico.

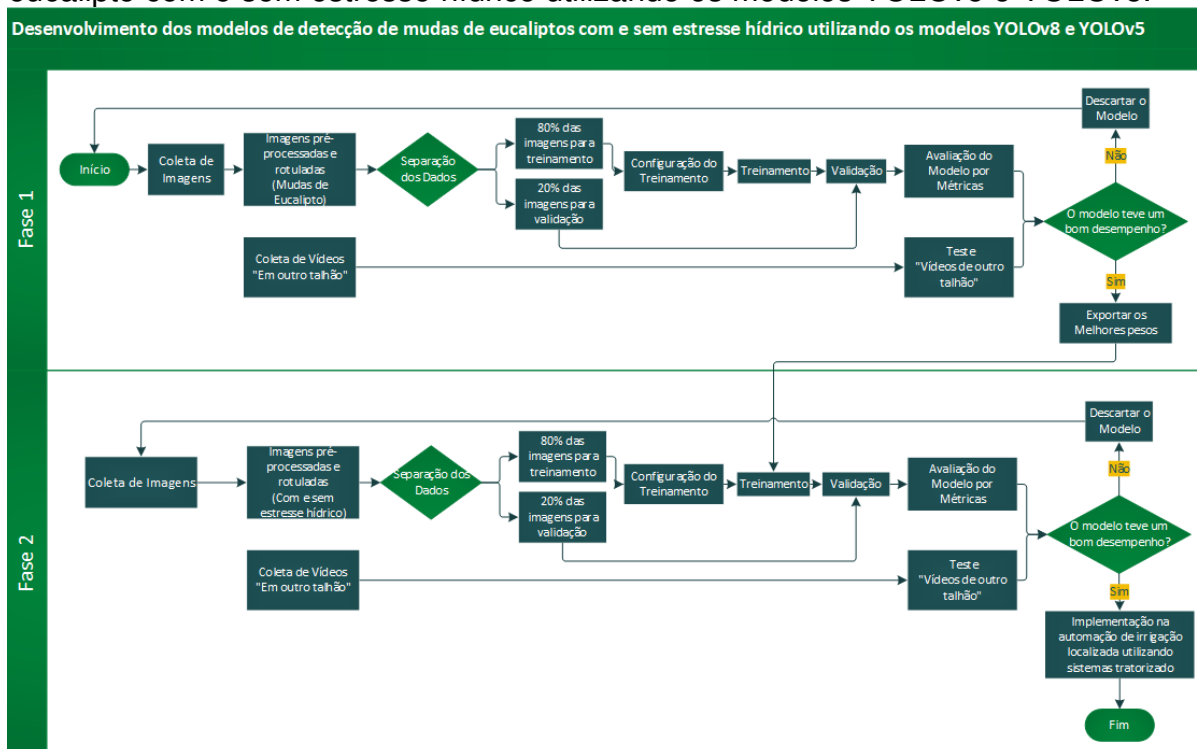
Para avaliar a eficácia dos modelos propostos, simulando sua aplicação em um sistema de irrigação de eucalipto controlado por trator e operando com taxa variável e em tempo real, realizou-se a coleta de vídeos das áreas de plantio. Esses vídeos foram capturados utilizando a mesma câmera empregada para as imagens anteriores.

Posicionada a uma altura de um metro acima do solo, a câmera registrou as imagens enquanto se movia à velocidade equivalente à de um trator em processo de irrigação da área. Para garantir a estabilidade da captura e evitar oscilações manuais, foi utilizado um suporte de celular fixo, permitindo a obtenção de imagens mais consistentes e com menor variação de enquadramento.

2.3 Treinamento dos modelos

A Figura 3 ilustra as etapas empregadas no desenvolvimento dos modelos, divididas em Fase 1 – Desenvolvimento de modelos gerais para detecção de plantas jovens de eucalipto; e Fase 2 – Desenvolvimento de modelos para detecção de plantas jovens de eucalipto com e sem estresse hídrico usando transferência de aprendizagem.

Figura 3 - Etapas do desenvolvimento dos modelos de detecção de plantas jovens de eucalipto com e sem estresse hídrico utilizando os modelos YOLOv5 e YOLOv8.



Fonte: O autor, (2024).

A estruturação do desenvolvimento do modelo em duas fases baseou-se na necessidade de abordar de maneira eficiente e especializada a complexa tarefa de detectar estresse hídrico em plantas jovens de eucalipto, considerando as especificidades do crescimento e das condições ambientais dessas plantas. Esta abordagem é respaldada por estudos na área de agricultura de precisão e ciência de dados aplicados à botânica, os quais destacam a eficácia de utilizar técnicas de transferência de aprendizagem na elaboração de modelos altamente especializados, aprimorando significativamente sua exatidão e capacidade de adaptação às condições específicas em análise (Plata et al., 2021; Sneha et al., 2024; Zhao et al., 2024).

Na primeira fase buscou-se a criação de uma base sólida de reconhecimento das plantas jovens de eucalipto, independentemente de sua condição hídrica. Essa etapa, já concluída e descrita em Santana et al., (2024), foi crucial para assegurar que o modelo tivesse uma alta capacidade de identificação das características fundamentais das plantas, facilitando a generalização para diferentes cenários.

Na Fase 1 foram utilizadas 10.000 imagens de plantas jovens de eucalipto, sendo separadas em dois grupos: 5.000 fotos em condições de sol e céu limpo; e

5.000 sob condições nubladas ou com algum tipo de sombra. As imagens foram separadas aleatoriamente, sendo 80% utilizadas no treinamento e 20% para a validação dos modelos desenvolvidos, garantindo a representatividade das condições de iluminação no conjunto de validação e evitando qualquer viés durante o treinamento.

O treinamento dos modelos personalizados YOLOv5 e YOLOv8 foi realizado no Google Colab Pro +, utilizando uma placa gráfica NVIDIA A100-SXM4-40GB. Os modelos YOLOv5 e YOLOv8 foram ajustados utilizando os hiperparâmetros padrões sugeridos pela Ultralytics (Ultralytics, 2023). Especificamente, os hiperparâmetros configurados incluíram: número de épocas de treinamento, fixado em 600; tamanho da imagem de entrada, definido como 640 pixels; e o tamanho do lote, estabelecido em 16.

As configurações de tamanho da imagem de entrada e tamanho do lote foram escolhidas com base nas recomendações da Ultralytics para otimizar o desempenho dos modelos em tarefas de detecção, permitindo um equilíbrio entre precisão e eficiência computacional. A decisão de fixar o número de épocas em 600 foi baseada na observação de testes anteriores e de melhorias incrementais no desempenho do modelo ao longo do tempo, até que ganhos adicionais se tornassem marginais ou inexistentes, indicando que o modelo atingiu sua capacidade ótima de aprendizado com os dados fornecidos.

Os modelos foram treinados individualmente com pesos iniciais e parciais, usando versões nano (YOLOv5n.pt para YOLOv5 e YOLOv8n.pt para YOLOv8) adequadas para sistemas embarcados devido à sua eficiência computacional. Segundo Wang et al. (2020), estes modelos são ideais para detecção em tempo real em dispositivos com capacidades de processamento limitadas, oferecendo vantagens significativas em eficiência e consumo de recursos.

Após o treinamento dos modelos na Fase 1, conforme descrito no trabalho de Santana et al. (2024), aplicou-se a técnica de *transfer learning* para iniciar a Fase 2. Essa transferência foi realizada através da inicialização do treinamento dos modelos da Fase 2, utilizando os pesos finais obtidos na Fase 1.

Os pesos referem-se aos valores numéricos ajustáveis dentro do modelo que determinam a importância de cada característica de entrada na produção da saída do modelo. Durante o processo de treinamento estes pesos foram ajustados para minimizar o erro entre as previsões do modelo e os resultados reais, permitindo que o

modelo aprendesse a realizar tarefas específicas, como a detecção de objetos em imagens (Narkhede et al., 2022).

Dessa forma, o conhecimento adquirido durante o treinamento da Fase 1 foi transferido e reaproveitado no treinamento dos modelos personalizados da Fase 2. Na segunda fase buscou-se treinar os modelos para a detecção de plantas jovens de eucalipto com e sem estresse hídrico. Nesta etapa foram utilizadas 6.920 imagens (3.460 sem estresse hídrico e 3.460 com estresse hídrico), as quais foram divididas de forma aleatória em 80% para treinamento e 20% para validação.

Durante a Fase 2 foram utilizados os mesmos parâmetros e configurações de treinamento utilizados na Fase 1. Isso incluiu o uso do Google Colab Pro + com a placa gráfica NVIDIA A100-SXM4-40GB, assim como os hiperparâmetros padrões sugeridos pela Ultralytics, consistindo no número de épocas (600), tamanho da imagem de entrada (640 pixels) e tamanho do lote (16), garantindo a consistência metodológica entre as fases do projeto.

2.4 Análise dos modelos

Para avaliar e comparar o desempenho dos modelos treinados foram empregadas as seguintes métricas: precisão (P), *recall* (R), mAP50, mAP50-95, índice de confiança e matriz de confusão (Ultralytics, 2023).

A precisão (P) é definida como a razão de detecções corretas pelo total de detecções efetuadas pelo modelo, tendo sido calculada pela Equação 1:

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

em que:

P = Precisão das detecções, adimensional;

TP = "Verdadeiro positivo", refere-se ao número de instâncias positivas corretamente identificadas pelo modelo, adimensional; e

FP = "Falso positivo", refere-se ao número de instâncias negativas incorretamente classificadas como positivas, adimensional.

O *recall* (R) é definido como a razão de detecções corretas pelo total de amostras pertencentes à classe verdadeira (Equação 2).

$$R = \frac{(TP)}{(TP) + (FN)} \quad (2)$$

em que:

R = Recall das detecções, adimensional; e

FN = "Falso negativo", indicando o número de instâncias positivas incorretamente classificadas como negativas, adimensional.

O mAP50 (*mean Average Precision at 50*) utiliza um limiar de IOU (*Intersection over Union*) de 0,5, considerando uma detecção correta se a intersecção entre as *bounding boxes* prevista e verdadeira for de pelo menos 50%. Já o mAP50-95 exige um limiar de IOU de 0,95, demandando maior precisão na detecção, onde a intersecção deve ser de pelo menos 95% (Ward et al., 2023). Tanto o mAP50, quanto o mAP50-95, são métricas comumente utilizadas para a avaliação de modelos de detecção de objetos (Liu et al., 2024).

O índice de confiança e a velocidade média de inferência são conceitos cruciais no aprendizado de máquina e na detecção de objetos, sendo também empregados na análise dos modelos. No estudo, o índice de confiança foi empregado tanto nas fotos quanto nos vídeos, enquanto a velocidade média de inferência foi utilizada apenas nos vídeos.

O índice de confiança mede a probabilidade de acerto das detecções realizadas pelo modelo, sendo calculado com base na análise das características da imagem e na comparação com o que foi aprendido durante o treinamento. Este índice é expresso em percentual, onde valores mais altos indicam maior certeza do modelo na precisão de sua detecção. Por outro lado, a velocidade média de inferência refere-se ao tempo que o modelo leva para processar e reconhecer objetos em um vídeo ou imagem. Essa métrica é especialmente importante em aplicações que requerem respostas rápidas, como em sistemas de monitoramento em tempo real.

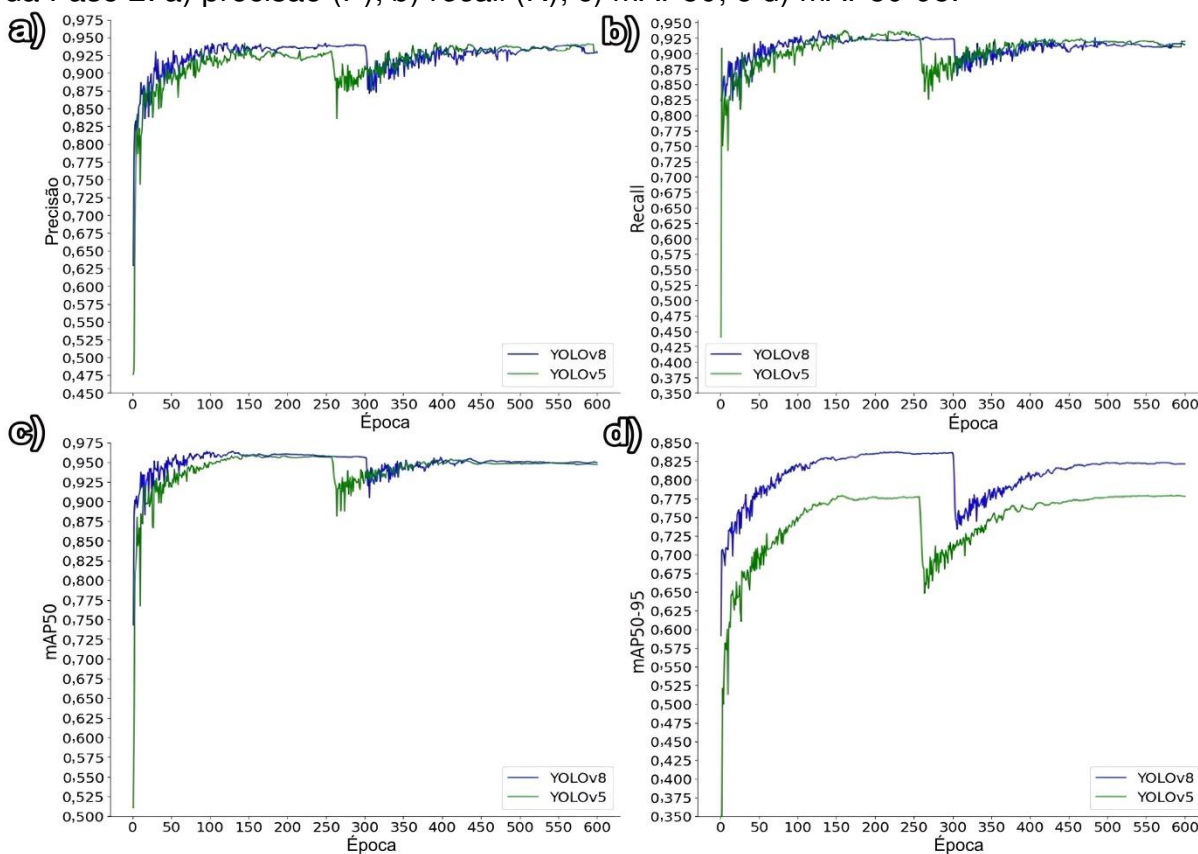
A matriz de confusão foi utilizada como uma métrica de avaliação, proporcionando insights valiosos sobre a precisão e a robustez dos modelos ao diferenciar entre as classes de interesse. A matriz de confusão permite medir a acurácia e as taxas de erro de um modelo no contexto de identificação de objetos em um conjunto de dados (Alruwail et al., 2024).

Os cálculos e as análises de desempenho dos modelos, utilizando as métricas mencionadas, foram realizados no Google Colab Pro +.

3 RESULTADOS E DISCUSSÃO

A Figura 4 apresenta as métricas de Precisão, Recall, mAP-50 e mAP50-95 dos modelos YOLOv5 e YOLOv8 durante o treinamento da Fase 2 para a detecção do estresse hídrico em plantas jovens de eucalipto.

Figura 4 - Métricas de análise dos modelos YOLOv5 e YOLOv8 durante o treinamento da Fase 2: a) precisão (P); b) *recall* (R); c) mAP50; e d) mAP50-95.



Fonte: O autor, (2024).

O decaimento observado na Figura 4 nas métricas de desempenho entre as épocas 250 e 300 foi resultado de uma interrupção no treinamento, exigindo a retomada a partir dos últimos pesos salvos. Interrupções como essa são comuns e podem ser causadas por instabilidade de conexão e limites de uso em plataformas de nuvem, que é uma das limitações do uso do Google Colab (Putra et al., 2024). Após a retomada, houve uma queda temporária no desempenho do modelo, que se ajustou

automaticamente para prosseguir com o aprendizado e alcançar a otimização desejada, conforme também observado nos trabalhos de Fu et al. (2022) e Karakaya et al. (2022).

Ao analisar a Figura 4 foram observadas algumas tendências, como no início do treinamento, em que o YOLOv8 apresentou uma precisão superior ao YOLOv5 (Figura 4a), mas essa vantagem se atenuou com o aumento do número de épocas, alcançando uma estabilidade de desempenho entre 92,6% e 94% após 480 épocas. As precisões obtidas pelos modelos YOLOv5 e YOLOv8 na detecção do estresse hídrico em plantas jovens de eucalipto foram altas, ao se analisar trabalhos correlatos na literatura.

Estudos anteriores demonstram a aplicabilidade do YOLOv5 na detecção de condições fitossanitárias em plantas, o que reforça seu potencial para uso na identificação de estresse em mudas de eucalipto. Por exemplo, Khalid et al. (2023) conseguiram detectar a fitossanidade de plantas em tempo real, com taxas de precisão de 65% para plantas saudáveis e 57% para plantas não saudáveis. Embora essas taxas sejam inferiores às obtidas neste estudo, elas indicam que modelos YOLO podem ser utilizados para identificar padrões visuais relacionados à saúde das plantas. Da mesma forma, Hamidon e Ahamed (2022) aplicaram o YOLOv5 para detectar estresse por queimadura das pontas em alface cultivada em ambiente protegido, alcançando uma precisão de 82,8%. Esse resultado sugere que o YOLOv5 pode ser sensível a diferentes tipos de estresse, o que reforça a viabilidade do seu uso para monitoramento da saúde vegetal em tempo real. Comparado a esses estudos, os modelos treinados neste trabalho apresentaram maior precisão na detecção de sintomas visuais em mudas de eucalipto, o que indica que a abordagem adotada pode oferecer um desempenho superior para aplicações específicas no setor florestal.

Ao analisar a Figura 4b, de *recall* do YOLOv5 e do YOLOv8 durante o treinamento, verifica-se que o YOLOv8 apresentou um *recall* mais alto em comparação ao YOLOv5. Essa diferença, no entanto, diminuiu rapidamente, com ambos os modelos alcançando um *recall* entre 91% e 92% ao final do treinamento. Isso demonstra que, após um período inicial de ajuste, ambos os modelos se tornaram muito eficazes em capturar a maioria das classes de objetos relevantes.

O *recall* é uma métrica que mede a capacidade do modelo em encontrar corretamente todas as instâncias positivas de uma classe (Chicco et al., 2020). No

contexto da detecção de plantas jovens com e sem estresse hídrico, um *recall* alto indica que o modelo é capaz de identificar a maioria das plantas jovens que realmente possuem ou não possuem estresse hídrico, contribuindo para a confiabilidade do modelo e maior capacidade de identificar corretamente diferentes condições de estresse hídrico em plantas jovens.

Essa capacidade de detecção precisa é de extrema importância em aplicações como a irrigação localizada em taxa variada. Ao detectar com precisão as plantas jovens com estresse hídrico, o modelo possibilita a implementação de medidas de manejo adequadas. Isso permite ajustar a taxa de irrigação de forma personalizada para cada planta jovem, garantindo uma utilização otimizada dos recursos hídricos.

No estudo de Niu et al. (2024) foi realizada uma comparação entre os modelos YOLOv5 e YOLOv8 na detecção precoce de estresse hídrico em milho, utilizando imagens capturadas por veículos aéreos não tripulados (UAVs). Os resultados mostraram que o YOLOv8 superou o YOLOv5, alcançando um *recall* de 88,7%. Essa superioridade do YOLOv8 evidencia sua maior eficácia na identificação de sinais precoces de deficiência hídrica em comparação com o modelo anterior.

Em relação à métrica mAP50 (Figura 4c), o YOLOv8 manteve um desempenho superior ao longo do treinamento, com ambos os modelos estabilizando em torno de 95% de desempenho ao final. Isso reflete a alta confiabilidade dos modelos em diferenciar corretamente entre plantas jovens com e sem estresse hídrico sob um critério de sobreposição mínima. Um mAP50 alto é fundamental para garantir a confiabilidade do modelo e sua capacidade de diferenciar corretamente entre plantas jovens com e sem estresse hídrico. Isso é crucial para aplicações práticas, como a tomada de decisões relacionadas ao manejo de um sistema de irrigação automatizado. Um mAP50 de 95% assegura que a maioria das plantas jovens com estresse hídrico será identificada corretamente, permitindo ações de irrigação específicas para essa categoria.

Ao analisar a Figura 4d, da métrica mAP50-95, observa-se que o YOLOv8 apresentou uma superioridade consistente sobre o YOLOv5 durante todo o treinamento, alcançando uma diferença de cinco pontos percentuais entre os modelos ao final. Conforme explicam Kubola et al. (2023), o mAP50-95 é uma medida mais rigorosa e importante porque reflete a capacidade dos modelos em lidar com cenários desafiadores, onde as plantas jovens podem estar próximas umas das outras ou apresentar características visuais semelhantes.

Essa métrica indica que o YOLOv8 é particularmente eficaz em cenários desafiadores, onde é exigida uma precisão elevada na sobreposição entre as caixas delimitadoras previstas e as reais. Ao final do treinamento, o YOLOv8 atinge uma pontuação de 82,5%, enquanto o YOLOv5 alcança 78%.

Um mAP50-95 entre 78% e 82% indica que ambos os modelos obtiveram um desempenho moderado em identificar corretamente as plantas jovens com e sem estresse hídrico, mesmo em situações em que é necessária uma sobreposição significativa (acima de 95%) entre as caixas delimitadoras reais e as previstas pelos modelos. Essas caixas delimitadoras circundam os objetos detectados nas imagens, servindo como referência visual para a localização e o reconhecimento de padrões específicos, como sinais de estresse hídrico, pelos modelos de aprendizado de máquina (Patkar et al., 2024).

No estudo realizado por Chitrangrum et al. (2024), que comparou o desempenho dos modelos YOLOv5 e YOLOv8 na detecção de doenças em folhas de milho, o YOLOv8 exibiu uma precisão média (mAP) no intervalo 50-95 de 0,727 e um mAP50 de 0,965. Em contrapartida, o YOLOv5 registrou uma precisão média (mAP) 50-95 entre 0,425 e 0,617 e um mAP50 que variou de 0,741 a 0,906. Por outro lado, no estudo realizado por Hawaldar et al. (2024), que realizou uma comparação entre YOLOv5 e YOLOv8 na detecção de ferrugem em plantas, o YOLOv5 alcançou uma precisão média (mAP) de 0,716, com um limiar de confiança de 0,5. Por sua vez, o YOLOv8 superou esse resultado, obtendo uma precisão média (mAP) de 0,744, evidenciando um desempenho superior na identificação da ferrugem em plantas. Observa-se que o estudo em questão demonstrou resultados superiores em termos de mAP50 e mAP50-95 em comparação com os trabalhos anteriormente citados, refletindo um avanço significativo na precisão e confiabilidade dos modelos desenvolvidos.

Os resultados positivos apresentados na Figura 4 evidenciam que a transferência de aprendizagem otimizou o uso do conhecimento prévio do modelo da Fase 1, aplicado a um vasto conjunto de imagens de plantas, permitindo aprender e generalizar com precisão os padrões associados ao estresse hídrico das plantas jovens de eucaliptos. Os benefícios da transferência de aprendizagem e o impacto de um grande conjunto de dados de treinamento é um consenso no campo da aprendizagem de máquina e visão computacional. A transferência de aprendizagem é reconhecida por sua capacidade de acelerar o processo de treinamento e melhorar

a generalização dos modelos em tarefas específicas, especialmente quando esses modelos são aplicados a domínios nos quais os dados podem ser escassos ou altamente especializados (Alhussainan et al., 2024; Mccall et al., 2024; Prinzi et al., 2024; Zhang et al., 2024).

Embora não tenhamos conduzido experimentos específicos para medir o impacto isolado da transferência de aprendizagem, a escolha desta técnica foi baseada em evidências amplamente documentadas na literatura sobre sua eficácia em melhorar a capacidade de generalização dos modelos de aprendizado profundo, especialmente em situações complexas, como é o caso da detecção de estresse hídrico em plantas. Esta aplicação envolve a análise de sutis variações visuais nas plantas, que podem ser dificilmente discerníveis sem um robusto conjunto de características aprendidas previamente. A transferência de aprendizagem permite que o modelo utilize conhecimento adquirido em contextos similares para identificar esses padrões delicados, tornando-se particularmente valioso em cenários onde a especificidade e a precisão são críticas para a identificação correta de sinais de estresse hídrico, um desafio notoriamente difícil devido à sua natureza variável e muitas vezes sutil.

Esta abordagem metodológica, conforme discutido por Pacal et al. (2022), é crucial não apenas para aprimorar a precisão dos modelos desenvolvidos, mas também para assegurar a relevância e a aplicabilidade dos aprendizados em contextos práticos. O desempenho satisfatório observado nas métricas de precisão, Recall, mAP50 e mAP50-95 demonstra que ambos os modelos são altamente eficientes em identificar corretamente as plantas, com uma distinção clara entre as que estão sob estresse hídrico e as que não estão.

Na Tabela 1 apresentam-se os números de verdadeiros positivos e falsos negativos, conforme observado na matriz de confusão para as classes “com estresse hídrico” e “sem estresse hídrico”, ao final do treinamento dos modelos YOLOv5 e YOLOv8 para a detecção de plantas jovens de eucalipto.

Tabela 1 - Resultados de verdadeiros positivos e falsos positivos nos modelos YOLOv5 e YOLOv8 na detecção de plantas jovens de eucalipto com e sem estresse hídrico.

Rotulado/Predito	YOLOv5 Predito como Sim (Positivo)	YOLOv8 Predito como Sim (Positivo)
Com Estresse Hídrico Rotulado como Sim (Positivo)	0,93 1287 (verdadeiro positivo)	0,93 1287 (verdadeiro positivo)
Com Estresse Hídrico Rotulado como Não (Negativo)	0,07 97 (falso positivo)	0,07 97 (falso positivo)
Sem Estresse Hídrico Rotulado como Sim (Positivo)	0,91 1259 (verdadeiro positivo)	0,93 1287 (verdadeiro positivo)
Sem Estresse Hídrico Rotulado como Não (Negativo)	0,09 125 (falso positivo)	0,07 97 (falso positivo)

Fonte: O autor, (2024).

Conforme verifica-se na Tabela 1, o YOLOv8 detectou corretamente 93% das plantas jovens com estresse hídrico e 93% das plantas jovens sem estresse hídrico. Já o YOLOv5 detectou corretamente 93% das plantas jovens com estresse hídrico e 91% das plantas jovens sem estresse hídrico. Ambos os modelos têm desempenho muito semelhante quando se trata de identificar corretamente plantas com e sem estresse hídrico, mas nota-se que o YOLOv8 possui valores ligeiramente superiores em relação ao YOLOv5.

Um número elevado de falsos positivos em modelos como o YOLOv5 e YOLOv8 poderia levar a aplicações desnecessárias de água em plantas que não necessitam de tanta irrigação. Embora essa prática possa não prejudicar diretamente as plantas, ela resulta em um maior uso de água, prolongando as operações de irrigação e aumentando os custos financeiros e logísticos associados. Esse aumento no tempo e nos recursos empregados não apenas aumenta os custos operacionais, mas também reduz a eficiência geral do manejo agrícola, destacando a importância de minimizar os falsos positivos para otimizar o uso de recursos hídricos no campo.

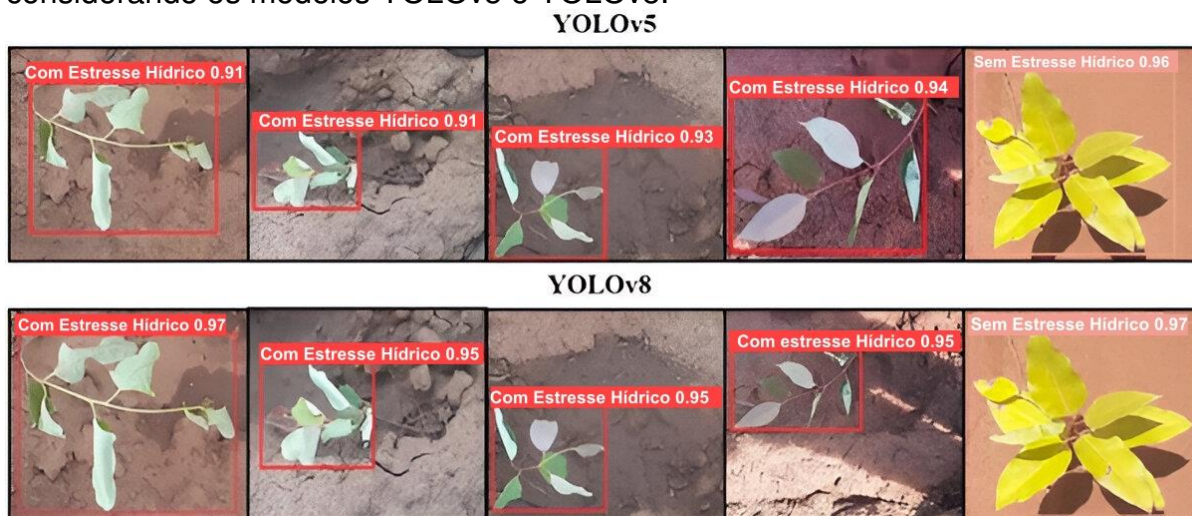
Entretanto, este não é o caso do estudo em questão, pois com taxas de falsos positivos de 0,09 para o YOLOv8 e 0,07 para o YOLOv5, respectivamente, na detecção de plantas sem estresse hídrico, os modelos demonstraram um desempenho satisfatório. Essas taxas indicam uma boa eficiência, minimizando a probabilidade de superirrigação e desperdício de recursos, ao mesmo tempo em que

mantêm a eficácia na identificação correta de plantas necessitadas de maior volume de irrigação.

Cardellicchio et al. (2023) utilizaram a arquitetura YOLOv5 para reconhecimento de tomates e observaram que as taxas de falsos positivos variaram significativamente entre as classes, sendo mais altas para nós e flores. Essas taxas oscilaram entre 0,07 e 0,59, dependendo do modelo e da classe analisada. Especificamente, os modelos mais densos como o YOLOv5l6 e o YOLOv5x6, embora ofereçam melhor precisão geral, enfrentam dificuldades particulares em diferenciar características específicas de nós e flores, resultando em maiores taxas de falsos positivos nessas categorias. O desafio evidenciado por Cardellicchio et al. (2023) na identificação de diferentes estruturas em plantas de tomate, especialmente a dificuldade em distinguir entre nós e flores, reflete uma limitação comum em modelos de detecção baseados em YOLO: a identificação precisa de características sutis dentro de uma mesma classe. Esse problema é análogo ao encontrado na detecção de sintomas de estresse hídrico em plantas jovens de eucalipto, onde pequenas variações na coloração, textura e morfologia das folhas podem levar a falsas detecções ou a dificuldades na diferenciação entre estresse hídrico e sintomas causados por doenças radiculares. Assim, a similaridade entre os desafios de fenotipagem de características e a identificação de condições de estresse hídrico reforça a importância de um treinamento robusto e da consideração de múltiplos fatores visuais para aumentar a confiabilidade dos modelos.

A Figura 5 apresenta os resultados do índice de confiança alcançados pelos modelos YOLOv5 e YOLOv8, quando aplicados ao mesmo conjunto de imagens de validação, para a classificação de plantas jovens de eucalipto com e sem estresse hídrico.

Figura 5 - Comparação do índice de confiança em imagens do conjunto de validação considerando os modelos YOLOv5 e YOLOv8.




Fonte: O autor, (2024).

Os resultados apresentados na Figura 5 mostram que o YOLOv5 obteve um índice de confiança superior a 90% em todas as imagens analisadas, enquanto o YOLOv8 alcançou valores iguais ou superiores a 95% nas classificações dessas mesmas imagens. Valores elevados do índice de confiança são importantes para a escolha de sistemas de classificação, uma vez que este índice mede o quão certo o modelo está sobre suas previsões.

Valores mais altos do índice de confiança indicam maior certeza do modelo na precisão de sua detecção, no entanto, na análise dos modelos é fundamental verificar os menores valores do índice de confiança, a fim de se entender onde os modelos apresentam dificuldades, permitindo identificar padrões específicos de falhas e tendências comuns em cenários de baixa performance. Sendo assim, a Figura 6 apresenta os piores índices de confiança considerando as 1.384 imagens de validação para os dois modelos em análise.

Figura 6 - Piores índices de confiança considerando todas as imagens de validação para os modelos YOLOv5 e YOLOv8.



Fonte: O autor, (2024).

Na Figura 6 observam-se que os menores índices de confiança, variando de 0,39 a 0,73, foram registrados pelo modelo YOLOv5. Estes valores foram especificamente associados a classificações de plantas com sintomas de estresse hídrico. Em contraste, o modelo YOLOv8 demonstrou desempenho superior nas mesmas condições, com índices de confiança entre 0,56 e 0,92. Isso mostra que a classe com estresse hídrico é particularmente desafiadora para detecção, especialmente para o YOLOv5, podendo tal fato ser atribuído à variabilidade nas manifestações visuais do estresse nas plantas, um desafio menos significativo para o YOLOv8.

A redução na confiança observada nessas imagens pode estar relacionada à variabilidade dos sintomas visuais do estresse hídrico, que se manifestam de diferentes formas, como murchamento, alterações sutis na coloração e textura foliar, tornando a identificação mais incerta. Além disso, fatores como iluminação irregular, sombras e variações na aparência das mudas dentro do conjunto de validação podem ter influenciado essa incerteza. Os menores índices de confiança foram registrados em plantas deformadas, com folhas queimadas e retorcidas, resultado de uma aclimação insuficiente na casa de vegetação antes do transplante. A exposição a altas temperaturas e intensa radiação solar agravou o estresse, tornando a detecção mais desafiadora. Nessas condições, o YOLOv5 mostrou-se menos eficaz, reforçando a complexidade da identificação de sintomas em plantas com danos estruturais mais severos. Apesar dessas dificuldades, os modelos mantiveram um desempenho geral

consistente, demonstrando robustez na detecção do estresse hídrico em plantas jovens de eucalipto.

Os resultados obtidos indicam que, embora ambos os modelos tenham conseguido detectar estresse hídrico em plantas jovens de eucalipto, o YOLOv8 demonstrou um índice de confiança superior, na maioria das situações, em comparação ao YOLOv5, nas imagens de validação que não foram previamente expostas durante o treinamento. Isso ressalta a capacidade do YOLOv8 de lidar com variações complexas nas manifestações visuais do estresse, apresentando uma robustez significativa mesmo em cenários não familiarizados. Essa eficácia é crucial para aplicações práticas onde a variabilidade das condições das plantas é frequente.

De acordo com Zhuang et al. (2023) a detecção de plantas usando visão computacional depende de características como cor, textura, forma e padrões das folhas. Conforme observado nas imagens de validação (Figuras 5 e 6), o estresse hídrico nas plantas pode causar mudanças na cor das folhas e em suas características morfológicas, o que pode afetar a precisão da detecção, especialmente ao utilizar o YOLOv5.

Os valores apresentados na Tabela 2 referem-se aos resultados do desempenho das métricas de precisão (P), *recall* (R), mAP50 e mAP50-95 dos modelos de detecção de objetos YOLOv5 e YOLOv8, aplicados às 1.384 imagens de validação para a detecção de plantas jovens de eucalipto com e sem estresse hídrico.

Tabela 2 - Resultados do desempenho das métricas de precisão (P), *recall* (R), mAP50 e mAP50-95 dos modelos de detecção de plantas jovens com e sem estresse hídrico.

YOLOv5				
Classe	precisão	<i>recall</i>	mAP50	mAP50-95
Com Estresse Hídrico	0,925	0,913	0,929	0,713
Sem Estresse Hídrico	0,955	0,907	0,966	0,845
4,2 GFLOPs, 3,31 it/s				
YOLOv8				
Classe	precisão	<i>recall</i>	mAP50	mAP50-95
Com Estresse Hídrico	0,924	0,914	0,943	0,778
Sem Estresse Hídrico	0,944	0,931	0,970	0,885
8,1 GFLOPs, 3,99 it/s				

Fonte: O autor, (2024).

Ao analisar os dados da Tabela 2 é possível observar que para a classe de "com estresse hídrico", o YOLOv8 apresentou uma precisão de 92,4%, *recall* de 91,4%, mAP50 de 94,3% e mAP50-95 de 77,8%. Enquanto isso, o YOLOv5 obteve uma precisão de 92,5%, *recall* de 91,3%, mAP50 de 92,9% e mAP50-95 de 71,3%. Portanto, para a classe "com estresse hídrico" o YOLOv8 teve uma leve vantagem nessas métricas.

No caso da classe "sem estresse hídrico" o YOLOv8 registrou uma precisão de 94,4%, *recall* de 93,1%, mAP50 de 97,0% e mAP50-95 de 88,5%. Por outro lado, o YOLOv5 obteve uma precisão de 95,5%, *recall* de 90,7%, mAP50 de 96,6% e mAP50-95 de 84,5%. Para a classe "sem estresse hídrico" o YOLOv5 teve uma precisão ligeiramente maior, enquanto o YOLOv8 obteve um *recall*, mAP50 e mAP50-95 superiores.

Em geral, os resultados obtidos pelos modelos YOLOv5 e YOLOv8 na detecção de plantas jovens com e sem estresse hídrico têm importância direta no desempenho desses modelos na irrigação a taxas variadas. A capacidade de detecção precisa das plantas jovens afetadas pelo estresse hídrico contribui para uma aplicação mais eficiente da irrigação, resultando em uma utilização otimizada dos recursos hídricos e garantindo um crescimento saudável das plantas jovens.

Ao analisar os dados de taxa de processamento, que mede a velocidade com que os modelos analisam as imagens e é crucial para avaliar a eficiência dos sistemas de detecção em tempo real, observamos que o modelo YOLOv8 teve um desempenho superior ao modelo YOLOv5. Durante a validação, o YOLOv8 obteve uma taxa de processamento de 3,99 it/s (iterações por segundo), enquanto o YOLOv5 alcançou uma taxa de processamento de 3,31 it/s. Isso indica que o YOLOv8 é capaz de processar as imagens de forma mais rápida em comparação ao YOLOv5.











No trabalho de Ragavendran et al., (2024) os autores encontraram taxas variando de 1,88 a 1,97 it/s para detectar os equipamentos de segurança utilizados pelos trabalhadores no canteiro de obras utilizando o modelo YOLOv8, enquanto Kothala et al. (2023), ao desenvolverem modelos YOLOv5 para detectar hemorragia intracraniana (HIC), obtiveram taxas variando de 2,10 a 11,65 it/s. Em ambos os trabalhos, os autores afirmaram que as taxas encontradas foram adequadas para aplicações em tempo real, sublinhando a capacidade dos modelos em processar imagens de maneira rápida o suficiente para fornecer informações vitais em situações

onde o tempo é crucial, seja na prevenção de acidentes de trabalho ou no diagnóstico médico emergencial.

Quando se trata do desenvolvimento de modelos de detecção de plantas em tempo real, a velocidade de processamento é um fator crítico, pois afeta diretamente a capacidade de resposta e eficiência do sistema sob condições de campo. Portanto, em termos de velocidade de processamento, o YOLOv8 possui melhor desempenho, o que permite que o modelo processe um maior número de imagens por segundo, resultando em uma detecção mais rápida e em tempo real das plantas jovens com e sem estresse hídrico.

A Figura 7 apresenta os resultados do índice de confiança das detecções realizadas em cinco vídeos de teste de plantas jovens de eucalipto. O teste consistiu em avaliar os modelos com dados não vistos durante seu treinamento, visando verificar sua performance e a capacidade de generalizar para novas situações.

Figura 7 - Comparação do índice de confiança em vídeos de teste, entre os modelos YOLOv5 e YOLOv8. (AISPf - *Average Inference Speed Per Frame*, ACI - *Average Confidence Index*).

YOLOv5				
				
Sem Estresse Hídrico 0.93	Com Estresse Hídrico 0.93	Com Estresse Hídrico 0.94	Com Estresse Hídrico 0.86	Com Estresse Hídrico 0.94
AISPf: 8.55 ms ACI: 93%	AISPf: 7.94 ms ACI: 93%	AISPf: 8.02 ms ACI: 93%	AISPf: 8.00 ms ACI: 87%	AISPf: 7.60 ms ACI: 90%
YOLOv8				
				
Sem Estresse Hídrico 0.96	Com Estresse Hídrico 0.94	Com Estresse Hídrico 0.95	Com Estresse Hídrico 0.92	Com Estresse Hídrico 0.97
AISPf: 7.27 ms ACI: 96%	AISPf: 7.09 ms ACI: 94%	AISPf: 7.28 ms ACI: 94%	AISPf: 7.00 ms ACI: 91%	AISPf: 7.30 ms ACI: 94%

Fonte: O autor, (2024).

Ao analisar o desempenho dos modelos YOLOv5 e YOLOv8 na detecção de plantas jovens de eucalipto nos vídeos de teste (Figura 7), podemos observar que ambos os modelos obtiveram resultados promissores. O índice de confiança médio (ACI) representa a média dos índices de confiança calculados para todas as plantas detectadas em cada quadro dos vídeos de teste analisados.

O YOLOv5 alcançou um índice de confiança médio de 93% em três dos cinco vídeos analisados. Nos outros dois vídeos, as plantas foram classificadas com índices de confiança médios de 90% e 87%, respectivamente. Por sua vez, o YOLOv8 registrou um índice de confiança médio de 94% em três dos cinco vídeos analisados. Nos dois vídeos restantes, os índices de confiança médios foram de 96% e 91%, respectivamente.

Comparando os resultados do ACI, observamos que o modelo YOLOv8 teve um desempenho ligeiramente superior, obtendo pontuações médias de confiança mais altas em uma maior quantidade de vídeos. Ambos os modelos apresentaram altas pontuações de confiança, o que indica uma capacidade confiável de identificar corretamente as plantas jovens de eucalipto com e sem sintomas de estresse hídrico nos vídeos de teste obtidos.

Logo, através da análise de imagens capturadas em tempo real por sistemas de monitoramento instalados em máquinas agrícolas, os modelos YOLOv5 e YOLOv8 poderão identificar com precisão as plantas jovens que apresentam sintomas de estresse hídrico. Isso possibilita a geração de informações valiosas e imediatas, fundamentais para a tomada de decisões assertivas em relação à necessidade, intensidade e frequência de irrigação mecanizada. Esse processo é crucial para garantir o desenvolvimento saudável das plantas, otimizando o uso de recursos hídricos na agricultura e trazendo um retorno econômico substancial ao diminuir os custos operacionais com mão de obra e maquinário, aumentando a eficiência agrícola.

Ao analisar a Figura 7 e comparar as velocidades médias de inferência por quadro dos modelos YOLOv5 e YOLOv8 nos vídeos, podemos observar que o YOLOv5 apresentou tempos médios de 8,55 ms, 7,94 ms, 8,02 ms, 8,00 ms e 7,60 ms nos cinco vídeos. Já o YOLOv8 obteve tempos médios de 7,27 ms, 7,09 ms, 7,28 ms, 7,00 ms e 7,30 ms nos mesmos vídeos. Com base nesses dados, nota-se que o YOLOv8 teve um desempenho melhor em termos de velocidade média de inferência por quadro, apresentando tempos médios menores em todos os vídeos em comparação com o YOLOv5. A consistência observada nos tempos médios de inferência por quadro entre os vídeos de teste sugere uma tendência de superioridade do YOLOv8 em termos de velocidade, independentemente do contexto específico de cada vídeo.

A velocidade de inferência do modelo desempenha um papel crucial em sistemas embarcados de máquinas agrícolas, onde é necessário tomar decisões

rápidas com base nas detecções realizadas. Por exemplo, ao detectar plantas jovens com estresse hídrico em tempo real, uma maior velocidade de inferência permite tomar ações imediatas de ajuste da irrigação durante o deslocamento da máquina sob as linhas de plantio. Isso possibilita ampliar a velocidade de deslocamento e otimizar a capacidade operacional de trabalho.

De modo geral, os resultados deste estudo sugerem que os modelos YOLOv5 e YOLOv8 têm potencial para processarem dados e identificar plantas jovens de eucalipto sob estresse hídrico, o que poderia facilitar uma resposta automatizada em sistemas de irrigação tratorizados se aplicados em tempo real.

Quando integrado ao sistema de geoposicionamento da máquina, o modelo não apenas detectaria as plantas jovens, mas também poderia registrar suas coordenadas geográficas. Isso permitiria a criação de um mapa detalhado da área, evidenciando a distribuição espacial das plantas com e sem estresse hídrico no talhão. Embora a aplicação de água em tempo real seja o principal benefício do sistema, o mapeamento possibilitaria a identificação de padrões recorrentes, como áreas onde as mudas apresentam sintomas frequentes de estresse hídrico.

Essas informações podem estar relacionadas a características do solo, como variações na retenção de umidade, compactação ou drenagem deficiente. Com isso, seria possível adotar manejos diferenciados nessas regiões, como ajustes na frequência e volume de irrigação, uso de coberturas vegetais ou até mesmo correções no solo para melhorar sua capacidade de retenção de água. Dessa forma, o mapeamento contribuiria para um planejamento agrícola mais preciso, otimizando o uso dos recursos hídricos e reduzindo perdas na produtividade.

Ao ajustar a irrigação de acordo com as necessidades específicas de cada planta jovem de eucalipto, os modelos não apenas resolvem o problema da alta taxa de mortalidade das plantas jovens após o transplante devido ao estresse hídrico, mas também otimizam a eficiência operacional da irrigação, reduzindo a necessidade de mão de obra, os custos associados a irrigações frequentes e o desgaste de equipamentos.

Sendo assim, a adoção de modelos para a detecção de estresse hídrico em plantas jovens de eucalipto visando a irrigação em taxa variada e em tempo real oferece uma maneira mais sustentável e eficiente de gerenciar os recursos na silvicultura de eucalipto, resultando em economia de combustível, menor impacto ambiental e aumento da produtividade.

4 CONCLUSÃO

- Os modelos YOLOv5 e YOLOv8 obtiveram altas pontuações de confiança na identificação de plantas jovens com e sem estresse hídrico em fotos e vídeos, demonstrando eficácia na detecção.
- O modelo YOLOv8, no geral, superou o YOLOv5 em métricas de desempenho, mostrando-se ligeiramente mais eficiente na identificação de plantas jovens de eucalipto sob estresse hídrico.
- Além de maior precisão, o YOLOv8 também se destacou na velocidade de inferência por quadro, evidenciando uma capacidade de processamento mais ágil, essencial para a implementação de sistemas de irrigação inteligentes.
- Os modelos YOLOv5 e YOLOv8 têm um alto potencial como ferramentas para a automação da irrigação localizada de plantas jovens de eucalipto em condições de campo, permitindo controlar a aplicação de água em taxa variada e em tempo real.

REFERÊNCIAS

- ALHUSSAINAN, N. F.; BEN YOUSSEF, B.; & BEN ISMAIL, M. M. A Deep Learning Approach for Brain Tumor Firmness Detection Based on Five Different YOLO Versions: YOLOv3–YOLOv7. **Computation**, v. 12, n. 3, p. 44, 2024.
- ALRUWAILI, M.; ATTA, M. N.; SIDDIQI, M. H.; KHAN, A.; KHAN, A.; ALHWAITI, Y.; & ALANAZI, S. Deep Learning-Based YOLO Models for the Detection of People With Disabilities. **IEEE Access**, v. 12, pp. 2543-2566, 2024.
- CAMPOS, A.; LIENARD, R. B. D.; MOURA, G. M.; DE OLIVEIRA, B. A.; DA SILVA, L. L.; DE MOURA, J. N. M.; & TRAZZI, P. A. Cultivo de eucalipto no Brasil e no mundo: avaliações bibliométricas. In: **9º Congresso Florestal Brasileiro**. p. 321-324. 2022. <https://doi.org/10.55592/CFB.2022.3113801>
- CARDELLICCHIO, A.; SOLIMANI, F.; DIMAURO, G.; PETROZZA, A.; SUMMERER, S.; CELLINI, F.; & RENÒ, V. Detection of tomato plant phenotyping traits using YOLOv5-based single stage detectors. **Computers and Electronics in Agriculture**, v. 207, p. 107757, 2023.
- CHICCO, D.; & JURMAN, G. The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. **BMC genomics**, v. 21, p. 1-13, 2020.
- CHITRANINGRUM, N.; BANOWATI, L.; HERDIANA, D.; MULYATI, B.; SAKTI, I.; FUDHOLI, A.; ... & ANDRIA, A. Comparison Study of Corn Leaf Disease Detection based on Deep Learning YOLO-v5 and YOLO-v8. **Journal of Engineering and Technological Sciences**, v. 56, n. 1, p. 61-70, 2024.
- DANG, F.; CHEN, D.; LU, Y.; LI, Z.; & ZHENG, Y. DeepCottonWeeds (DCW): a novel benchmark of YOLO object detectors for weed detection in cotton production systems. In: **2022 ASABE Annual International Meeting**. American Society of Agricultural and Biological Engineers, p. 1, 2022.
- FELIPPE, D.; NAVROSKI, M. C.; AGUIAR, N. S. D.; PEREIRA, M. D. O.; MORAES, C.; & AMARAL, M. Crescimento, sobrevivência e trocas gasosas de mudas de *Eucalyptus dunnii* Maiden submetidas a regimes de irrigação e aplicação de hidrogel. **Revista Forestal Mesoamericana Kurú**, v. 17, n. 40, p. 11-20, 2020.
- FENG, Y.; CHEN, W.; MA, Y.; ZHANG, Z.; GAO, P.; & LV, X. Cotton Seedling Detection and Counting Based on UAV Multispectral Images and Deep Learning Methods. **Remote Sensing**, v. 15, n. 10, p. 2680, 2023.
- FU, L.; YANG, Z.; WU, F.; ZOU, X.; LIN, J.; CAO, Y.; & DUAN, J. YOLO-Banana: A lightweight neural network for rapid detection of banana bunches and stalks in the natural environment. **Agronomy**, v. 12, n. 2, p. 391, 2022.
- GANESAN, G.; & CHINNAPPAN, J. Hybridization of ResNet with YOLO classifier for automated paddy leaf disease recognition: An optimized model. **Journal of Field Robotics**, v. 39, n. 7, p. 1085-1109, 2022.

GARG, G.; TIWARI, S.; SHIVANI, S.; & MALHI, A. Survey on Vehicle Detection, Identification and Count using CNN-based YOLO Architecture and Related Applications. In: **Advancement of Deep Learning and its Applications in Object Detection and Recognition**. River Publishers, p. 197-210, 2023.

HAMIDON, M. H.; & AHAMED, T. Detection of tip-burn stress on lettuce grown in an indoor environment using deep learning algorithms. **Sensors**, v. 22, n. 19, p. 7251, 2022.

HATI, A. J., & SINGH, R. R. AI-driven pheno-parenting: a deep learning based plant phenotyping trait analysis model on a novel soilless farming dataset. **IEEE Access**, v. 11, p. 35298-35314, 2023.

HAWALDAR, V.; JAIN, R.; MENGDE, M.; & AGRAWAL, S. Revolutionizing Plant Disease Detection in Agriculture: a Comparative Study of Yolov5 and Yolov8 Deep Learning Models, **Research Square**, 04 March 2024, PREPRINT (Version 1). 2024.

IBÁ - INSTITUTO BRASILEIRO DE ÁRVORES. **Relatório Anual 2023**. 2023. Disponível em <https://iba.org/datafiles/publicacoes/relatorios/relatorio-anual-iba2023-r.pdf>. Acesso em: 8 mar. 2023.

JAIN, S.; MAHAPATRA, D.; & SAINI, M. Real-Time Image Based Plant Phenotyping Using Tiny-YOLOv4. In: **International Conference on Intelligent Human Computer Interaction**. Cham: Springer Nature Switzerland, p. 271-283, 2022.

JIANG, Y.; LI, C. Convolutional neural networks for image-based high-throughput plant phenotyping: a review. **Plant Phenomics**, 9 Apr 2020, v. 2020. 2020.

KARAKAYA, M.; CELEBI, M. F.; GÖK, A. E.; & ERSOY, S. Discovery of agricultural diseases by deep learning and object detection. **Environmental Engineering & Management Journal (EEMJ)**, v. 21, n. 1, 2022.

KHALID, M.; SARFRAZ, M. S.; IQBAL, U.; AFTAB, M. U.; NIEDBAŁA, G.; & RAUF, H. T. Real-time plant health detection using deep convolutional neural networks. **Agriculture**, v. 13, n. 2, p. 510, 2023.

KOTHALA, L. P.; JONNALA, P.; & GUNTUR, S. R. Localization of mixed intracranial hemorrhages by using a ghost convolution-based YOLO network. **Biomedical Signal Processing and Control**, v. 80, p. 104378, 2023.

KUBOLA, K.; KONGON, B.; BOONMEE, P.; & JITNGERNMADAN, P. (2023, November). Optimal AI Model for Industrial AR Application based on Object Detection. In: **2023 7th International Conference on Information Technology (InCIT)**. IEEE, p. 38-42, 2023.

LABELIMG. 2023. **heartexlabs/labellmg-GitHub**. <https://github.com/tzutalin/labellmg>

LI, Z.; GUO, R.; LI, M.; CHEN, Y.; & LI, G. A review of computer vision technologies for plant phenotyping. **Computers and Electronics in Agriculture**, v. 176, p. 105672, 2020.

LIU, R.; HUANG, M.; WANG, L.; BI, C.; & TAO, Y. PDT-YOLO: A Roadside Object-Detection Algorithm for Multiscale and Occluded Targets. **Sensors**, v. 24, n. 7, p. 2302, 2024.

MACEACHERN, C. B.; ESAU, T. J.; SCHUMANN, A. W.; HENNESSY, P. J.; & ZAMAN, Q. U. Detection of fruit maturity stage and yield estimation in wild blueberry using deep learning convolutional neural networks. **Smart Agricultural Technology**, v. 3, p. 100099, 2023.

MCCALL, S.; KOLAWOLE, S. S.; NAZ, A., GONG, L.; AHMED, S. W.; PRASAD, P. S.; ... & ARDAKANI, S. P. Computer Vision Based Transfer Learning-Aided Transformer Model for Fall Detection and Prediction. **IEEE Access**, v. 12, p. 28798-28809, 2024.

MONTALBO, F. J. P. (A computer-aided diagnosis of brain tumors using a fine-tuned YOLO-based model with transfer learning. **KSII Transactions on Internet and Information Systems (TIIS)**, v. 14, n. 12, p. 4816-4834, 2020.

NARKHEDE, V. M.; BARTAKKE, P. P.; SUTAONE, S. M. A review on weight initialization strategies for neural networks. **Artificial intelligence review**, v. 55, n. 1, p. 291-322, 2022.

NAVROSKI, M. C.; ARAUJO, M. M.; SILVA CUNHA, F.; BERGHETTI, A. L. P.; DE OLIVEIRA P. M., Influência do polímero hidroretentor na sobrevivência de mudas de *Eucalyptus dunnii* sob diferentes manejos hídricos. **Nativa**, v. 2, n. 2, p. 108-113, 2014.

NIU, S.; NIE, Z.; LI, G., & ZHU, W. Early Drought Detection in Maize Using UAV Images and YOLOv8+. **Drones**, v. 8, n. 5, p. 170, 2024.

PACAL, I.; KARAMAN, A.; KARABOGA, D.; AKAY, B.; BASTURK, A.; NALBANTOGLU, U.; & COSKUN, S. An efficient real-time colonic polyp detection with YOLO algorithms trained by using negative samples and large datasets. **Computers in biology and medicine**, v. 141, p. 105031, 2022.

PATKAR, U. C.; SHRIVES, S. B.; PATIL, U. S.; PATANKAR, A. J.; JAIN, N.; KUMARI, M.; & CHANDHOKE, A. Object Detection using Machine Learning and Deep Learning. **International Journal of Intelligent Systems and Applications in Engineering**, v. 12, n. 1s, p. 466-473, 2024.

PLATA, I. T.; PANGANIBAN, E. B.; ALADO, D. B.; TARACATAC, A. C.; BARTOLOME, B. B.; & LABUANAN, F. R. E. A Recognition Method for Cassava Phytoplasma Disease (CPD) Real-Time Detection based on Transfer Learning Neural Networks. **International Journal of Advanced Computer Science and Applications**, v. 12, n. 12, 2021.

PRINZI, F.; INSALACO, M.; ORLANDO, A.; GAGLIO, S.; & VITABILE, S. A YOLO-based model for breast cancer detection in mammograms. **Cognitive Computation**, v. 16, n. 1, p. 107-120, 2024.

PUTRA, R. H.; ASTUTI, E. R.; PUTRI, D. K.; WIDIASRI, M.; LAKSANTI, P. A. M.; MAJIDAH, H.; & YODA, N. Automated permanent tooth detection and numbering on panoramic radiograph using a deep learning approach. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, v. 137, n. 5, p. 537-544, 2024.

RAGAVENDRAN L.T; UPADHYAY, B.; & SANKRITYAYAN, A. YOLO V8: An improved real-time detection of safety equipment in different lighting scenarios on construction sites, 02 April 2024, PREPRINT (Version 1) available at **Research Square**.2024. <https://doi.org/10.21203/rs.3.rs-4179998/v1>

SANTANA, J.S.; VALENTE, D.S.M.; QUEIROZ, D.M.; COELHO, A.L.F.; BARBOSA, I.A.; MOMIN, A. Automated Detection of Young Eucalyptus Plants for Optimized Irrigation Management in Forest Plantations. **AgriEngineering**, v.6, n. 4, p.3752, 2024. <https://doi.org/10.3390/agriengineering6040214>

SETH, V.; PAULUS, R.; & KUMAR, A. Tomato leaf diseases detection using deep learning—a review. **Intelligent Systems and Smart Infrastructure**, p. 118-131, 2023.

SNEHA, N.; SUNDARAM, M.; & RANJAN, R. Acre-Scale Grape Bunch Detection and Predict Grape Harvest Using YOLO Deep Learning Network. **SN Computer Science**, v. 5, n. 2, p. 250, 2024.

TANG, Y.; ZHOU, H.; WANG, H.; & ZHANG, Y. Fruit detection and positioning technology for a Camellia oleifera C. Abel orchard based on improved YOLOv4-tiny model and binocular stereo vision. **Expert systems with applications**, v. 211, p. 118573, 2023.

WANG, L.; YE, X.; XING, H.; WANG, Z.; & LI, P. Yolo nano underwater: A fast and compact object detector for embedded device. In: **Global Oceans 2020: Singapore-US Gulf Coast**. IEEE, p. 1-4, 2020.

WANG, Q.; CHENG, M.; HUANG, S.; CAI, Z.; ZHANG, J.; & YUAN, H. A deep learning approach incorporating YOLO v5 and attention mechanisms for field real-time detection of the invasive weed Solanum rostratum Dunal seedlings. **Computers and Electronics in Agriculture**, v. 199, p. 107194, 2022a.

WANG, Z.; JIN, L.; WANG, S.; & XU, H. Apple stem/calyx real-time recognition using YOLO-v5 algorithm for fruit automatic loading system. **Postharvest Biology and Technology**, v. 185, p. 111808, 2022.

WARD, T.; RASHAD, S.; & ELGAZZAR, H. Machine Learning Based Pedestrian Detection and Tracking for Autonomous Vehicles. In: **2023 IEEE 13th Annual Computing and Communication Workshop and Conference (CCWC)**. IEEE, p. 1294-1299, 2023.

WU, K.; ZHANG, J.; YIN, X.; WEN, S.; & LAN, Y. An improved YOLO model for detecting trees suffering from pine wilt disease at different stages of infection. **Remote Sensing Letters**, v. 14, n. 2, p. 114-123, 2023.

YANG, K.; PENG, B.; GU, F.; ZHANG, Y.; WANG, S.; YU, Z.; & HU, Z. Convolutional neural network for object detection in garlic root cutting equipment. **Foods**, v. 11, n. 15, p. 2197, 2022.

ULTRALYTICS. **Ultralytics YOLOv8 Docs**. 2023. accessed 10 may 2023, <<https://ultralytics.com>>.

ULTRALYTICS. **Ultralytics**. 2023a. accessed 5 jun 2023, <<https://docs.ultralytics.com/reference/yolo/utils/metrics>>.

YUAN, X.; LI, D.; SUN, P.; WANG, G.; & MA, Y. Real-Time Counting and Height Measurement of Nursery Seedlings Based on Ghostnet–YoloV4 Network and Binocular Vision Technology. **Forests**, v. 13, n. 9, p. 1459, 2022.

ZHANG, Z.; LU, Y.; YANG, M.; WANG, G.; ZHAO, Y.; & HU, Y. Optimal training strategy for high-performance detection model of multi-cultivar tea shoots based on deep learning methods. **Scientia Horticulturae**, v. 328, p. 112949, 2024.

ZHAO, H.; TANG, Z.; LI, Z.; DONG, Y.; SI, Y.; LU, M.; & PANOUTSOS, G. Real-time object detection and robotic manipulation for agriculture using a YOLO-based learning approach. **arXiv preprint arXiv:2401.15785**, 2024.

ZHUANG, J.; JIN, X.; CHEN, Y.; MENG, W.; WANG, Y.; YU, J.; & MUTHUKUMAR, B. Drought stress impact on the performance of deep convolutional neural networks for weed detection in Bahiagrass. **Grass and Forage Science**, v. 78, n. 1, p. 214-223, 2023.

CAPÍTULO 3: SISTEMA PARA DETECÇÃO DE PLANTAS JOVENS DE EUCALIPTO UTILIZANDO YOLOV5

RESUMO

O déficit hídrico é um dos principais desafios nos florestamentos comerciais, tornando a irrigação essencial para o crescimento de plantas jovens de eucalipto após o transplante. Este trabalho teve por objetivo desenvolver e avaliar um sistema de detecção em tempo real de plantas jovens de eucalipto, utilizando o modelo YOLOv5, a fim auxiliar no processo de irrigação automática dessa cultura. Foram capturadas 13.750 imagens utilizando uma câmera RGB de 13 megapixels, posicionada a 1,0 metro sobre a linha de plantio. Após o rótulo das imagens, o modelo foi treinado com 80% das imagens e validado com os 20% restantes, utilizando o YOLOv5 implementado em *Python 3.11* e processado no Google Colab Pro+. O modelo desenvolvido foi implementado em uma NVIDIA Jetson Nano, que foi instalada em uma plataforma robótica remotamente pilotada para a detecção em tempo real das plantas jovens de eucalipto. Os testes de detecção em tempo real indicaram uma precisão de 91%, *recall* de 100% e *F1-Score* de 0,95, com velocidade média de inferência de 46,49 milissegundos e taxa de captura média de 2,73 FPS. Os resultados sugerem que o modelo é promissor para a detecção em tempo real de plantas jovens de eucalipto, diminuindo custos e permitindo a gestão eficiente do manejo de irrigação.

Palavras-chave: detecção em tempo real; Irrigação; plataforma robótica.

ABSTRACT

Water deficit is one of the main challenges in commercial forestry, making irrigation essential for the growth of young eucalyptus plants after transplantation. This study aimed to develop and evaluate a real-time detection system for young eucalyptus plants using the YOLOv5 model to assist in the automatic irrigation process of this crop. A total of 13,750 images were captured using a 13-megapixel RGB camera positioned 1.0 meter above the planting line. After labeling the images, the model was trained with 80% of the images and validated with the remaining 20%, using YOLOv5 implemented in Python 3.11 and processed on Google Colab Pro+. The developed model was implemented on an NVIDIA Jetson Nano, which was installed on a remotely piloted robotic platform for real-time detection of young eucalyptus plants. Real-time detection tests indicated a Precision of 91%, Recall of 100%, and an F1-Score of 0.95, with an average inference speed of 46.49 milliseconds and an average capture rate of 2.73 FPS. The results suggest that the model is promising for real-time detection of young eucalyptus plants, reducing costs and enabling efficient irrigation management.

Keywords: real-time detection; irrigation; robotic platform.

1 INTRODUÇÃO

Os florestamentos comerciais com espécies do gênero *Eucalyptus* são economicamente importantes para o Brasil, destacando-se como uma das principais fontes de matéria-prima para as indústrias de celulose, papel e madeira (Dornelles et al., 2021; Santos et al., 2022). Este setor não só apresenta importância econômica para o país, mas também desempenha papel crucial na sustentabilidade ambiental por meio do sequestro de carbono e recuperação de áreas degradadas (Araújo et al., 2023). O manejo adequado das plantações de eucalipto, no entanto, enfrenta desafios significativos, como a irrigação, a adubação e a aplicação de produtos químicos (Oliveira et al., 2021). Plantas jovens de eucalipto, recém-transplantadas, são especialmente vulneráveis à ausência ou ineficiência de irrigação, o que pode levar a altas taxas de mortalidade e comprometimento do rendimento florestal (García et al., 2024).

A mecanização e a automação no manejo das plantações de eucalipto permitem otimizar as operações de irrigação, reduzindo a dependência de mão de obra e aumentando a precisão e eficiência dos cuidados culturais (Ramantswana et al., 2020). A detecção precisa e automática das plantas jovens sob condições de campo é essencial para garantir o sucesso das operações de manejo das plantações, pois permite o uso de sistemas mecanizados e/ou automatizados (Zhang et al., 2024). Com uma identificação precisa das plantas, é possível otimizar os manejos da cultura, como a irrigação, a adubação e o controle de pragas, melhorando o crescimento e a saúde das plantas (Talaviya et al., 2020; Thorat et al., 2023).

Sistemas embarcados automáticos, com base em inteligência artificial, podem trabalhar ininterruptamente por horas, com menor custo e elevada capacidade operacional (Abaimov et al., 2020). Tecnologias, como a visão computacional, têm-se tornado uma aliada para os setores agrícola e florestal, emergindo como uma ferramenta promissora para o monitoramento e gestão das plantações (Sharma et al., 2023). Embora a visão computacional seja uma tecnologia promissora para o monitoramento e gestão das plantações, sua aplicação prática requer sistemas com características especiais de processamento. Modelos de inteligência artificial, como os utilizados para a detecção de mudas, necessitam de hardware com alta capacidade de processamento, como GPUs otimizadas para CUDA Cores, além de outras

otimizações específicas para acelerar a inferência em tempo real (Lizano & Westerlund, 2024).

A NVIDIA Jetson Nano, um computador de placa única de baixo custo, oferece potencial para aplicações em visão computacional devido a sua capacidade de processamento paralelo e baixo consumo de energia (Valladares et al., 2021). Esta plataforma possibilita a implementação de algoritmos complexos de aprendizado de máquina e visão computacional, facilitando a análise em tempo real e a tomada de decisões instantâneas no campo (Kurniawan & Kurniawan 2021), a partir, por exemplo, da detecção de plantas jovens de eucalipto.

Entre os diversos algoritmos de detecção de objetos, o YOLOv5 (You Only Look Once) tem se destacado pela sua precisão e eficiência (Jocher et al., 2021). Desenvolvido para realizar detecções em tempo real, o YOLOv5 consegue identificar e classificar objetos em imagens de forma rápida, tornando-o ideal para aplicações que exigem respostas imediatas, como a detecção de plantas sob condições de campo (Cardellicchio et al., 2023). A arquitetura do YOLOv5 permite o processamento de grandes volumes de dados com precisão, o que é fundamental para o monitoramento contínuo e eficiente das plantações (Lu et al., 2024).

A integração do YOLOv5 com plataformas de computação embarcada, como a Jetson Nano, abre um leque de possibilidades para a automação agrícola (Sassu et al., 2023). Plataformas robóticas, equipadas com sensores e algoritmos avançados, são capazes de se deslocar automaticamente pelo campo, capturando imagens e dados em tempo real (Prajapati, et al., 2023). A combinação dessas tecnologias permite o desenvolvimento de sistemas robustos e autônomos para a detecção de sintomas de estresse hídrico, otimização da irrigação e monitoramento geral das condições das plantações (Wakchaure et al., 2023).

O uso do YOLOv5 na detecção de plantas e outros objetos em cenários agrícolas não é apenas uma inovação tecnológica, mas também uma ferramenta crucial para a sustentabilidade e o aumento da eficiência das operações agrícolas (Maideen & Mohanarathinam, 2023). Sua capacidade de realizar detecções precisas em diversas condições de iluminação e ambientes, combinada com a robustez da Jetson Nano, oferece um caminho promissor para a implementação de sistemas inteligentes de monitoramento agrícola (Nnadozie et al., 2023). Além disso, o uso de plataformas robóticas com navegação autônoma possibilita a realização de tarefas

repetitivas e trabalhosas, como a inspeção de grandes áreas de cultivo, de maneira mais eficiente e com menor intervenção humana (Visentin et al., 2023).

Tendo em vista a dificuldade e os custos do manejo de irrigação em plantas jovens de eucalipto, este estudo busca abordar desafios específicos relacionados à detecção dessas plantas sob condições de campo em tempo real. A identificação precisa das mudas é fundamental para a automação da irrigação, mas a variabilidade do ambiente impõe obstáculos que tornam essa tarefa complexa. Um dos principais desafios está na variação das condições ambientais, como mudanças na iluminação ao longo do dia e a presença de sombras projetadas por árvores, nuvens e pelo próprio equipamento, que podem comprometer a visibilidade das mudas nas imagens capturadas. Além disso, o fundo das imagens capturadas em campo apresenta alta complexidade, pois o solo pode conter resíduos vegetais, pedras, folhas caídas e outras plantas, tornando a diferenciação entre a muda de eucalipto e os demais elementos do ambiente mais difícil. Diante desses desafios, este estudo teve como objetivo desenvolver e avaliar um modelo de detecção em tempo real de plantas jovens de eucalipto, utilizando o YOLOv5 implementado na NVIDIA Jetson Nano. A proposta visa aprimorar a identificação das mudas, garantindo maior eficiência na automação da irrigação e contribuindo para a otimização dos recursos hídricos no setor florestal.


2 MATERIAL E MÉTODOS

A fim de desenvolver e avaliar um modelo de detecção em tempo real de plantas jovens de eucalipto, o estudo foi dividido em duas etapas. Na primeira, foram desenvolvidas e validadas redes do tipo YOLOv5, enquanto na segunda foram conduzidos ensaios em campo para a avaliação do modelo.

2.1 Área de estudo

No desenvolvimento do modelo, foram utilizadas imagens obtidas a partir de vistas superiores de plantas jovens de eucalipto. Essas imagens foram coletadas em duas plantações comerciais (Figura 1): uma situada no município de Selvíria, no Estado do Mato Grosso do Sul, que será denominada de Área 1 e outra localizada em Guaraciaba, no Estado de Minas Gerais, que será denominada Área 2.

Figura 1 - Mapa de localização das áreas de estudo: 1) Área 1, município de Selvíria, Mato Grosso do Sul; e 2) Área 2, município de Guaraciaba, Minas Gerais.



Fonte: O autor, (2024).


A segunda etapa do estudo envolveu a simulação em campo para a detecção em tempo real das plantas jovens de eucalipto. O ensaio foi realizado em uma área experimental, de 1.600 m², localizada na Universidade Federal de Viçosa, onde foram transplantadas 287 mudas de eucalipto (*Eucalyptus grandis*), com espaçamento de 1,90 metro entre plantas e 3 metros entre linhas de plantio.

2.2 Obtenção e processamento das imagens

As imagens das plantas jovens de eucalipto foram capturadas em talhões distintos, na mesma semana do transplântio, para ambas as áreas (Selvária, Mato Grosso do Sul, e Guaraciaba, Minas Gerais), com altura de plantas variando entre 12 e 23 cm (Figura 2). A captura foi realizada utilizando uma câmera RGB de 13 megapixels, com resolução de 4.128x3.096 pixels. A câmera foi posicionada a um metro de altura e com um ângulo de 90 graus em relação ao solo, alinhada diretamente sobre a linha de plantio.

A Figura 2 ilustra exemplos de imagens utilizadas para treinar e validar o modelo, mostrando as plantas da Área 1 (Figura 2a) e da Área 2 (Figura 2b), refletindo as condições observadas no campo. Após a coleta das imagens das plantas jovens de eucalipto, foi realizada a rotulação utilizando o *software* Labellmg versão 1.4.0 (Labellmg, 2023), a fim de marcar a localização das plantas nas imagens. Essas imagens rotuladas foram empregadas no desenvolvimento do modelo para detecção das plantas em tempo real.

Figura 2 - Plantas jovens de eucalipto: a) imagens obtidas na Área 1; e b) imagens obtidas na Área 2.

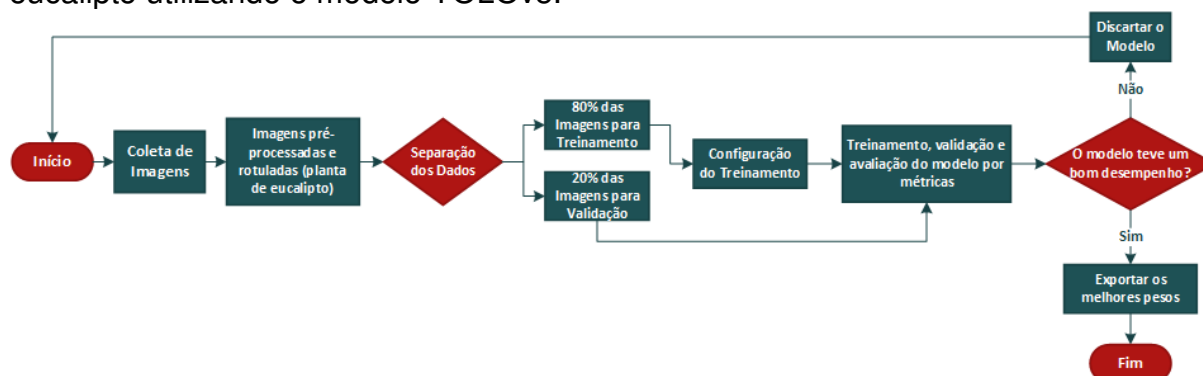


Fonte: O autor, (2024).

2.3 Desenvolvimento do modelo

A Figura 3 apresenta as etapas para o desenvolvimento do modelo de detecção de plantas jovens de eucalipto usando o YOLOv5. Ela oferece uma visão clara e organizada das técnicas e métodos utilizados, facilitando a compreensão das estratégias empregadas no desenvolvimento do modelo.

Figura 3 - Etapas do desenvolvimento do modelo de detecção de plantas jovens de eucalipto utilizando o modelo YOLOv5.



Fonte: O autor, (2024).

No treinamento foram utilizadas 13.750 imagens de plantas jovens de eucalipto, divididas em dois grupos: 6.875 da Área 1 e 6.875 da Área 2. As imagens provenientes dessas áreas foram combinadas em um único banco de dados antes da próxima etapa, que envolveu a rotulagem. Após a rotulagem, as imagens foram separadas aleatoriamente em dois grupos: um para treinamento, com 80% das imagens, e outro para validação, com os 20% restantes (Figura 3).

O treinamento do modelo foi realizado utilizando a versão YOLOv5n6 (nano 6) (Ultralytics, 2023), no ambiente Google Colab Pro+. Para isso, foi empregada uma placa gráfica NVIDIA A100-SXM4-40 GB, garantindo um processamento eficiente e rápido. A escolha do YOLOv5 para esta etapa da pesquisa se justifica por sua compatibilidade com sistemas embarcados, particularmente a NVIDIA Jetson Nano, utilizada no Capítulo 3. Embora o YOLOv8 apresente um desempenho superior em termos de precisão e robustez, o YOLOv5 oferece maior eficiência computacional, tornando-se mais adequado para dispositivos com recursos limitados e aplicações que exigem processamento em tempo real. Além disso, o YOLOv5 é amplamente reconhecido por seu bom desempenho em inferência, permitindo manter uma taxa de detecção elevada mesmo em hardwares com menor capacidade de processamento. Sua arquitetura otimizada proporciona um equilíbrio entre precisão e velocidade, sendo uma solução viável para aplicações embarcadas na agricultura. Outro fator relevante é sua maturidade na comunidade de visão computacional, apresentando diversas otimizações e estabilidade para implementação em sistemas agrícolas automatizados.

Para garantir um treinamento eficiente, o modelo YOLOv5n6 foi ajustado com os hiperparâmetros padrões sugeridos pela Ultralytics (Ultralytics, 2023), incluindo:

número de épocas de treinamento (600), tamanho da imagem de entrada (640 pixels) e tamanho do lote (16). Essa configuração foi escolhida para otimizar o desempenho do modelo em tarefas de detecção, equilibrando precisão e eficiência computacional. A escolha de 600 épocas se baseou em testes preliminares realizados. O modelo foi treinado com pesos iniciais, e em seguida com seus pesos parciais pré-treinados, utilizando a versão do YOLOv5n6.pt para garantir a eficiência computacional adequada para sistemas embarcados (Maideen & Mohanarathinam, 2023).

Durante o processo de treinamento do modelo, a validação e a avaliação por métricas foram realizadas de forma simultânea e integrada. Enquanto o treinamento ajustava os pesos do modelo para minimizar o erro nos dados de treinamento, a validação foi feita com um conjunto de dados separado para avaliar a capacidade do modelo de generalizar para dados não vistos anteriormente. Ao mesmo tempo, a avaliação por métricas forneceu resultados contínuos sobre o desempenho do modelo em ambas as fases, garantindo uma análise precisa de sua eficácia. Esses três processos interdependentes foram conduzidos de maneira concomitante, permitindo ajustes dinâmicos que asseguraram a qualidade e a confiabilidade do modelo em detectar corretamente a classe do objeto ao longo de seu desenvolvimento.

Para avaliar o desempenho do modelo treinado, foram utilizadas as seguintes métricas: precisão (P), *recall* (R), mAP50, mAP50-95, índice de confiança e matriz de confusão (Huang et al., 2023). A precisão (P) é a proporção de detecções corretas em relação ao total de detecções feitas pelo modelo (Equação 1).

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

em que: TP (verdadeiro positivo) é o número de instâncias positivas corretamente identificadas; e FP (falso positivo) é o número de instâncias negativas incorretamente classificadas como positivas.

A Recall (R) é a proporção de detecções corretas em relação ao total de instâncias que pertencem à classe positiva (Equação 2):

$$R = \frac{(TP)}{(TP) + (FN)} \quad (2)$$

em que: FN (False Negative) é o número de instâncias positivas incorretamente classificadas como negativas.

O mAP50 (Mean Average Precision at 50) foi calculado com um limiar de IOU de 0,5, sendo uma detecção considerada correta quando a intersecção entre as bounding boxes prevista e verdadeira atinge pelo menos 50%. A precisão média (AP) é calculada para cada classe com base na curva precisão-recall, e o mAP50 é a média dessas precisões. Já o mAP50-95, com cálculo semelhante ao mAP50, é uma métrica mais rigorosa que avalia a média das precisões médias (AP) em diferentes limiares de IOU, variando de 0,5 a 0,95 em incrementos de 0,05. Essa métrica exige maior precisão na detecção, pois considera diferentes níveis de sobreposição entre as bounding boxes. Ambas as métricas foram calculadas automaticamente pela função de avaliação do YOLOv5, seguindo os procedimentos padrão descritos por Ultralytics (2023). O mAP50-95 exige um limiar de IOU que varia de 0,5 a 0,95, exigindo maior precisão na detecção (Ward et al., 2023). Ambos são amplamente utilizados para avaliar modelos de detecção de objetos (Liu et al., 2024).

Outra métrica empregada foi o índice de confiança, que mede a probabilidade de uma detecção estar correta, com base na análise das características da imagem e no conhecimento adquirido durante o treinamento. Este índice é expresso em percentual, com valores mais altos indicando maior confiança na precisão da detecção. O índice de confiança foi calculado automaticamente pelo modelo do YOLOv5, que compara as características das imagens detectadas com os padrões aprendidos durante o treinamento. Essa métrica é essencial para filtrar detecções de baixa confiabilidade, garantindo que apenas aquelas com alta probabilidade de acerto sejam consideradas. Assim como as outras métricas, o cálculo segue os procedimentos padrão descritos por Ultralytics (2023).

Outra métrica utilizada foi a matriz de confusão, que fornece uma avaliação detalhada da precisão e robustez dos modelos ao diferenciar entre classes de interesse. Ela foi calculada automaticamente pelo YOLOv5, que compara as previsões do modelo com as classes verdadeiras das imagens, registrando o número de verdadeiros positivos, falsos positivos, verdadeiros negativos e falsos negativos. Isso permite medir a acurácia e as taxas de erro do modelo, proporcionando uma visão clara do desempenho na identificação correta e incorreta de objetos (Alruwail et al., 2023).

Os cálculos e as análises de desempenho do modelo na validação foram realizados no Google Colab Pro+, onde as métricas mencionadas foram calculadas automaticamente pelo YOLOv5. Esse ambiente de desenvolvimento permitiu uma análise robusta e detalhada do desempenho do modelo, assegurando que as métricas fossem precisas e refletissem a eficácia real do sistema implementado (Bisong et al., 2019).

Após a conclusão da validação e análise das métricas do modelo, o melhor peso obtido foi selecionado para a implementação no sistema de detecção em tempo real. O melhor peso foi então carregado na placa NVIDIA Jetson Nano, permitindo que o modelo realizasse a detecção das plantas jovens de eucalipto em tempo real, garantindo a eficiência computacional necessária para operar em sistemas embarcados e assegurar a precisão das detecções durante os ensaios em campo.

2.4 Ensaios em campo

2.4.1 Detecção de plantas jovens de eucalipto utilizando plataforma robótica remotamente controlada

O modelo YOLOv5 obtido na fase de desenvolvimento foi instalado em uma placa NVIDIA Jetson Nano, a fim de detectar as plantas jovens de eucalipto em tempo real. A placa Jetson Nano foi configurada para suportar o sistema operacional Linux Ubuntu 18.04, com 4 GB de memória RAM e 128 CUDA cores. Uma câmera de 13 MP, da marca Arducam, foi montada na parte frontal da plataforma robótica, com a lente direcionada para baixo e posicionada a uma altura de 50 cm acima do solo.

A plataforma robótica utilizada foi equipada com sistema de navegação autônoma. Para orientação e navegação, foram utilizados módulos GNSS-RTK (*Global Navigation Satellite System - Real-Time Kinematic*), sensores IMU (*Inertial Measurement Unit*) e componentes de IHM (Interface Homem-Máquina). O GNSS-RTK obtém dados de posicionamento de alta precisão em tempo real, enquanto os sensores IMU medem a aceleração e a orientação da plataforma robótica. A IHM refere-se ao componente do sistema que permite a interação entre o usuário e a máquina ou sistema, que incluiu elementos como tela de toque, teclado e mouse, que facilitaram a operação e o controle da plataforma robótica. O desenvolvimento da plataforma robótica e do algoritmo de navegação utilizados encontram-se detalhados

em Baltazar et al. (2024). Na Figura 4 são apresentados os componentes e as funcionalidades da plataforma robótica.

Figura 4 - Sistema mecânico, elétrico e eletrônico da plataforma robótica utilizada, Link: <https://youtu.be/XvfqyicldCQ>.



Fonte: Baltazar et al., (2024).

Durante os ensaios a plataforma foi remotamente pilotada por um operador a 10 metros de distância, utilizando um tablet com sinal via Bluetooth. Durante o experimento, a plataforma robótica operou em sua velocidade máxima de 0,3 m/s, enquanto o piloto mantinha as rodas centralizadas na linha de plantio para garantir que a planta jovem de eucalipto estivesse no campo de visão da câmera instalada na plataforma.

2.4.2 Avaliação de desempenho do sistema de detecção em tempo real em testes de campo na área experimental

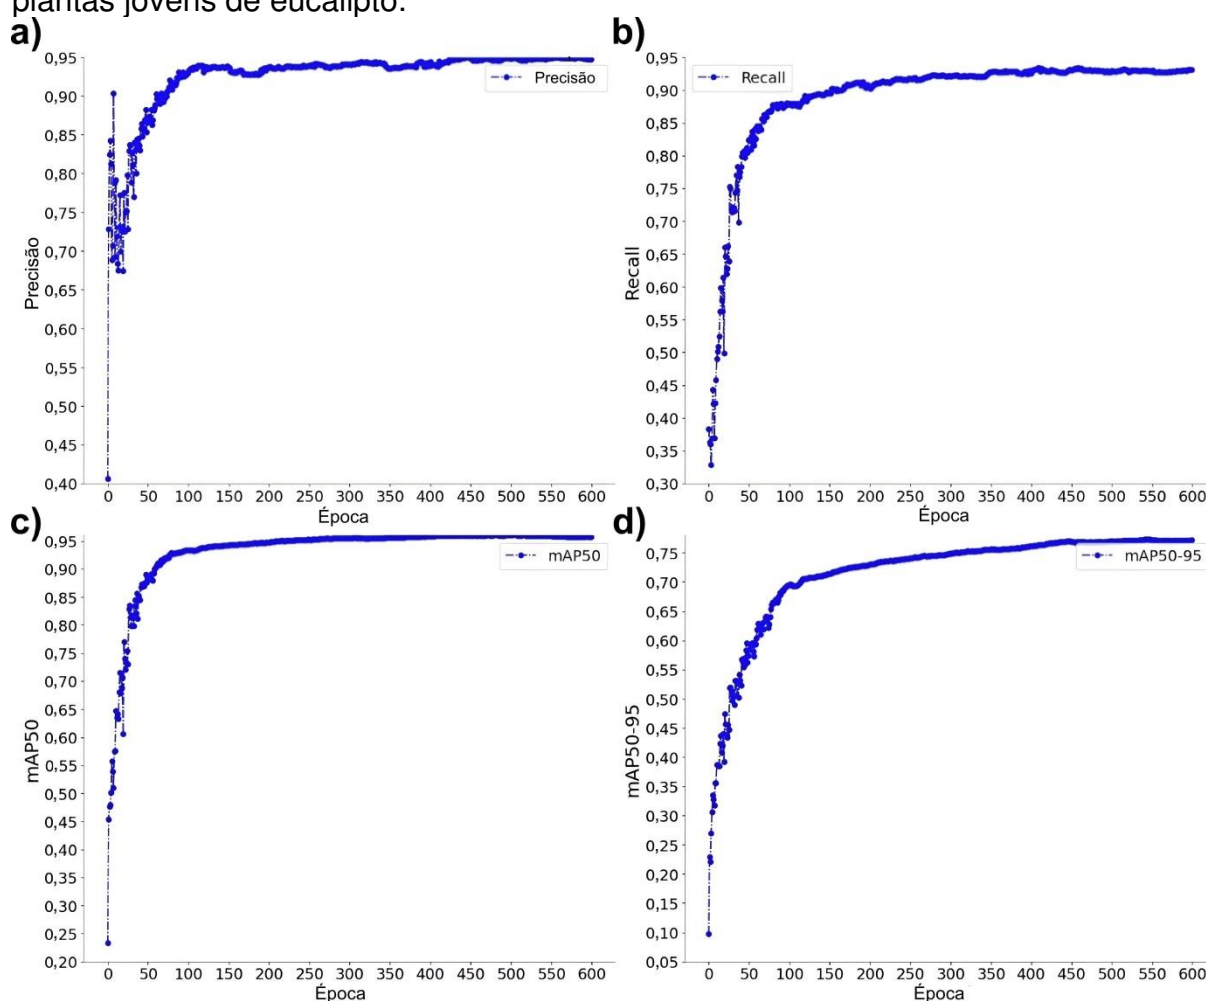
Para capturar vídeos durante o deslocamento da plataforma robótica sobre as linhas de plantio, foi instalado o *software SimpleScreenRecorder* no sistema Linux da Jetson Nano. Este *software* registrou o *feed* de vídeo da câmera montada na frente da plataforma, permitindo a captura em tempo real de todas as detecções das plantas jovens de eucalipto para análise posterior. Os vídeos obtidos foram utilizados para calcular os valores de verdadeiros positivos (TP), falsos positivos (FP) e falsos negativos (FN), necessários para a geração da matriz de confusão e o cálculo das métricas de desempenho, como precisão (P), *recall* (R) e *F1-score* (Huang et al., 2023).

Além disso, foi desenvolvido um *script* em *Python* para salvar em um arquivo .TXT os valores do índice de confiança, velocidade média de inferência em milissegundos (ms) e taxa de *frames* por segundo (FPS) a cada detecção realizada pelo modelo em tempo real. A velocidade média de inferência foi calculada registrando o tempo de processamento de cada detecção realizada pelo modelo em tempo real, expresso em milissegundos (ms). Esses tempos foram então utilizados para gerar histogramas que ilustram a distribuição da velocidade de inferência ao longo das detecções. Simultaneamente, a taxa de *frames* por segundo (FPS) foi calculada dividindo o número total de frames processados pelo tempo total de execução, refletindo a capacidade do sistema de processar imagens em tempo real. Os dados de velocidade média de inferência (ms) e número de frames por segundo (FPS) foram representados na forma de histogramas, o que permitiu uma análise detalhada do desempenho do modelo na Jetson Nano.

3 RESULTADOS E DISCUSSÃO

A Figura 5 apresenta os gráficos de desempenho ao longo das épocas para as métricas de precisão, *recall*, mAP50 e mAP50-95 do modelo YOLOv5 durante o treinamento para a detecção de plantas jovens de eucalipto.

Figura 5 - Métricas do modelo YOLOv5 durante o treinamento para detecção de plantas jovens de eucalipto.



Fonte: O autor, (2024).

Pela análise do gráfico apresentado na Figura 5a, a Precisão do modelo começou em 40% na primeira época e aumentou rapidamente nas primeiras 10 épocas, alcançando 79,12%. Esse crescimento inicial reflete a adaptação do modelo aos padrões de detecção das plantas jovens de eucalipto. Após 20 épocas, o aumento da Precisão com as épocas foi reduzindo, estabilizando-se em torno de 90% por volta da época 80. O valor máximo de precisão foi de 95% na época 554, indicando um

desempenho elevado do modelo na identificação correta das plantas jovens ao final do treinamento.

No estudo realizado por Nnadozie et al. (2022), a rede neural YOLOv5n apresentou uma precisão variando de 91,1% a 95% na detecção de plantas de mandioca, dependendo da resolução das imagens utilizadas. Em contrapartida, Wang et al. (2022) obtiveram uma precisão de 71,13% ao aplicar o YOLOv5n na detecção de plantas recém-germinadas de chá branco Fuding (*Camellia sinensis cv. Fuding-dabaicha*). Os resultados deste estudo, onde o YOLOv5n obteve uma precisão média de 95% na detecção de mudas de eucalipto, apresentam maior similaridade com os valores reportados por Nnadozie et al. (2022). Essa proximidade pode estar relacionada ao fato de que tanto a mandioca quanto o eucalipto são culturas de maior porte e apresentam estruturas foliares bem definidas, facilitando a detecção pelo modelo. Por outro lado, o menor desempenho observado por Wang et al. (2022) pode ser explicado pelo estágio inicial das plantas analisadas, onde as plântulas ainda possuem folhas muito pequenas e morfologias menos distintas, tornando a detecção mais desafiadora para o YOLOv5n (Benjumea et al., 2021). Essas comparações reforçam a importância do tipo de cultura, do estágio fenológico das plantas e da resolução das imagens no desempenho dos modelos de detecção. No contexto deste estudo, a precisão obtida pelo YOLOv5n na detecção de mudas de eucalipto confirma sua aplicabilidade para a automação da irrigação, indicando que o modelo pode ser eficaz para identificar plantas com morfologias bem definidas em condições de campo.

Ao analisar a evolução do recall durante o treinamento (Figura 5b), observa-se que o Recall se iniciou em 38,31% e teve um aumento rápido nas primeiras épocas. Por volta da época 10, o *recall* atingiu 49%, indicando uma melhora significativa na capacidade do modelo de identificar todas as plantas jovens de eucalipto. A estabilização do *recall* em torno de 0,88 a 0,90 a partir da época 80 demonstra a eficácia do modelo em identificar a maioria das plantas nas imagens utilizadas. O valor máximo de *recall* registrado foi 93,37% na época 458, o que indica que o modelo manteve um alto desempenho na detecção até o final do treinamento.

Comparando esses resultados com os de Mota-Delfin et al. (2022), que obtiveram valores de Recall entre 74,7% e 79,3% na detecção de plantas de milho e plantas daninhas usando diferentes variações do YOLOv5, o modelo desenvolvido apresenta um desempenho superior. Essa diferença pode ser atribuída à maior

resolução das imagens ou ao maior contraste das plantas jovens de eucalipto em relação ao fundo, facilitando a detecção mais precisa pelo modelo.

Por outro lado, Kahya e Aslan (2023) obtiveram um Recall de 100% na detecção de plantas jovens de alcachofras usando o YOLOv5n. A superioridade no desempenho relatado por esses autores pode ser explicada pelas características visuais das alcachofras, que são muito nítidas e contrastantes nas imagens, facilitando a identificação. Na identificação de plantas jovens de eucalipto, embora o recall máximo não tenha atingido 100%, a taxa de 93,37% ainda é considerada muito satisfatória para aplicações práticas. Esse resultado é especialmente relevante, considerando os desafios da detecção em condições variáveis de campo, onde fatores como iluminação, sombra e variações na coloração do solo podem reduzir o contraste visual entre a planta e o ambiente. Os resultados obtidos demonstram que o modelo é eficaz para a detecção de mudas de eucalipto, apresentando um desempenho competitivo em comparação com estudos da literatura. Além disso, o modelo manteve uma taxa de detecção elevada mesmo em cenários menos favoráveis, indicando sua robustez em diferentes condições ambientais.

A métrica mAP50 (Figura 5c), que começou em 23,26%, apresentou um aumento constante durante as primeiras épocas, alcançando 64,65% na época 10. A estabilização desta métrica ocorreu por volta da época 100, quando os valores ficaram próximos a 90%, portanto um pouco mais tarde em comparação com a métrica de Precisão. O valor máximo de mAP50 registrado foi 96,11% na época 504, demonstrando que o modelo teve um desempenho satisfatório na detecção de plantas jovens de eucalipto, conseguindo identificar com alta precisão as plantas considerando uma interseção sobre união (IoU) de 0,50.

Os resultados obtidos em outros estudos também evidenciaram a eficácia do algoritmo YOLOv5 em diferentes contextos. García-Navarrete et al. (2024) realizaram um estudo com plantas de milho sob condições de campo e relataram um desempenho de mAP50 de 97,5% para a classe milho. Xu et al. (2024) utilizaram um algoritmo YOLOv5 combinado com o *Vision Transformer* (ViT) e obtiveram resultados da validação experimental de 87,6% na detecção de plantas daninhas.

Em relação à métrica mAP50-95 (Figura 5d), observa-se o valor inicial de 9%, sendo menor o aumento dessa métrica com as épocas em comparação com as demais métricas. Na época 10, o valor era de 38,69%, indicando que o modelo ainda estava se ajustando aos diferentes níveis de IoU. A estabilização ocorreu após a

época 150, com valores próximos de 75%. O valor máximo de mAP50-95 foi de 77,21% na época 549, indicando que o modelo manteve um bom desempenho mesmo em níveis mais rigorosos de avaliação.

Rahman et al. (2023) obtiveram valores de mAP50-95 variando entre 55,34% (YOLOv5n) e 60,89% (YOLOv5m) na detecção de ervas daninhas. Em um estudo posterior, Rahman et al. (2024) obtiveram valores de mAP50-95 variando de 51,2% a 61,1% para diferentes classes de plantas. Esses resultados podem ser explicados pelo fato de a métrica mAP50-95 utilizar um limiar mais rigoroso, considerando várias sobreposições de IoU (*Intersection over Union*), variando de 50% a 95%, o que reduz a tolerância para previsões que não estão exatamente no local correto, penalizando mais os erros do modelo.

No presente estudo, no entanto, o modelo de detecção de plantas jovens de eucaliptos apresentou uma métrica mAP50-95 acima de 77%, demonstrando que o modelo desenvolvido pode ser considerado adequado para aplicações agrícolas. Esse desempenho pode ser atribuído, em parte, às 13.750 imagens de plantas jovens de eucalipto utilizadas no treinamento, que permitiram ao modelo aprender a identificar as plantas jovens em diferentes condições de iluminação, ângulos e cenários. A grande quantidade e diversidade das imagens contribuíram para uma melhor generalização do modelo, refletindo-se na robustez das detecções em campo.

Na Tabela 1 são apresentados os números de verdadeiros positivos e falsos positivos observados na matriz de confusão do modelo desenvolvido usando YOLOv5, em que a classe prevista foi "planta de eucalipto", para um conjunto de validação de 2.750 imagens, após as 600 épocas de treinamento.

Tabela 1 - Resultados de verdadeiros positivos e falsos positivos do modelo YOLOv5 na fase de validação.

Rotulado/Predito	Desempenho do YOLOv5 na validação
Muda de Eucalipto Rotulada como Sim (Positivo)	0,93 2.557 (Verdadeiro positivo)
Muda de Eucalipto Rotulada como Não (Negativo)	0,07 193 (Falso positivo)

Fonte: O autor, (2024).

Conforme verificam-se nos valores apresentados na Tabela 1, o modelo YOLOv5 apresentou um desempenho satisfatório ao detectar corretamente 93% das

plantas jovens de eucalipto em um conjunto de 2.557 imagens. Isso reflete a boa precisão do modelo, com 2.557 casos classificados corretamente como plantas de eucalipto (verdadeiros positivos). No entanto, o modelo também gerou 193 classificações incorretas, identificando erroneamente algumas plantas daninhas como plantas de eucalipto (falsos positivos), representando 7% das detecções.

Um número elevado de falsos positivos em modelos como o YOLOv5 poderia levar a aplicações desnecessárias de insumos, prolongando as operações e aumentando os custos financeiros e logísticos associados. No entanto, a baixa taxa de falsos positivos observada na validação indica que o modelo pode operar de forma eficiente em tempo real, reduzindo o risco de detecções errôneas. É importante destacar que todas as imagens do conjunto de validação continham uma ou mais mudas de eucalipto, o que significa que a métrica de falsos positivos avalia casos em que o modelo identificou incorretamente elementos do ambiente como sendo mudas. Dessa forma, o desempenho do YOLOv5 na detecção precisa das plantas reforça seu potencial para aplicações em monitoramento agrícola e manejo de plantações, garantindo uma identificação confiável mesmo em cenários com variação de fundo e iluminação.

Na Tabela 2 são apresentados os resultados do desempenho das métricas de precisão (P), *recall* (R), mAP50 e mAP50-95 na fase de validação dos modelos e o número de iterações por segundo (It/s).

Tabela 2 - Resultados do desempenho das métricas de precisão (P), *recall* (R), mAP50 e mAP50-95 na fase de validação dos modelos e o número de iterações por segundo (It/s).

Desempenho do YOLOv5 na validação					
Classe	P	R	mAP50	mAP50-95	It/s
Muda de Eucalipto	0,949	0,929	0,959	0,773	3,25
Resumo do modelo: 206 layers, 4.2 GFLOPs					

Fonte: O autor, (2024).

Conforme apresentado na Tabela 2, na fase de validação o modelo YOLOv5 obteve um desempenho satisfatório na detecção de plantas jovens de eucalipto. Com uma precisão (P) de 0,949, o modelo demonstrou alta confiabilidade nas detecções positivas, indicando que 94,9% das plantas identificadas como eucalipto eram realmente eucalipto. Em relação ao *recall* (R), que foi de 0,929, este valor significa

que o modelo foi capaz de identificar 92,9% das plantas de eucalipto presentes nas imagens.

Embora o *recall* seja elevado, é importante considerar que as plantas de eucalipto que não são identificadas pelo modelo podem não receber a irrigação necessária. Isso pode resultar em consequências significativas, como a morte da planta ou o comprometimento do seu crescimento. Portanto, enquanto uma precisão elevada minimiza a irrigação incorreta de plantas daninhas, o *recall* é crítico para garantir que todas as plantas de eucalipto recebam o manejo adequado. Assim, a melhoria contínua do *recall* é essencial para maximizar a eficiência do sistema de detecção e garantir que todas as plantas de eucalipto sejam identificadas e irrigadas corretamente.

A métrica mAP50 registrou um valor de 0,959, o que significa que o modelo manteve uma boa precisão na detecção de objetos quando a sobreposição entre a predição e o objeto real foi de pelo menos 50%. A métrica mAP50-95, que é mais rigorosa pois avalia a precisão em múltiplos níveis de interseção sobre união (IoU) de 50% a 95%, atingiu 0,773. Isso mostra que o modelo YOLOv5 conseguiu manter um bom desempenho, mesmo sob critérios de avaliação mais exigentes.

Comparando esses resultados com os de Pérez-Porras et al. (2023), que utilizaram o YOLOv5 para detectar plantas de papoula (*Papaver rhoeas*) com precisão, *recall* e mAP50 de 76%, 74,6% e 76,2%, respectivamente, observa-se que o modelo desenvolvido apresentou um desempenho superior. A diferença pode ser atribuída à variação nas características das plantas e às condições ambientais nas imagens, que podem ter facilitado a detecção das plantas jovens de eucalipto.

Por outro lado, Moharram et al., (2023) alcançaram uma precisão de 97,22%, *recall* de 97,77% e mAP50 de 95,68% na detecção de pinheiro silvestre utilizando YOLOv5. Os autores destacaram que o aumento dos dados de treinamento melhorou a confiabilidade do modelo. Embora os resultados obtidos pelo modelo desenvolvido estejam próximos aos de Moharram et al., (2023), o ligeiro decréscimo no *recall* em nosso estudo sugere que ainda há espaço para melhorias, possivelmente por meio de um maior volume de dados de treinamento ou técnicas de aumento de dados (Maharana et al., 2023).

Os resultados das métricas de desempenho na validação do modelo confirmam que o YOLOv5 é uma ferramenta eficaz para a detecção de plantas jovens de eucalipto, especialmente quando treinado com um conjunto de dados abrangente. A

performance do modelo em nosso estudo é comparável e, em alguns casos, superior à de estudos anteriores, reforçando sua aplicabilidade em sistemas de detecção em tempo real.

A taxa de processamento do modelo durante a validação foi de 3,25 iterações por segundo (It/s). Essa taxa de processamento indica que o modelo pode analisar mais de três imagens por segundo, o que é essencial para tarefas que exigem respostas rápidas. Esse valor pode ser considerado adequado, especialmente em cenários de aplicação prática.

3.1 Ensaios em campo

Na Tabela 3 são apresentados os resultados da detecção em tempo real utilizando o YOLOv5 implementado na placa Jetson Nano na plataforma robótica. De acordo com os valores apresentados na Tabela 3, o modelo demonstrou uma acurácia satisfatória, detectando corretamente 91% das plantas jovens de eucalipto, resultando em 287 verdadeiros positivos. Não houve casos de falsos negativos, ou seja, todas as plantas de eucaliptos foram detectadas pelo modelo.

No entanto, também foram observados 29 falsos positivos, onde o modelo detectou algo como planta de eucalipto, mas não era, correspondendo a 9% das detecções. Esses resultados indicam que, apesar de algumas detecções incorretas, o modelo YOLOv5 executado na placa Jetson Nano se mostrou adequado para a detecção em tempo real em operações agrícolas, apresentando desempenho satisfatório para a detecção em tempo real de plantas jovens de eucalipto.

Tabela 3 - Resultados de verdadeiros positivos e falsos positivos da detecção em tempo real sob condições de campo usando o YOLOv5 implementado na placa Jetson Nano na plataforma robótica.

Rotulado/Predito	Detecção em tempo real do YOLOv5 na Jetson Nano
Muda de Eucalipto Rotulada como Sim (Positivo)	0,91 287 (Verdadeiro positivo)
Muda de Eucalipto Rotulada como Não (Negativo)	0,09 29 (Falso positivo)

Fonte: O autor, (2024).

Comparando com os resultados do trabalho de Wang et al. (2023), que implementaram o YOLOv5 na NVIDIA Jetson AGX Xavier para detectar plantas de

milho e plantas daninhas, o modelo desenvolvido apresentou um desempenho comparável na detecção de plantas de eucalipto. No estudo desses autores o desempenho na detecção de plantas de milho foi adequado, sem falsos positivos, enquanto em nosso caso houve 9% de falsos positivos. Essa diferença pode ser atribuída às características das plantas e à complexidade do ambiente em que a detecção foi realizada.

No entanto, a taxa de detecção de verdadeiros positivos do modelo desenvolvido está alinhada com o desempenho do YOLOv5 em outros trabalhos que também utilizaram plataformas da NVIDIA (Aishwarya et al., 2023; Bhagat et al., 2023; Harders et al., 2023), destacando a robustez do modelo para a detecção de plantas em tempo real. A utilização do Jetson Nano proporciona uma solução eficaz e de menor custo para aplicações em campo, permitindo detecções precisas mesmo com uma menor capacidade computacional em comparação com a placa AGX Xavier. Esses resultados sugerem que, embora haja espaço para melhorias na redução dos falsos positivos, o uso do YOLOv5 em uma placa NVIDIA Jetson Nano continua sendo uma abordagem viável e eficiente para a automação da detecção de plantas em plataformas robóticas.

O número elevado de falsos positivos (Tabela 3) pode ter implicações significativas no manejo da cultura do eucalipto, especialmente em práticas de irrigação, adubação e controle de pragas e doenças. A irrigação de áreas erroneamente identificadas como contendo eucaliptos pode levar ao desperdício de água e ao aumento dos custos operacionais. Na adubação, o fornecimento de nutrientes a plantas que não são eucaliptos pode resultar em aumento da competição com plantas daninhas. Além disso, o controle de pragas e doenças pode ser comprometido, pois tratamentos químicos ou biológicos podem ser aplicados em plantas daninhas que não requerem tais medidas, aumentando os custos e potencialmente afetando o ambiente. Portanto, é crucial o desenvolvimento de modelos com baixos valores de falsos positivos, contribuindo para a eficiência e a sustentabilidade das práticas de manejo agrícola.

Na Tabela 4 são apresentados os resultados do desempenho das métricas de precisão (P), *recall* (R) e *F1-Score* utilizando o YOLOv5 com a placa NVIDIA Jetson Nano na plataforma robótica. Os resultados, de acordo com a Tabela 4, indicam uma precisão de 0,91, o que significa que 91% das detecções em tempo real feitas pelo modelo foram corretas. O *recall* foi de 1,00, demonstrando que o modelo conseguiu

identificar todas as plantas jovens de eucalipto presentes na área do experimento. O *F1-Score*, que é uma métrica que combina precisão e *recall*, foi de 0,95, refletindo o equilíbrio entre a capacidade do modelo de detectar corretamente as plantas e a quantidade de detecções corretas em relação ao total de detecções feitas.

Tabela 4 - Resultados do desempenho das métricas de precisão (P), *recall* (R), *F1-Score*, usando o YOLOv5 com a placa NVIDIA Jetson Nano na plataforma robótica.

Detecção em tempo real do YOLOv5 na Jetson Nano			
Classe	P	R	F1-Score
Planta de Eucalipto	0,91	1,00	0,95

Fonte: O autor, (2024).

Alam et al. (2022) utilizaram modelos de visão computacional em tempo real para identificar plantas de tabaco em uma plataforma móvel de pulverização robótica. Os modelos modificados *Faster R-CNN* e YOLOv5 identificaram plantas de tabaco a 10 e 16 FPS, respectivamente, com Precisão de 98% e 94%, a uma velocidade do robô de aproximadamente 1,10 m/s O robô usou o ROS (*Robot Operating System*) como estrutura de software e uma GPU NVIDIA GTX 1650Ti de 8 GB para o processamento das imagens. Do mesmo modo, Wang et al. (2022), ao empregarem a rede YOLOv5 para detecção em tempo real de culturas e plantas daninhas no campo utilizando uma GPU NVIDIA GTX 3080Ti, obtiveram os seguintes resultados: precisão (57,3%), *recall* (90%), *F1 score* (70%) e 20,8 FPS. Segundo esses autores, o YOLOv5 proporcionou o melhor desempenho para detecção de beterraba sacarina e ervas-daninhas entre os cinco modelos comparados. Esses resultados demonstram a alta capacidade de detecção dos modelos baseados em YOLOv5 em diferentes tipos de GPU e nas variadas aplicações agrícolas.

A identificação correta de todas as plantas de eucalipto presentes na área de plantio é crucial, pois plantas não irrigadas podem não sobreviver ao déficit hídrico. Portanto, o desempenho satisfatório do modelo contribui para a irrigação adequada e a maior sobrevivência das plantas jovens de eucalipto. A precisão e o *recall* do modelo foram considerados satisfatórios para operações agrícolas, refletindo sua capacidade de detectar e classificar corretamente as plantas jovens de eucalipto em imagens em tempo real utilizando o YOLOv5 instalado na Jetson Nano.

A análise das detecções em tempo real revelou aspectos importantes sobre a adaptabilidade e a precisão do modelo quando aplicado a plantas de diferentes tamanhos e a complexidade do fundo da imagem. À medida que a plataforma robótica

se desloca, as variações no fundo da imagem podem tornar-se uma tarefa complexa para um modelo de visão computacional, influenciando a capacidade de detecção.

Na Figura 6 são ilustrados os resultados da detecção das plantas jovens de eucalipto sob condições de campo, demonstrando a capacidade do modelo em operar em tempo real, inclusive em situações de sombreamento e de variações no porte das plantas.

Figura 6 - Detecção em tempo real utilizando YOLOv5 implementado na placa NVIDIA Jetson Nano e embarcado na plataforma robótica de deslocamento automático na área de plantio de eucalipto (Links: a) <https://youtu.be/-YctEbEshs8>; b) https://youtu.be/1S-YtfJT_WI; e c) <https://youtu.be/tn8BNEI3ato>).



Fonte: O autor, (2024).

Conforme observa-se na Figura 6a, durante as detecções realizadas em vídeo em tempo real, a proximidade da câmera com as plantas, posicionada a 50 cm acima do solo, facilitou a identificação das plantas menores, com altura entre 15 e 23 cm, pois estas ficavam bem evidentes no campo de visão da câmera. No entanto, essa mesma proximidade apresentou desafios operacionais para plantas jovens maiores, próximas dos 35 cm de altura. Devido à altura reduzida da câmera, o modelo teve dificuldades em desenhar corretamente as caixas delimitadoras para essas plantas mais altas, já que elas ocupavam uma maior parte do campo de visão, dificultando a detecção precisa dos limites das plantas.

Esse aspecto ressalta a importância de ajustar a altura da câmera em função do tamanho das plantas para otimizar o desempenho do sistema de detecção em tempo real. Além disso, essas limitações operacionais devem ser consideradas na implementação prática do sistema, especialmente em plantações onde a variação de tamanho das plantas é significativa, pois o modelo enfrentou dificuldades para detectar plantas de eucalipto de maior porte e com mais de uma ramificação. Isso ocorre porque o modelo YOLOv5 foi treinado com imagens de plantas pequenas na primeira semana após o transplante.

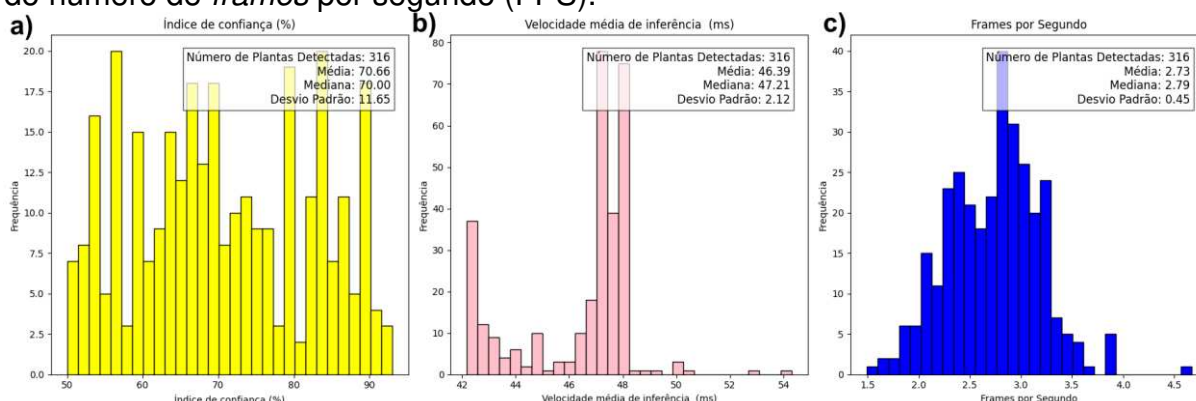
Portanto, imagens de plantas maiores ou com mais ramificações apresentam maior dificuldade de detecção. Em um caso específico, quando o modelo encontrou uma dessas plantas jovens, ele interpretou um dos ramos como se fosse uma planta independente. Como consequência, ele detectou incorretamente um ramo como se fosse uma planta distinta, em vez de reconhecer a planta inteira.

A Figura 6b demonstra a capacidade do modelo em diferenciar mudas de eucalipto de plantas daninhas, especialmente gramíneas, mesmo em um ambiente com alta complexidade e variações de iluminação. O modelo identificou corretamente as mudas de eucalipto, distinguindo-as de plantas invasoras com características visuais distintas, como forma, cor e textura. Essa precisão na detecção é essencial para operações agrícolas em tempo real, onde a presença de diferentes espécies e as variações nas condições de luz podem comprometer o desempenho de sistemas automatizados.

Verificou-se ainda que o modelo é eficiente em detectar plantas de eucalipto de menor porte (Figura 6c) e com um único ramo, devido à semelhança com as plantas utilizadas no treinamento do modelo. Na Figura 6c, o modelo em tempo real demonstrou sua capacidade de detectar várias plantas simultaneamente nos mesmos frames, mesmo em condições de sombreamento. Nesse caso específico, duas plantas foram plantadas próximas uma da outra como uma estratégia para garantir o estabelecimento da planta, caso uma delas não sobrevivesse. Essa capacidade do modelo de distinguir e detectar ambas as plantas com precisão, mesmo em situações de proximidade e sombreamento, reforça a robustez do sistema em lidar com diferentes cenários encontrados no campo.

A Figura 7 apresenta os histogramas da detecção em tempo real utilizando o YOLOv5 implementado na placa NVIDIA Jetson Nano e embarcado na plataforma robótica de deslocamento automático na área experimental de plantio de eucalipto.

Figura 7 - Histogramas da detecção em tempo real utilizando YOLOv5 implementado na placa NVIDIA Jetson Nano e embarcado na plataforma robótica de deslocamento automático na área experimental de plantio de eucalipto: a) Histograma do índice de confiança (%); b) Histograma da velocidade média de inferência (ms); e c) Histograma do número de *frames* por segundo (FPS).



Fonte: O autor, (2024).

De acordo com a Figura 7a, o YOLOv5 detectou 316 plantas, das quais, conforme visto anteriormente na Tabela 3, 287 foram verdadeiros positivos (TP) e 29 foram falsos positivos (FP). O índice de confiança médio foi de 70,66%, com uma mediana de 70% e um desvio padrão de 11,65. Esses valores indicam que a maioria das detecções foi realizada com um nível de confiança que está acima do limite de 70%, o que demonstra uma consistência aceitável no desempenho do modelo em relação à precisão da detecção.

No entanto, o desvio padrão de 11,65% sugere que houve uma variação significativa nos níveis de confiança entre as diferentes detecções, refletindo a presença de algumas detecções com menor certeza. A média elevada do índice de confiança é crucial, pois garante que as detecções feitas pelo modelo são confiáveis e precisas, reduzindo a probabilidade de falsas detecções que podem comprometer a eficiência da operação.

Jha et al. (2022) implementaram o modelo YOLOv5 na placa NVIDIA Jetson Nano para identificar plantas daninhas. Os resultados mostraram índices de confiança de 92%, 93% e 71% para as diferentes classes, demonstrando a eficiência do modelo YOLOv5. Esses resultados são semelhantes aos obtidos no presente estudo, indicando que a plataforma Jetson Nano é eficaz para a detecção em tempo real de diferentes tipos de plantas, incluindo plantas jovens de eucalipto.

Na Figura 7b é apresentado o histograma da velocidade média de inferência do modelo, que é o tempo que o YOLOv5 leva para processar as imagens em tempo

real. A velocidade média foi de 46,39 milissegundos, com uma mediana de 47,21 milissegundos e um desvio padrão de 2,12. A importância de obter velocidades médias de inferência maiores é que elas permitem que o modelo processe as imagens e forneça detecções em tempo hábil, o que é essencial para operações em tempo real, especialmente em ambientes de campo onde as condições podem mudar rapidamente. Uma velocidade de inferência mais alta assegura que a plataforma robótica pode se deslocar e realizar detecções sem atrasos significativos, mantendo a operação fluida e eficiente. Nota-se na Figura 7c o fluxograma da métrica de *frames* por segundo (FPS). A métrica de FPS teve uma média de 2,73, uma mediana de 2,79 e um desvio padrão de 0,45.

Embora o modelo YOLOv5 tenha demonstrado uma alta capacidade de processamento de imagens com uma velocidade média de inferência de 46,49 milissegundos na placa NVIDIA Jetson Nano, a taxa de *frames* por segundo (FPS) foi relativamente baixa. Isso ocorre porque, apesar de a inferência de cada frame ser rápida, o *hardware* da Jetson Nano possui limitações que impedem o processamento de um maior número de frames por segundo. Portanto, para melhorar a eficiência operacional e permitir operações mais rápidas, é recomendada a utilização de hardware com maior capacidade de processamento, que permita aumentar os valores de FPS, sem comprometer a velocidade de inferência.

Wang et al. (2023a) implementaram o YOLOv5 na placa NVIDIA Jetson TX2 para a detecção de ervas daninhas. Os resultados do teste demonstraram que os modelos leves e aprimorados YOLOv5 apresentaram uma velocidade de detecção de 80 FPS, 79,36 FPS e 81,97 FPS para as diferentes variações do YOLOv5, com um tempo médio de execução para uma imagem de quadro único de 35,3 milissegundos. Isso mostra que placas mais potentes que a Jetson Nano podem oferecer desempenhos superiores em termos de velocidade de processamento, o que é vantajoso para aplicações que exigem detecção em tempo real com alta taxa de atualização. Comparativamente, a Jetson Nano também demonstrou ser uma plataforma eficaz, embora com limitações de desempenho em relação a placas mais avançadas como a Jetson TX2.

Maiores valores de FPS são desejáveis porque permitem uma maior velocidade de deslocamento da máquina e uma maior eficiência operacional. Os valores de FPS obtidos com a Jetson Nano foram relativamente baixos, o que implica que uma máquina utilizando o sistema desenvolvido não poderia se deslocar a velocidades

maiores sem comprometer a detecção das plantas. Isso destaca a importância de utilizar plataformas de hardware mais potentes do que a Jetson Nano para aumentar os valores de FPS e, conseqüentemente, melhorar a eficiência operacional da plataforma robótica.

Com base na análise dos resultados, nota-se que o modelo desenvolvido cumpre o objetivo principal de identificar as plantas jovens de eucalipto presentes nos vídeos, realizando a detecção em tempo real sob condições de campo na plataforma robótica, com um *recall* de 1,00, ou seja, todas as plantas jovens presentes na área experimental foram detectadas. Isso é crucial para um sistema de irrigação automatizado, pois garante que todas as plantas recebam água. Uma vez que a planta jovem de eucalipto não irrigada corre um alto risco de não sobreviver, a confiabilidade do modelo em garantir que nenhuma planta seja ignorada é fundamental para o sucesso do sistema.

A implementação do modelo YOLOv5 no sistema de detecção em tempo real de plantas jovens de eucalipto representa uma solução inovadora que pode contribuir significativamente para a redução de custos operacionais em plantações. Nos sistemas atuais, a detecção e o manejo de plantas exigem a presença de muitos trabalhadores para identificar manualmente as plantas jovens de eucalipto e realizar a irrigação. Este processo é frequentemente ineficiente e sujeito a erros humanos, resultando em maior uso de recursos e custos elevados de mão de obra. Com o uso de sistemas automatizados baseados em inteligência artificial, como o desenvolvido neste estudo, é possível reduzir drasticamente a necessidade de pessoal no campo.

A precisão e o *recall* elevados do modelo garantem que todas as plantas jovens sejam identificadas corretamente, permitindo a aplicação precisa e seletiva da irrigação, minimizando desperdícios e custos associados. Assim, a adoção de sistemas como o desenvolvido neste trabalho não apenas aumenta a eficiência operacional, mas também proporciona uma economia substancial ao reduzir a dependência de trabalho manual intensivo, tornando o manejo agrícola mais sustentável e competitivo economicamente.

4 CONCLUSÕES

Os resultados deste estudo confirmam que o YOLOv5 é uma solução viável para a detecção de mudas de eucalipto em tempo real, apresentando alta precisão e recall na identificação das plantas, o que reforça sua aplicabilidade para automação agrícola.

A implementação do modelo na NVIDIA Jetson Nano demonstra que é possível realizar detecções com alta taxa de acerto, apesar das limitações computacionais do hardware embarcado. No entanto, a baixa taxa de frames por segundo (FPS) impacta a velocidade da plataforma robótica, indicando que o uso de hardware mais potente pode ser necessário para aumentar a eficiência operacional em aplicações que demandam processamento contínuo e rápido. O desempenho do modelo também revela que a identificação de mudas maiores ou mais ramificadas ainda representa um desafio, especialmente em ambientes com fundo complexo e variações de iluminação. Esses fatores devem ser considerados para futuras melhorias no treinamento e otimização do modelo.

Além disso, os achados deste estudo indicam que a detecção eficaz das mudas permite a automação da irrigação em tempo real, garantindo que todas as plantas da área experimental sejam identificadas e atendidas, contribuindo para a redução do desperdício de água e o aumento da eficiência produtiva. Dessa forma, este trabalho reforça que o YOLOv5 é uma alternativa viável para aplicações agrícolas embarcadas, sendo capaz de operar em tempo real e oferecer suporte a práticas mais sustentáveis e eficientes no manejo de plantações de eucalipto.

REFERÊNCIAS

- ABAIMOV, S.; & MARTELLINI, M. Artificial intelligence in autonomous weapon systems. **21st Century Prometheus: Managing CBRN Safety and Security Affected by Cutting-Edge Technologies**, p. 141-177, 2020.
- AISHWARYA, N.; & KUMAR, V. Banana Ripeness Classification with Deep CNN on NVIDIA Jetson Xavier AGX. In: **2023 7th International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud)(I-SMAC)**. IEEE, p. 663-668, 2023.
- ALAM, M. S.; ALAM, M.; TUFAIL, M.; KHAN, M. U.; GÜNEŞ, A.; SALAH, B.; ... & KHAN, M. T. TobSet: A new tobacco crop and weeds image dataset and its utilization for vision-based spraying by agricultural robots. **Applied Sciences**, v. 12, n. 3, p. 1308, 2022.
- ALRUWAILI, M.; ATTA, M. N.; SIDDIQI, M. H.; KHAN, A.; KHAN, A.; ALHWAITI, Y.; & ALANAZI, S. Deep Learning-Based YOLO Models for the Detection of People With Disabilities. **IEEE Access**, 2023.
- ARAÚJO, L. M.; SANTOS, L. A. C.; PACHECO, A. R.; CALIL, F. N.; & SILVA-NETO, C. M. The genus Eucalyptus as a forest component in Integrated Crop-Livestock-Forestry Systems (ICLFS): a bibliometric analysis. **Scientia Forestalis**, v. 51, 2023.
- BALTAZAR, J. A.; COELHO, A. L. F.; VALENTE, D. S. M.; DE QUEIROZ, D. M.; & VILLAR, F. M. M. Development of a Robotic Platform with Autonomous Navigation System for Agriculture. **AgriEngineering**, v. 6, n. 3, p. 3362, 2024.
- BENJUMEA, A.; TEETI, I.; CUZZOLIN, F.; BRADLEY, A. YOLO-Z: Improving small object detection in YOLOv5 for autonomous vehicles. **arXiv preprint arXiv:2112.11798**, 2021.
- BHAGAT, S.; KOKARE, M.; HASWANI, V.; HAMBARDE, P.; TAORI, T.; GHANTE, P. H.; & PATIL, D. K. Advancing real-time plant disease detection: A lightweight deep learning approach and novel dataset for pigeon pea crop. **Smart Agricultural Technology**, v. 7, p. 100408, 2024.
- BISONG, E. Building machine learning and deep learning models on google cloud platform: a comprehensive guide for beginners, Berkeley, CA: **Apress**, p. 59-64, 2019.
- CARDELLICCHIO, A.; SOLIMANI, F.; DIMAURO, G.; PETROZZA, A.; SUMMERER, S., CELLINI, F.; & RENÒ, V. Detection of tomato plant phenotyping traits using YOLOv5-based single stage detectors. **Computers and Electronics in Agriculture**, v. 207, p. 107757, 2023.
- DORNELLES, L. B.; MACIEL FILHO, R.; & MARIANO, A. P. Organosolv fractionation of eucalyptus: economics of cellulosic ethanol and chemicals versus lignin valorization to phenols and polyols. **Industrial Crops and Products**, v. 173, p. 114097, 2021.

GARCÍA, L. Y., RUBILAR, R., VALVERDE, J. C., EMHART, V., BASCUÑÁN, L., MEDINA, A., & BOZO, D. Morphological, physiological and carbon balance response of Eucalyptus genotypes under water stress. **New Forests**, v. 55, n. 3, p. 441-457, 2024.

GARCÍA-NAVARRETE, O. L.; SANTAMARIA, O.; MARTÍN-RAMOS, P.; VALENZUELA-MAHECHA, M. Á.; & NAVAS-GRACIA, L. M. Development of a Detection System for Types of Weeds in Maize (*Zea mays* L.) under Greenhouse Conditions Using the YOLOv5 v7. 0 Model. **Agriculture**, v. 14, n. 2, p. 286, 2024.

HARDERS, L. O.; UFER, T.; WREDE, A.; & HUSSMANN, S. UAV-based real-time weed detection in horticulture using edge processing. **Journal of Electronic Imaging**, v. 32, n. 5, p. 052405-052405, 2023.

HUANG, H.; LAN, G.; WEI, J.; ZHONG, Z.; XU, Z.; LI, D.; & ZOU, F. TLI-YOLOv5: a lightweight object detection framework for transmission line inspection by unmanned aerial vehicle. **Electronics**, v. 12, n. 15, p. 3340, 2023.

JHA, Y.; PRAJAPATI, H.; & FATANIYA, B. Real-Time Object Detection in Microscopic Image of Indian Herbal Plants using YOLOv5 on Jetson Nano. In: **2022 International Conference on Connected Systems & Intelligence (CSI)**. IEEE, p. 1-8, 2022.

JOCHER, G.; STOKEN, A.; CHAURASIA, A.; BOROVEC, J.; KWON, Y.; MICHAEL, K.; ... & THANH MINH, M. ultralytics/yolov5: v6. 0-YOLOv5n'Nano'models, Roboflow integration, TensorFlow export, OpenCV DNN support. **Zenodo**, 2021.

KAHYA, E.; & ASLAN, Y. Detection of artichoke on seedling based on YOLOV5 model. **International Journal of Agriculture Environment and Food Sciences**, v. 8, n. 1, p. 186-201, 2023.

KURNIAWAN, A.; & KURNIAWAN, A. (Introduction to nvidia jetson nano. **IoT Projects with NVIDIA Jetson Nano: AI-Enabled Internet of Things Projects for Beginners**, p. 1-6, 2021.

LABELIMG. 2023. **heartexlabs/labellmg-GitHub**. <https://github.com/tzutalin/labellmg>

LIU, R.; HUANG, M.; WANG, L.; BI, C.; & TAO, Y. PDT-YOLO: A Roadside Object-Detection Algorithm for Multiscale and Occluded Targets. **Sensors**, v. 24, n. 7, p. 2302, 2024.

LIZANO, S. A., & WESTERLUND, T. Comparison of edge computing platforms for hardware acceleration of AI: Kria KV260, Jetson Nano and RTX 3060. **J. Edge Comput.**, v. 15, n. 3, p. 123-135, 2024.

LU, C.; NNADOZIE, E.; CAMENZIND, M. P.; HU, Y.; & YU, K. Maize plant detection using UAV-based RGB imaging and YOLOv5. **Frontiers in Plant Science**, v. 14, p. 1274813, 2024.

MAHARANA, K.; MONDAL, S.; & NEMADE, B. A review: Data pre-processing and data augmentation techniques. **Global Transitions Proceedings**, v. 3, n. 1, p. 91-99, 2022.

MAIDEEN, A., & MOHANARATHINAM, A. Computer Vision-Assisted Object Detection and Handling Framework for Robotic Arm Design Using YOLOV5. **ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal**, v. 12, p. e31586-e31586, 2023.

MOHARRAM, D.; YUAN, X.; & LI, D. Tree seedlings detection and counting using a deep learning algorithm. **Applied Sciences**, v. 13, n. 2, p. 895, 2023.

MOTA-DELFIN, C.; LÓPEZ-CANTEÑS, G. D. J.; LÓPEZ-CRUZ, I. L.; ROMANTCHIK-KRIUCHKOVA, E.; & OLGUÍN-ROJAS, J. C. Detection and counting of corn plants in the presence of weeds with convolutional neural networks. **Remote Sensing**, v. 14, n. 19, p. 4892, 2022.

NNADOZIE, E. C.; ILOANUSI, O.; ANI, O.; & YU, K. Cassava Detection from UAV Images Using YOLOv5 Object Detection Model: Towards Weed Control in a Cassava Farm. **bioRxiv**, p. 2022.11. 16.516748, 2022.

OLIVEIRA, E. B.; PINTO JUNIOR, J. E.; & JUNIOR, J. E. P. **O eucalipto e a Embrapa: quatro décadas de pesquisa e desenvolvimento**. Brasília, DF: Embrapa, p. 1160, 2021.

PÉREZ-PORRAS, F. J.; TORRES-SÁNCHEZ, J.; LÓPEZ-GRANADOS, F.; & MESAS-CARRASCOSA, F. J. Early and on-ground image-based detection of poppy (*Papaver rhoeas*) in wheat using YOLO architectures. **Weed Science**, v. 71, n. 1, p. 50-58, 2023.

PRAJAPATI, H. A.; KADAM, D. M.; AITWAR, S. S.; JAGTAP, P. D.; SINGH, D.; NANDEHA, N.; & MUKHERJEE, D. Application of Robotics, Artificial Intelligence and Deep Learning in Modern Agriculture Technology: A Review. **International Journal of Plant & Soil Science**, v. 35, n. 23, p. 106-116, 2023.

RAHMAN, A.; LU, Y.; & WANG, H. Performance evaluation of deep learning object detectors for weed detection for cotton. **Smart Agricultural Technology**, v. 3, p. 100126, 2023.

RAMANTSWANA, M.; GUERRA, S. P. S.; & ERSSON, B. T. Advances in the mechanization of regenerating plantation forests: A review. **Current forestry reports**, v. 6, p. 143-158, 2020.

SANTOS, H. F.; SILVA, M. L. D.; SOARES, N. S.; DINIZ, F. F.; & COELHO JUNIOR, L. M. Brazil's competitiveness in exportation of forest products from 2008 to 2018. **Revista Árvore**, v. 46, p. e4617, 2022.

SASSU, A.; MOTTA, J.; DEIDDA, A.; GHIANI, L.; CARLEVARO, A.; GARIBOTTO, G., & GAMBELLA, F. Artichoke deep learning detection network for site-specific agrochemicals uas spraying. **Computers and Electronics in Agriculture**, v. 213, p. 108185, 2023.

SHARMA, S.; VERMA, K.; & HARDAHA, P. Implementation of artificial intelligence in agriculture. **Journal of Computational and Cognitive Engineering**, v. 2, n. 2, p. 155-162, 2023.

TALAVIYA, T.; SHAH, D.; PATEL, N.; YAGNIK, H.; & SHAH, M. Implementation of artificial intelligence in agriculture for optimisation of irrigation and application of pesticides and herbicides. **Artificial Intelligence in Agriculture**, v. 4, p. 58-73, 2020.

THORAT, T.; PATLE, B. K.; & KASHYAP, S. K. Intelligent insecticide and fertilizer recommendation system based on TPF-CNN for smart farming. **Smart Agricultural Technology**, v. 3, p. 100114, 2023.

ULTRALYTICS. **Comprehensive Guide to Ultralytics YOLOv5**. Accessed 10 May 2023, URL: <https://docs.ultralytics.com/yolov5/>

VALLADARES, S.; TOSCANO, M.; TUFÍÑO, R.; MORILLO, P.; & VALLEJO-HUANGA, D. (2021). **Performance evaluation of the Nvidia Jetson Nano through a real-time machine learning application**. In: **Intelligent Human Systems Integration 2021: Proceedings of the 4th International Conference on Intelligent Human Systems Integration (IHSI 2021): Integrating People and Intelligent Systems, February 22-24, 2021, Palermo, Italy**. Springer International Publishing, p. 343-349, 2021.

VISENTIN, F.; CREMASCO, S.; SOZZI, M.; SIGNORINI, L.; SIGNORINI, M.; MARINELLO, F.; & MURADORE, R. A mixed-autonomous robotic platform for intra-row and inter-row weed removal for precision agriculture. **Computers and Electronics in Agriculture**, v. 214, p. 108270, 2023.

WAKCHAURE, M.; PATLE, B. K.; & MAHINDRAKAR, A. K. Application of AI techniques and robotics in agriculture: A review. **Artificial Intelligence in the Life Sciences**, v. 3, p. 100057, 2023.

WANG, A.; PENG, T.; CAO, H.; XU, Y.; WEI, X.; & CUI, B. TIA-YOLOv5: An improved YOLOv5 network for real-time detection of crop and weed in the field. **Frontiers in Plant Science**, v. 13, p. 1091655, 2022.

WANG, B.; YAN, Y.; LAN, Y.; WANG, M.; & BIAN, Z. Accurate detection and precision spraying of corn and weeds using the improved YOLOv5 model. **IEEE Access**, v. 11, p. 29868-29882, 2023.

WANG, J.; LI, X.; YANG, G.; WANG, F.; MEN, S.; XU, B.; ... & YAN, L. Research on tea trees germination density detection based on improved YOLOv5. **Forests**, v. 13, n. 12, p. 2091, 2022.

WANG X.; WANG Q.; LI H.; HE J.; LU C.; E ZHANG X. Weed Detection Method of Straw-covered Farmland Based on YOLO v5-Jetson TX2. **Transactions of the Chinese Society for Agricultural Machinery**, v. 54, n. 11, p. 39-48, 2023a.

WARD, T.; RASHAD, S.; & ELGAZZAR, H. Machine Learning Based Pedestrian Detection and Tracking for Autonomous Vehicles. In: **2023 IEEE 13th Annual**

Computing and Communication Workshop and Conference (CCWC). IEEE, p. 1294-1299, 2023.

XU, Y., BAI, Y., FU, D., CONG, X., JING, H., LIU, Z., & ZHOU, Y. Multi-species weed detection and variable spraying system for farmland based on W-YOLOv5. **Crop Protection**, v. 182, p. 106720, 2024.

ZHANG, T.; ZHOU, J.; LIU, W.; YUE, R.; YAO, M.; SHI, J.; & HU, J. Seedling-YOLO: High-Efficiency Target Detection Algorithm for Field Broccoli Seedling Transplanting Quality Based on YOLOv7-Tiny. **Agronomy**, v. 14, n. 5, p. 931, 2024.

CONCLUSÃO GERAL

A presente tese apresentou um estudo abrangente sobre a detecção de plantas jovens de eucalipto utilizando modelos de inteligência artificial, com ênfase nas versões YOLOv5 e YOLOv8, avaliando seu desempenho em diferentes cenários e condições.

No Capítulo 1, os resultados indicaram que o modelo YOLOv8 alcançou uma precisão média de detecção de 0,958 e um recall de 0,935. O mAP50, representando a média da precisão com uma sobreposição de pelo menos 50% entre a predição e a verdade real, atingiu 0,974, enquanto a média de precisão para múltiplos limiares de sobreposição (mAP50-95) foi de 0,836. O YOLOv5, por sua vez, obteve uma precisão média de 0,951 e um recall médio de 0,944, com um mAP50 de 0,972 e um mAP50-95 de 0,791. Embora ambos os modelos tenham demonstrado alto desempenho, o YOLOv8 apresentou uma leve superioridade em termos das métricas avaliadas.

No Capítulo 2, a análise revelou que tanto o YOLOv5 quanto o YOLOv8 obtiveram altas pontuações de confiança na identificação de plantas jovens de eucalipto com e sem estresse hídrico em imagens e vídeos, comprovando sua eficácia para detecção em campo. O modelo YOLOv8, além de manter uma maior precisão, destacou-se pela velocidade superior de inferência por quadro, fator essencial para a implementação de sistemas de irrigação automatizados. Dessa forma, ambos os modelos mostraram-se promissores como ferramentas para a automação da irrigação localizada de plantas jovens de eucalipto, permitindo uma aplicação de água em taxa variada e em tempo real, garantindo uma resposta eficiente às necessidades hídricas das plantas.

No Capítulo 3, os resultados indicaram que o modelo YOLOv5, implementado na NVIDIA Jetson Nano, apresentou um desempenho satisfatório para operações agrícolas, alcançando uma precisão de 95% e um recall de 93,37% na detecção de plantas jovens. Com uma velocidade média de inferência de 46,49 milissegundos e uma taxa de acerto de 91%, o modelo demonstrou alta capacidade de processamento de imagens em tempo real. No entanto, a detecção de mudas maiores ou com mais ramificações apresentou desafios, especialmente em situações com variações de fundo durante o movimento da plataforma robótica, impactando a precisão. Além disso, a baixa taxa de frames por segundo (FPS) na Jetson Nano limitou a velocidade

de operação da plataforma, sugerindo a necessidade de um hardware mais robusto para aumentar o FPS e melhorar a eficiência operacional.

De maneira geral, os estudos conduzidos demonstraram que o modelo YOLOv5 é viável para operações de irrigação em tempo real, com um recall de 1, garantindo que todas as plantas na área experimental fossem identificadas e irrigadas, assegurando a sobrevivência das mudas e a eficiência do processo produtivo. A pesquisa evidencia que a implementação de sistemas de detecção baseados em YOLOv5 e YOLOv8 proporciona um avanço significativo na automação agrícola, destacando a importância do uso de hardware adequado para maximizar o desempenho e a velocidade de operação.