



FATEC OSASCO – PREFEITO HIRANT SANAZAR
CURSO DE TECNOLOGIA EM AUTOMAÇÃO INDUSTRIAL

DAVID GABRIEL RIBEIRO DOS SANTOS
KAYKY SANTOS MACIEL
MARCOS PAULO SILVA DE OLIVERIA JUNIOR

DAIA – DRONE AGRÔNOMO COM INTELIGÊNCIA ARTIFICIAL

OSASCO

2025

DAVID GABRIEL RIBEIRO DOS SANTOS
KAYKY SANTOS MACIEL
MARCOS PAULO SILVA DE OLIVERIA JUNIOR

DAIA – DRONE AGRÔNOMO COM INTELIGÊNCIA ARTIFICIAL

Trabalho de Graduação apresentado à banca examinadora do Curso de Graduação em Automação Industrial da Faculdade de Tecnologia de Osasco, Faculdade Prefeito Hirant Sanazar, como parte dos requisitos para obtenção do diploma de Graduação em tecnólogo em Automação Industrial.

Orientador (a): Prof. Dr. Alexandre Imperatore



FATEC OSASCO – PREFEITO HIRANT SANAZAR
TECNOLOGIA EM AUTOMAÇÃO INDUSTRIAL

DAVID GABRIEL RIBEIRO DOS SANTOS
KAYKY SANTOS MACIEL
MARCOS PAULO SILVA DE OLIVERIA JUNIOR

ESTE TRABALHO DE GRADUAÇÃO FOI JULGADO ADEQUADO COMO PARTE DO
REQUISITO PARA OBTENÇÃO DO DIPLOMA DE
“GRADUADO EM TECNÓLOGO EM AUTOMAÇÃO INDUSTRIAL”

APROVADO EM SUA FORMA FINAL PELA BANCA EXAMINADORA DO CURSO DE
TECNOLOGIA EM AUTOMAÇÃO INDUSTRIAL

Prof. Esp. Wilson Donizete Fernandes
Coordenador

BANCA EXAMINADORA:

Prof.(a) _____
Orientador(a)

Prof.(a) _____
Coorientador(a)

Prof.(a) _____
Convidado(a)

AGRADECIMENTOS

*AO GRANDE **EU SOU!***

A NOSSO ORIENTADOR!

A NOSSA FAMILIA!

E NOSSOS COLEGAS!

RESUMO

Este projeto consiste em desenvolver um sistema capaz de detectar a presença da lagarta-cartucho (*Spodoptera frugiperda*) em plantações por meio de técnicas de Visão Computacional e Inteligência Artificial, utilizando o modelo YOLOv8 integrado ao drone DJI Tello. O objetivo é permitir a identificação rápida e automática da praga a partir de imagens capturadas ou fornecidas ao sistema, gerando relatórios de detecção que auxiliem no monitoramento e na tomada de decisão no manejo agrícola.

Palavras-Chave: Visão Computacional. Detecção de Pragas. YOLOv8. Agricultura de Precisão. Drone DJI Tello.

ABSTRACT

This project consists of developing a system capable of detecting the presence of the fall armyworm (*Spodoptera frugiperda*) in crops using Computer Vision and Artificial Intelligence techniques, utilizing the YOLOv8 model integrated with the DJI Tello drone. The objective is to enable the rapid and automatic identification of the pest from images captured or provided to the system, generating detection reports that assist in monitoring and decision-making in agricultural management.

KeyWords: Computer Vision. Pest Detection. YOLOv8. Precision Agriculture. DJI Tello Drone.

LISTA DE FIGURAS

FIGURA 1. Diferenças relativas entre plataformas de asa fixa e rotativa	19
FIGURA 2. Estrutura da uma rede neural rasa	23
FIGURA 3. Arquitetura YOLO do artigo original (modificada pelo autor)	24
FIGURA 4. Disposição dos botões de Conexão e Status.	29
FIGURA 5. Apresentação da câmera aberta em resposta ao comando “câmera”.....	29
FIGURA 6. Disposição dos botões de direção do drone na interface gráfica.....	30
FIGURA 7. Disposição dos botões de deslocamento do drone.na interface gráfica.	30
FIGURA 8. Disposição dos botões referentes a câmera/cor/YOLO.	30
FIGURA 9. Disposição dos botões de tipo <i>sliders</i> referentes ao ajuste de movimento.	31
FIGURA 10. Tela de apresentação dos resultados no terminal da interface gráfica.	31
FIGURA 11. Interface de controle do drone.	31
FIGURA 12. Estrutura das imagens a serem coletadas pela câmera do drone.....	34
FIGURA 13. Padrão de nomenclatura das imagens que compõe o dataset.	34
FIGURA 14. Classificação do objeto de detecção através da <i>bounding-box</i> (em vermelho).	35
FIGURA 15. Print PDF Relatório de detecção.	38
FIGURA 16. Modelo DJI Tello Boost.	40

LISTA DE ABREVIATURAS E SIGLAS

1. **Cepea** – Centro de Estudos Avançados em Economia Aplicada
2. **CNA** – Confederação da Agricultura e Pecuária do Brasil
3. **PIB** – Produto Interno Bruto
4. **IA** – Inteligência Artificial
5. **FAO** – *Food and Agriculture Organization* (Organização das Nações Unidas para a Alimentação e Agricultura)
6. **EMBRAPA** – Empresa Brasileira de Pesquisa Agropecuária
7. **DAIA** – Drone Agrônomo com Inteligência Artificial
8. **PDF** – *Portable Document Format*
9. **SMS** – *Short Message Service*
10. **VANT** – Veículo Aéreo Não Tripulado
11. **RCASS** – *Remote Control Aerial Spraying System* (Sistema de Pulverização Aérea por Controle Remoto)
12. **SEBRAE** – Serviço Brasileiro de Apoio às Micro e Pequenas Empresas
13. **DJI** – Da-Jiang *Innovations* (nome da empresa fabricante de drones)
14. **CBT** – Companhia Brasileira de Tratores
15. **CTA** – Centro Técnico Aeroespacial
16. **BQM-1BR** – Nome de modelo de VANT brasileiro (não é uma sigla expandida, mas um código de identificação técnica)
17. **RGB** – *Red, Green, Blue* (Padrão de cores aditivas utilizado em sensores de imagem)
18. **BGR** – *Blue, Green, Red* (Padrão inverso de cores aditivas utilizado em sensores de imagem)
19. **ANAC** – Agência Nacional de Aviação Civil
20. **SISANT** – Sistema de Aeronaves Não Tripuladas (Sistema da ANAC para registro de drones)
21. **GOV.BR** – Governo do Brasil (portal oficial)
22. **ML** – *Machine Learning*
23. **SDK** – *Software Development Kit*
24. **UDP** – *User Datagram Protocol*

SUMÁRIO

1. INTRODUÇÃO	14
1.1 MOTIVAÇÃO E JUSTIFICATIVA	15
1.2 OBJETIVO GERAL	15
1.2.1 OBJETIVOS ESPECÍFICOS	16
1.3 ESTRUTURA DO DOCUMENTO	16
2. FUNDAMENTAÇÃO TEÓRICA.....	17
2.1 HISTÓRICO E EVOLUÇÃO DOS DRONES NA AGRICULTURA	17
2.2 HISTÓRICO DO DRONE AGRÍCOLA NO BRASIL.....	18
2.3 TIPOS DE DRONE	19
2.3.1 ESTRUTURA	19
2.3.2 UTILIZAÇÃO	20
2.3.3 MODELOS DE DRONE AGRÍCOLAS	20
2.4 INTELIGÊNCIA ARTIFICIAL	21
2.4.1 USO DA IA NA AGRICULTURA DIGITAL	21
2.4.2 APRENDIZADO DE MÁQUINA (MACHINE LEARNING).....	22
2.4.3 REDES NEURAIS ARTIFICIAIS	22
2.4.4 YOLO: VISÃO COMPUTACIONAL E ARQUITETURA.....	23
2.5 COMO AS PRAGAS AFETAM A AGRICULTURA	25
2.5.1 AS 10 PRINCIPAIS PRAGAS NA AGRICULTURA BRASILEIRA	26
3. DESENVOLVIMENTO DO PROJETO.....	27
3.1 PROGRAMAÇÃO	28
3.1.1 COMPONENTES VISUAIS E FUNCIONAIS DA APLICAÇÃO .	29
3.1.2 COMUNICAÇÃO DRONE (SDK) E PROGRAMAÇÃO	32
3.2 COLETA DAS IMAGENS	33
3.3 PREPARAÇÃO DO DATASET.....	34

3.4	TREINAMENTO DO MODELO YOLOV8	37
3.5	TESTES E VALIDAÇÃO.....	37
3.6	MATERIAS E MÉTODOS	39
3.6.1	MATERIAIS.....	39
3.6.1.1	<i>MATERIAIS FÍSICOS</i>	39
3.6.1.2	<i>FERRAMENTAS DIGITAIS</i>	40
3.7	MÉTODOS.....	41
3.7.1	COLETA E PREPARAÇÃO DAS IMAGENS	41
3.7.2	ROTULAGEM MANUAL	41
3.7.3	TREINAMENTO DO MODELO	41
3.7.4	IMPLEMENTAÇÃO E TESTES DO SISTEMA	41
3.8	RESULTADOS E DISCUSSÕES.....	42
4.	CONCLUSÕES.....	44
5.	REFERÊNCIAS	45

1. INTRODUÇÃO

A agricultura é um dos amparos vitais que compõe a economia brasileira e do mundo, tendo efeitos significativos avante a produção de alimentos, se responsabilizando pelo desenvolvimento de mão de obra e renda. Segundo dados do Cepea em parceria com a CNA, o “número de pessoas trabalhando no agronegócio somou 28,34 milhões em 2023”, o que representa 26,8% do total de ocupações no Brasil (CEPEA, 2024). Mediante estes dados vale ressaltar que o agronegócio representou, no Brasil, uma média de 24,78% do PIB nos últimos cinco anos (2020–2024), sendo o ramo agrícola responsável por 71,74% desse valor, o que corresponde a 17,8% do PIB nacional, conforme cálculos na Figura 1, com base nos dados fornecidos pelo CEPEA (s.d.).

Segundo ZHAI et al. (2020) foi demonstrado que a utilização de tecnologias pertencentes a indústria 4.0 como Internet das Coisas, Big Data, Inteligência Artificial, Computação em Nuvem, Sensores Remotos etc. na área agrícola é de suma importância para revolução da agroindústria, levando o mundo para o cenário da agricultura 4.0, trazendo efeitos como uma produção eficiente, qualidade, diminuição de impactos ambientais, redução do uso de recursos básicos, ponto de vista preditivo para uma agricultura de precisão. Um dos dispositivos mais utilizados nas práticas agrícolas são os drones, com função de mapeamento e ou pulverização, adaptados com inteligência artificial esses dispositivos trazem eficiência, facilidade e autonomia, aumentando a produtividade das lavouras.

A agricultura digital, está ajudando a combater perdas nas lavouras, que resulta em 40% da produção agrícola anualmente segundo FAO (2021), sistemas utilizam imagens de satélites para ver áreas afetadas por pragas, Segundo AHMED et al. (2024) tratar pragas de maneira adequada faz com que aumente sua proliferação, fazendo com que campos inteiros sejam destruídos. Segundo o pesquisador Antônio Gerage, o monitoramento das lavouras é essencial para determinar o momento ideal de aplicação de defensivos agrícolas, maximizando sua eficiência (EMBRAPA, 2012).

Como parte deste trabalho, ele propõe o desenvolvimento do DAIA (Drone Agrônomo com Inteligência Artificial) um protótipo funcional que realizará detecção precoce de pragas em plantações por meio de visão computacional, o projeto prevê o uso de um drone de modelo TELLO, responsável por capturar imagens e enviá-las para um computador para o processamento de dados através de inteligência artificial, gerando assim relatórios para embasar a tomada de decisão.

1.1 MOTIVAÇÃO E JUSTIFICATIVA

Com base nas pesquisas realizadas, foi identificada uma deficiência significativa na detecção precoce de problemas fitossanitários, como pragas e doenças foliares. Atualmente, esse monitoramento é feito, em grande parte, de forma manual ou com o apoio de tecnologias como satélites e drones, porém muitas vezes sem a precisão e frequência necessárias para antecipar infestações. Essa limitação contribui para grandes perdas na produção agrícola, o que é especialmente preocupante diante do aumento contínuo da demanda global por alimentos.

O objetivo da tecnologia na agricultura é proporcionar praticidade e facilidade nas operações, demandando a qualificação de consultores agrícolas e produtores rurais para acompanhar as inovações, possibilitando análise categórica quanto ao tratamento de cada planta recorrendo ao mínimo dos recursos disponíveis (EOS DATA ANALYTICS, 2022). Segundo Yahya (2018) as novas tecnologias são capazes de aumentar os rendimentos, reduzir custos e danos nas plantações fomentando a tese de que a adoção de novas tecnologias também gera aumento de competitividade. Complementando essa realidade, uma pesquisa realizada pela Embrapa, Sebrae e INPE (Santim, 2020) identificou que 84,1% dos agricultores no Brasil já empregam ao menos uma tecnologia digital em seus processos produtivos, e 66,1% das finalidades destinadas a obtenção de informações do processo.

A agricultura de precisão faz uso de métodos computacionais de alto desempenho, comunicação máquina para máquina, métodos e soluções analíticas que processam um grande volume de dados a fim de ponderar a tomada de decisões. Por isso a agricultura 4.0 representa uma união dessas tecnologias digitais impulsionando a agricultura de precisão (TOTVS, 2024).

Nesse cenário, a aplicação de drones com sistemas automatizados e inteligência artificial surge como uma alternativa promissora, capaz de melhorar o controle fitossanitário, otimizar o uso de insumos agrícolas e promover maior sustentabilidade no campo (DUTTA; GOSWAMI, 2020).

1.2 OBJETIVO GERAL

O projeto DAIA tem como meta central criar um sistema de monitoramento agrônômico através de um drone (modelo TELLO). O equipamento possui câmera que envia imagens para um computador, que seja capaz de capturar, processar e analisar imagens em tempo real para identificar precocemente a presença de pragas nas lavouras. Esse processo não apenas gera relatórios automáticos e detalhados, mas também orienta o uso criterioso de

defensivos e insumos, promovendo ganhos de produtividade e sustentabilidade na agricultura de precisão.

1.2.1 OBJETIVOS ESPECÍFICOS

Desenvolver o modelo de detecção de pragas: Treinar uma rede neural YOLOv8 para reconhecer as principais pragas que afetam culturas como café e cana-de-açúcar, visando excelência de acurácia ($> 95\%$) na classificação.

Automatizar a geração de relatórios: Criar um módulo de software capaz de compilar os resultados das detecções em relatórios PDF, com sugestões de manejo integrado de pragas.

Facilitar a tomada de decisão: Acoplar algum meio de aviso seja por Email, *pop-up* ou SMS, para alertar em tempo real e estatísticas de infestação, permitindo ao produtor planejar intervenções de forma estratégica.

1.3 ESTRUTURA DO DOCUMENTO

Este trabalho está organizado em quatro capítulos principais. No Capítulo 1, apresenta-se a introdução ao tema, contemplando a motivação, os objetivos gerais e específicos, bem como a justificativa para o desenvolvimento do projeto. O Capítulo 2 reúne a fundamentação teórica necessária para embasar o estudo, abordando a evolução dos drones na agricultura, inteligência artificial, redes neurais, o modelo YOLO e aspectos relacionados às pragas agrícolas.

O Capítulo 3 descreve de forma detalhada o desenvolvimento do projeto, incluindo a programação da aplicação, o processo de coleta e preparação das imagens, a construção do dataset, o treinamento do modelo YOLOv8, além de apresentar os materiais utilizados e os métodos adotados. Também são discutidos os testes realizados e os resultados obtidos.

Por fim, o Capítulo 4 apresenta as conclusões do trabalho, destacando as principais contribuições, limitações identificadas e sugestões para trabalhos futuros.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 HISTÓRICO E EVOLUÇÃO DOS DRONES NA AGRICULTURA

A agricultura, como outras áreas, tem buscado tecnologias para aumentar sua eficiência e sustentabilidade. Os drones, também conhecidos como VANTs (Veículos Aéreos Não Tripulados), tiveram sua origem em aplicações militares. O primeiro drone reconhecido foi o *Kettering Bug*, desenvolvido em 1918 durante a Primeira Guerra Mundial, utilizado como torpedo aéreo para ataques a distância (SANTOS, 2022).

A aplicação dos drones na agricultura começou a ganhar força na década de 1980, quando a empresa japonesa Yamaha desenvolveu o primeiro drone agrícola, o modelo R-50. Este drone, com estrutura semelhante a um helicóptero, foi projetado para pulverização de culturas, aliviando o esforço físico dos agricultores e aumentando a precisão na aplicação de defensivos agrícolas (YAMAHA MOTOR, s.d.). O desenvolvimento do R-50 iniciou-se em 1983, atendendo a uma demanda da Associação Japonesa de Aviação Agrícola, ligada ao Ministério da Agricultura, para criar um sistema remoto de pulverização aérea (RCASS). Após superar desafios técnicos relacionados à estabilidade e sistema de rotores, o protótipo foi concluído em 1986 e lançado oficialmente em 1987, com capacidade para carregar até 20 kg de carga útil, sendo o primeiro helicóptero não tripulado destinado à pulverização agrícola (YAMAHA MOTOR, s.d.). O sucesso do R-50 foi significativo no Japão, especialmente em áreas de difícil acesso, como terrenos inclinados e pomares, sendo utilizado em culturas como arroz, cevada, soja e frutas cítricas (YAMAHA MOTOR, s.d.).

Posteriormente, o R-50 evoluiu para modelos mais avançados, como o Yamaha RMAX, lançado em 1997, que trouxe melhorias em eficiência, operação automatizada e facilidade de manuseio, consolidando a presença dos drones na aviação agrícola (YAMAHA MOTOR, s.d.). Atualmente, drones agrícolas são amplamente utilizados mundialmente, integrando tecnologias como GPS, sensores multiespectrais e inteligência artificial para monitoramento de culturas, mapeamento e aplicação precisa de insumos, revolucionando a agricultura de precisão (SEBRAE, 2024). Além disso, drones modernos possuem maior autonomia e capacidade de carga, como o DJI Agras T100, que pode pulverizar até 75 litros por voo, e sistemas de voo em enxame que coordenam múltiplos drones simultaneamente para otimizar tempo e recursos. A integração com IA permite que os drones analisem dados em tempo real e tomem decisões autônomas, aumentando a eficiência das operações (SEBRAE, 2024; SANTOS, 2022).

2.2 HISTÓRICO DO DRONE AGRÍCOLA NO BRASIL

No Brasil, a trajetória dos drones agrícolas iniciou-se em contexto militar, com a Companhia Brasileira de Tratores (CBT) e o Centro Técnico Aeroespacial (CTA) desenvolvendo em 1982/83, o BQM-1BR — o primeiro VANT fabricado no país, inicialmente para vigilância e operações militares, mas que serviu de base para drones civis (FARMFOR, 2021). A partir dos anos 2000, o CTA e a Embrapa passaram a trabalhar em VANTs de asa fixa para levantamento fotográfico e monitoramento ambiental em áreas agrícolas (ALVES JR., 2015).

A entrada comercial dos drones no Brasil foi marcada em 2010, quando a empresa norte-americana PrecisionHawk iniciou parcerias com cooperativas do Paraná para testar drones equipados com câmeras RGB para mapeamento topográfico, gerando imagens que auxiliavam no monitoramento manual da vegetação (ARPAC DRONES, 2023). A regulamentação da ANAC em 2012, via Sistema SISANT, autorizou operações de drones com até 25 kg, impulsionando o uso em culturas como soja e cana-de-açúcar (ANAC, 2022). Em 2017, o SISANT foi modernizado, e até 2022 mais de 90 mil drones foram registrados, destacando-se a pulverização agrícola (GOV.BR, 2022).

Nos últimos anos, o uso de drones no Brasil cresceu exponencialmente, chegando a mais de 8.000 unidades em operação, com aumento superior a 600% em três anos (TIMESBRASIL, 2025). Modelos como DJI Agras T40 e T50 são utilizados em culturas como café, soja, milho, cana-de-açúcar e arroz, com redução de custos operacionais de até 70% no café em comparação a métodos manuais (AGRO ESTADÃO, 2025). O desenvolvimento nacional também avança, com drones como o P150, equipado com tanque de até 70 litros, capaz de pulverizar até 5 hectares por voo, atendendo grandes propriedades e terrenos difíceis (AGRO ESTADÃO, 2025).

Além dos ganhos econômicos, o uso de drones contribui para a sustentabilidade, promovendo economia de água e redução das emissões de carbono. A capacitação técnica de operadores, incluindo jovens e mulheres, é incentivada por políticas públicas que fortalecem a agricultura de precisão no país (GLOBO RURAL, 2025).

A revolução tecnológica vai além dos drones, com a integração de inteligência artificial e visão computacional para monitoramento automatizado de pragas e deficiências nutricionais. Entre 2022 e 2024, o mercado de drones agrícolas cresceu 375%, com mais de 5.269 unidades operacionais registradas. Algoritmos como o YOLOv8 têm sido fundamentais,

alcançando acurácia superior a 90% na identificação de pragas a partir de imagens multiespectrais (MUNDOGEO, 2025).

2.3 TIPOS DE DRONE

2.3.1 ESTRUTURA

Existem diversos tipos de drones, cada um com uma determinada função. Porém, todos eles se baseiam em um tipo de plataforma, como:

•**Asa rotativa:** Esse tipo de drone funciona como um helicóptero ou multirrotor (com mais de um rotor).

•**Asa fixa:** Esse tipo de drone tem como característica o uso de apenas um rotor e asas fixas, semelhantes às de um avião.

•**Asa híbrida:** Uma mistura das plataformas fixa e rotativa. Esse drone utiliza tanto os recursos de multirrotor quanto de asas fixas.

Abaixo, a figura 1 apresenta as diferenças entre os modelos de asa fixa e rotativa:

Quadro 1 - Diferenças relativas entre plataformas de asa fixa e rotativa

	Drone de asa fixa	Drone de asa rotativa
Projeto	Mais voltado para mapeamento e monitoramento de médias e grandes áreas.	Mapeamento e monitoramento de pequenas áreas, além de inspeção de obras e recursos naturais.
Aplicações mais comuns	Agricultura, mineração, topografia, monitoramento de perímetro (fronteiras), monitoramento da vida selvagem, engenharia, entre outros.	Agricultura, inspeção e fiscalização ambiental, mercado imobiliário, videografia, topografia, emergência, entre outros.
Velocidade de voo	Maior	Menor
Autonomia da bateria	Maior	Menor
Cobertura de área por voo	Maior	Menor
Pilotagem manual	Mais difícil	Mais fácil
Modo de decolagem e pouso	Horizontal	Vertical
Área de decolagem e pouso	Maior	Menor
Modo de orientação das imagens	Vertical	Vertical e oblíqua (panorâmica)

Figura 1. Diferenças relativas entre plataformas de asa fixa e rotativa (Fonte: SENAR et al., 2018)

2.3.2 UTILIZAÇÃO

Entre as diversas finalidades quanto ao uso de drones na agricultura, exemplifica-se:

- **Drones para Mapeamento Aéreo:** Esses drones são ideais para realizar mapeamentos detalhados das propriedades rurais, auxiliando na identificação de falhas no plantio, pragas, doenças e deficiências nutricionais. Os modelos ópticos multiespectrais permitem gerar mapas NDVI e administrar o uso de defensivos agrícolas de forma otimizada.
- **Drones para Irrigação:** Embora o uso direto de drones para irrigação ainda esteja em desenvolvimento, eles já desempenham papel fundamental ao identificar, por meio de sensores hiperespectrais, multiespectrais ou térmicos, áreas que necessitam de maior irrigação. Assim, ajudam o produtor a direcionar o sistema de irrigação de maneira mais eficiente e sustentável.
- **Drones para Pulverização:** Esses drones aplicam insumos agrícolas de forma precisa e ágil, baseando-se em mapeamentos e utilizando sensores de laser e ultrassom. A pulverização por drone é mais econômica e assertiva do que métodos convencionais, sendo uma excelente estratégia para o Manejo Integrado de Pragas.
- **Drones para Georreferenciamento:** Utilizados para mapeamento, captação de imagens e delimitação de áreas, esses drones facilitam o cumprimento de obrigações legais, como o georreferenciamento exigido pelo INCRA. Eles tornam o processo de certificação da propriedade mais ágil e descomplicado.

2.3.3 MODELOS DE DRONE AGRÍCOLAS

A agricultura é um setor multifacetado, composto por diversas atividades como, pulverização, mapeamento, georreferenciamento e irrigação. Por essa razão, os drones destinados aos fins agrícolas são desenvolvidos com diferente propósitos e características técnicas, variando em tamanho, autonomia, capacidade de carga e tipos de sensores. Cada modelo é projetado para atender demandas específicas, o que torna essencial conhecer suas funcionalidades ao escolher o equipamento ideal para determinada cultura ou aplicação no campo. Por exemplo:

- **Agras MG-1:** Octocóptero para pulverização, capaz de transportar até 10 kg de fluidos e cobrir até 4 hectares por voo, sendo até 60 vezes mais rápido que a pulverização manual.

- **Delair UX11 Ag:** Drone de asa fixa para mapeamento, com câmera multiespectral, capaz de voar por 50 minutos a 20 km/h e realizar análises temporais das culturas.
- **Matrice M210 com Zenmuse XT2:** Ideal para imagens térmicas e análises profundas da saúde das plantas, com capacidade de acoplar diferentes sensores.
- **DJI Mavic 2 Pro:** Modelo de baixo custo para monitoramento da saúde das plantas, detectando sinais de doenças ou estresse de forma fácil e econômica.

2.4 INTELIGÊNCIA ARTIFICIAL

2.4.1 USO DA IA NA AGRICULTURA DIGITAL

Segundo Gomes (2024), a agricultura de precisão tem guiado os produtores na tomada de decisões, revolucionando progressivamente o setor, desde o campo até a gestão administrativa, por meio da transferência de dados e da integração M2M (máquina para máquina). Nesse cenário, a utilização da inteligência artificial torna-se essencial, pois permite a análise automatizada da saúde das plantas, da qualidade do solo e das condições climáticas (Tamares, Meira e Amaral, 2020).

O uso combinado da inteligência artificial com drones potencializa a eficiência das operações agrícolas. Como destacam Oliveira et al. (2020), os drones permitem identificar com precisão áreas afetadas por pragas e doenças, otimizando o uso de defensivos agrícolas. Além disso, sistemas avançados podem até mesmo sugerir os pesticidas adequados para o tratamento corretivo.

Considerando que a população mundial está em constante crescimento, é necessário que a produção de alimentos acompanhe essa demanda. A Organização das Nações Unidas para Alimentação e Agricultura (FAO) estima que a produção de alimentos precisará aumentar em até 60% até 2050 para atender ao crescimento populacional (INOVACOOP, 2024). Nesse contexto, a adoção de tecnologias como a inteligência artificial torna-se uma estratégia crucial, impactando positivamente a produtividade e a economia do setor agrícola. Segundo Sampaio (2021), a IA está em constante evolução, contribuindo significativamente para o desenvolvimento de máquinas inteligentes e técnicas modernas de cultivo.

Apesar das vantagens, ainda existem desafios relacionados à adoção da IA no meio rural. Segundo Borba (2022), a falta de infraestrutura básica e as preocupações com a privacidade de dados são barreiras significativas. Como apontam Mageto et al. (2020),

informações agrícolas têm alto valor estratégico, e o risco de acesso indevido, além da concentração dessas tecnologias nas mãos de poucas empresas, pode gerar monopólios e vulnerabilidades na cadeia produtiva.

2.4.2 APRENDIZADO DE MÁQUINA (MACHINE LEARNING)

O aprendizado de máquina, comumente denotado como *machine learning*, é uma das ementas da inteligência artificial onde o objetivo se dá em aprimorar o desempenho de um sistema baseado em experiências vivenciadas pela máquina, não sendo necessário a programação evidente para cada tarefa, pois o computador em questão está sempre aprendendo. De acordo com a IBM (2024), o ML abre oportunidades para que os sistemas computacionais imitem a forma como os seres humanos aprendem, isto é, analisando grande volume de dados. Alpaydin (2020) complementa que tal aprendizagem traz a eficiência computacional como fator determinante em razão deste grande volume de informações, por isso o aprendizado da máquina consiste em executar algoritmos capazes de ajustar parâmetros internos.

2.4.3 REDES NEURAIS ARTIFICIAIS

Compreende-se uma rede neural como um elo que se acopla a outras pequenas unidades tidas como os neurônios artificiais. O termo neurônio é intuitivo ao cérebro humano que possui aproximadamente 86 bilhões de neurônios conectados a outros estabelecendo troca de impulsos elétricos. Assim são as redes neurais artificiais, onde cada unidade recebe e transmite informações ao mesmo tempo (DIDÁTICA TECH, 2024).

As redes neurais artificiais se tratam de subconjuntos dentro da temática de aprendizado de máquina, onde as redes neurais serão projetadas para realizar o reconhecimento de padrões complexos em grandes volumes de dados. Então o modelo recebe os dados, como a imagem de algum objeto e então essa informação passa por camadas mais ocultas, onde diversos cálculos e algoritmos de funções são calculados por meio do erro, resultado obtido e esperado (Ultralytics, 2024). Em razão desse cálculo, a combinação das operações realizadas por cada neurônio se dá na resolução do sistema resolver problemas complexos. A figura 3 evidencia uma rede neural rasa com apenas 1 camada oculta.




Figura 2. Estrutura da uma rede neural rasa. Fonte Didática Tech (2024).

2.4.4 YOLO: VISÃO COMPUTACIONAL E ARQUITETURA

Entre as tecnologias de IA aplicadas, destaca-se o uso de modelos de visão computacional baseados em redes neurais convolucionais, como o YOLO (*You Only Look Once*). Esse modelo permite a detecção em tempo real de objetos em imagens — neste caso, pragas em plantações — com alta velocidade e precisão. A integração do YOLO ao sistema de captação de imagens por drone permite a detecção precoce de infestações, facilitando o monitoramento contínuo e a tomada de decisão baseada em dados (Ultralytics 2024). Por isso, a convergência entre a agricultura e a visão computacional passa por avanços de certa forma notáveis, com aplicação do YOLO cada vez mais promissora, principalmente ao que tange a detecção de doenças (ALIF; HUSSAIN, 2024).

A capacidade de processamento em tempo real, aliada à precisão e à adaptabilidade do YOLO, torna essa família de algoritmos uma solução altamente atrativa para os desafios da agricultura moderna. Estudos como o de Zaji et al. (2023) já demonstram o uso de visão computacional baseada em YOLO para a estimativa de altura de espigas de trigo com câmeras estéreo, indicando o potencial dessas tecnologias mesmo em culturas de alto nível de detalhamento

O YOLO foi introduzido por Joseph Redmon em 2015, com o YOLOv1, marcando um divisor de águas nos métodos de detecção de objetos. Ao contrário dos modelos tradicionais baseados em duas etapas (como o R-CNN), o YOLO realiza a detecção de objetos em tempo real, dividindo a imagem de entrada em uma grade (*grid*) e prevendo simultaneamente as caixas

delimitadoras (*bounding boxes*) e as classes dos objetos. Esse novo paradigma aumentou significativamente a velocidade do processamento, mantendo precisão competitiva — uma característica crucial para aplicações em tempo real, como o uso em drones agrícolas. (Precisa de Citação)

A evolução da arquitetura YOLO, do YOLOv1 ao YOLOv10, introduziu melhorias contínuas em termos de projeto estrutural, estratégias de treinamento e técnicas de otimização, tornando as versões mais recentes capazes de lidar com objetos pequenos, situações de oclusão (obstruções visuais) e *datasets* variados, aspectos frequentemente presentes em imagens agrícolas complexas (ALIF; HUSSAIN, 2024). Sua estrutura arquitetônica é composta por 24 camadas convolucionais, sendo 4 dedicadas ao *max-pooling* atuando como um filtro e reduzindo o tamanho da saída das 2 primeiras camadas como sugere a figura 2, e 2 camadas densamente conectadas. A ideia é que antes do processamento a imagem a ser captada seja redimensionada na primeira camada em 448x448 pixels e em seguida passe pela sequência de convolações para reduzir a matriz e o mapa de características, extraindo o que de fato é relevante (DATACAMP, 2023).




Figura 3. Arquitetura YOLO do artigo original (modificada pelo autor). Fonte: Datacamp 2023.

2.5 COMO AS PRAGAS AFETAM A AGRICULTURA

As pragas agrícolas representam uma das maiores ameaças à produtividade e à sustentabilidade do setor agrícola. Elas podem comprometer até 90% da produção, como aponta um relatório do Sindicato Nacional da Indústria de Produtos para Defesa Vegetal (Sindiveg), que destaca o aumento significativo da ocorrência de pragas em culturas como soja e milho, com perdas que variam entre 30% e 50% em função do ataque de insetos como a mosca-branca (*Bemisia tabaci*) e o percevejo-marrom (*Euschistus heros*) (FOLHA AGRÍCOLA, 2024).

Além disso, a ferrugem asiática da soja, causada pelo fungo *Phakopsora pachyrhizi*, é considerada a doença mais severa enfrentada pela cultura, podendo causar perdas de até 90% se não for controlada adequadamente (FOLHA AGRÍCOLA, 2024). O Centro de Estudos Avançados em Economia Aplicada (CEPEA) reforça que as perdas médias de produtividade devido ao não controle de pragas variam entre 9,5% e 40%, dependendo do tipo de praga e da cultura afetada (CROPLIFE BRASIL, 2024).

Os impactos econômicos dessas perdas são expressivos. Segundo o CEPEA, a falta de controle da ferrugem asiática poderia reduzir a produtividade da soja em 30%, o que demandaria investimentos adicionais superiores a R\$ 30 bilhões para compensar as perdas, além de causar uma queda de 13,9% na receita bruta da cultura e transformar lucros em prejuízos bilionários (CROPLIFE BRASIL, 2024). A lagarta *Helicoverpa armigera*, outra praga de grande impacto, pode reduzir a produtividade em até 40%, afetando culturas como algodão e soja (CROPLIFE BRASIL, 2024).

No Brasil, as perdas anuais causadas por pragas chegam a R\$ 55 bilhões, o que representa cerca de 7,7% da produção agrícola nacional, ou aproximadamente 25 milhões de toneladas de alimentos (AGROLINK, 2015). A introdução de pragas exóticas e quarentenárias também representa uma ameaça crescente, não só para a agricultura, mas para o meio ambiente e comunidades locais, podendo inviabilizar o comércio internacional devido a barreiras fitossanitárias (MYFARM, 2024).

Além das perdas quantitativas, as pragas afetam a qualidade dos produtos agrícolas e elevam os custos de produção, pois exigem maiores gastos com defensivos agrícolas e manejo integrado de pragas (MIP). O uso intensivo de pesticidas, por sua vez, pode causar impactos ambientais e à saúde, tornando o controle eficiente e sustentável um desafio constante (PORTAL MAIS AGRO, 2024).

Portanto, o manejo integrado de pragas, que combina métodos biológicos, culturais e químicos, é fundamental para manter as populações de pragas abaixo do nível de dano econômico e garantir a produtividade e sustentabilidade da agricultura (PORTAL MAIS AGRO, 2024).

2.5.1 AS 10 PRINCIPAIS PRAGAS NA AGRICULTURA BRASILEIRA

A agricultura brasileira enfrenta diversos desafios causados por pragas que comprometem a produtividade e a qualidade das culturas. Segundo levantamento do Ministério da Agricultura, Pecuária e Abastecimento (Mapa) e da Embrapa, as dez pragas com maior risco fitossanitário para o Brasil são:

- ***Amaranthus palmeri***: Espécie exótica de caruru, de crescimento rápido e agressivo, que pode reduzir em até 90% a produtividade de lavouras como soja, milho e algodão. Além disso, apresenta capacidade de cruzar com outras plantas do gênero, transferindo genes resistentes a herbicidas (SUMMIT AGRO, 2022).
- ***Bemisia tabaci* (Mosca-branca)**: Inseto sugador comum em diversas culturas, vetor de vários vírus e causador de fumagina, que dificulta a fotossíntese. É uma praga de difícil controle, com alta capacidade de resistência a inseticidas (AGROSABER, s.d.).
- ***Xanthomonas citri***: Bactéria causadora do cancro cítrico, que provoca lesões em folhas, ramos e frutos, causando queda prematura e prejuízos significativos na citricultura (SUMMIT AGRO, 2022).
- ***Ralstonia solanacearum***: Bactéria que causa murcha bacteriana em culturas como tomate, batata e pimentão, levando à morte das plantas e perdas econômicas (SUMMIT AGRO, 2022).
- ***Anthonomus grandis* (Bicudo-do-algodoeiro)**: Besouro que pode destruir até 70% da safra de algodão, atacando principalmente os botões florais e causando queda das flores (AGROSABER, s.d.).

- ***Phakopsora pachyrhizi* (Ferrugem-asiática-da-soja):** Fungo que causa uma das doenças mais severas da soja, com potencial para perdas de até 90% em condições favoráveis à doença (BLOG AGROINTELI, s.d.).
- ***Helicoverpa armigera* (Lagarta-Helicoverpa):** Lagarta altamente destrutiva, que ataca milho, soja, algodão e outras culturas, preferindo partes reprodutivas das plantas, como flores e vagens (SUMMIT AGRO, 2022).
- ***Spodoptera frugiperda* (Lagarta-do-cartucho):** Praga que ataca principalmente o milho, mas também soja e algodão, alimentando-se das folhas e espigas, causando grandes perdas (SUMMIT AGRO, 2022).
- ***Phyllocnistis citrella* (Minador-dos-citros):** Inseto que causa galerias nas folhas de citros e tomate, reduzindo a capacidade fotossintética e levando à queda das folhas (AGROSABER, s.d.).
- ***Empoasca kraemeri* (Cigarrinha-verde):** Inseto sugador que injeta toxinas nas plantas, atacando feijão, maçã, pepino, batata, soja e algodão, causando prejuízos significativos mesmo em baixas populações (BLOG SENSIX, s.d.).

3. DESENVOLVIMENTO DO PROJETO

Este capítulo explana o desenvolvimento do sistema proposto onde é abordado a conexão geral da interface com o físico, tal como a estrutura geral do projeto contemplando a captação das imagens, montagem do *dataset* contendo registros fotográficos de lagarta-cartucho retirados da *internet*, o uso deste mesmo arsenal para o treinamento da inteligência artificial, associando o drone DJI Tello ao computador para receber comandos e enviar dados de vídeo ao vivo, a fim de realizar análise das imagens através do modelo de visão computacional YOLOv8-*Ultralytics* com base no treinamento efetuado, onde o resultado se sucedido de acordo com a detecção da praga em questão será gerado um relatório em PDF.

3.1 PROGRAMAÇÃO

A programação foi desenvolvida em linguagem Python, na versão 3.11, foi realizado o *download* das bibliotecas *openCV*, *djitellopy*, *reportlab*, *pillow* e *ultralytics*, com os seus respectivos funcionamentos descritos abaixo:

- ***OpenCV***: Biblioteca dedicada a visão computacional.
- ***Djitellopy***: Biblioteca dedicada para acesso às funcionalidades do drone DJI Tello, como controle e recepção de dados.
- ***Reportlab***: Biblioteca dedicada a geração de relatórios em PDF.
- ***Pillow***: Biblioteca dedicada a *bounding-box*.
- ***Ultralytics***: Biblioteca que contempla modelos de IA de visão computacional, como a utilizada YOLOv8.

As bibliotecas *tkinter*, *threading*, *time*, *os*, *math* e *datetime* não foi necessária instalação, pois todas já vêm com o Python.

As etapas do processo de programação do projeto se estruturam nas etapas a seguir:

- 1) Conexão com o Tello executando o *download* da biblioteca *djitellopy*, adicionando os comandos básicos de voo, como subir, descer, frente, trás, esquerda e direita com seu controle através da apresentação visual utilizando a biblioteca *tkinter*.
- 2) Voo do drone com a câmera ligada, adicionado o comando de *stream* de vídeo com a utilização da biblioteca *OpenCV* para exibição do vídeo por meio do comando “câmera” adicionado no controle.
- 3) Implementação da biblioteca *ultralytics* à programação para que assim executasse o YOLO em tempo real, integrando ao arquivo de modelo treinado *best.pt* com sua ativação mediante o comando “ativar YOLO”. Este processo foi possível apenas após a criação do *dataset* e treinamento do modelo YOLOv8 como detalhado na **seção 3.3 “Preparação do dataset”** e **seção 3.4 “Treinamento do Modelo YOLOv8”**.
- 4) Geração dos relatórios em PDF através da biblioteca *reportlab*, onde é criado o arquivo com detalhamento de data e hora, confiabilidade, posição da *bounding-box* e o registro da detecção.
- 5) Aperfeiçoamento dos componentes visuais acrescentados e adição de novos com sua totalidade descrito na seção a seguir.

3.1.1 COMPONENTES VISUAIS E FUNCIONAIS DA APLICAÇÃO

Ao executar o programa é aberto uma interface gráfica, que utiliza a biblioteca tkinter, na mesma são apresentados botões de comando divididos em sessões; conexão e status, direção SDK, avanço/giro (SDK), câmera/cor/YOLO, ajustes de movimento e terminal. Sendo o funcionamento descrito abaixo:

- Conexão e status:
 - **Conectar:** Validar a conexão Wi-Fi do drone com o computador.
 - **Câmera:** Abrir uma janela para câmera.
 - **Bateria:** Verificar o nível de bateria.
 - **Decolar:** Acionar sistema de decolagem.
 - **Pousar:** Acionar sistema de pouso.
 - **Emergência:** Acionar sistema de emergência.



Figura 4. Disposição dos botões de Conexão e Status. Fonte: Autoria própria, 2025




Figura 5. Apresentação da câmera aberta em resposta ao comando “câmera”. Fonte: Autoria própria, 2025.

- **Direção SDK:**
 - **Direção cima:** Acionar direcionamento para cima.
 - **Direção baixo:** Acionar direcionamento para baixo.
 - **Direção esquerda:** Acionar direcionamento para esquerda.
 - **Direção direita:** Acionar direcionamento para direita.



Figura 6. Disposição dos botões de direção do drone na interface gráfica. Fonte: Autoria própria, 2025.

- **Avanço/giro (SDK):**
 - **Frente:** Acionar botão de avanço para frente.
 - **Trás:** Aciona o movimento de recuo para trás.
 - **Giro lado esquerda:** Deslocar o drone para esquerda.
 - **Giro lado direita:** Deslocar o drone para direita.



Figura 7. Disposição dos botões de deslocamento do drone na interface gráfica. Fonte: Autoria própria, 2025.

- **Câmera / Cor / YOLO:**
 - **Câmera (On/voando):** Interligar comandos decolar com câmera.
 - **Fechar câmera:** Fechar modo visualização de câmera.
 - **Modo de cor:** Alterar modos de cor entre *RGB (Red Green Blue)*, *BGR (Blue Green Red)* e automático.
 - **Ativar YOLO:** Ativar sistema detecção de pragas.




Figura 8. Disposição dos botões referentes a câmera/cor/YOLO. Fonte: Autoria própria, 2025.

- Ajuste de movimento:
 - **Passo(cm):** Ajustar distancia de movimento (funções: Direção SDK, Avanço/giro (SDK)).
 - **Velocidade(cm/s):** Ajustar velocidade escalar.




Figura 9. Disposição dos botões de tipo *sliders* referentes ao ajuste de movimento.

Fonte: Autoria própria, 2025

- Terminal: Apresentação dos resultados referente aos comandos descritos acima.



Figura 10. Tela de apresentação dos resultados no terminal da interface gráfica. Fonte:

Autoria própria, 2025.




Figura 11. Interface de controle do drone. Fonte: Autoria própria, 2025.

3.1.2 COMUNICAÇÃO DRONE (SDK) E PROGRAMAÇÃO

A comunicação entre o sistema desenvolvido e o drone DJI Tello ocorre por meio do Tello SDK, um conjunto de comandos baseados em texto enviados via protocolo UDP (*User Datagram Protocol*), permitindo o controle de voo, o acesso aos sensores e o recebimento do fluxo de vídeo. O SDK opera simultaneamente em diferentes portas da rede Wi-Fi criada pelo próprio equipamento, organizadas da seguinte forma:

- **UDP 8889:** envio de comandos de controle (movimentos, decolagem, pouso, giros);
- **UDP 8890:** telemetria (altura, status dos motores, bateria e orientação);
- **UDP 11111:** streaming de vídeo em formato H.264.

No sistema implementado, a biblioteca `djitellopy` foi utilizada como camada intermediária, abstraindo a comunicação UDP e convertendo os comandos do SDK em funções Python. Essa camada simplifica o uso do drone, permitindo que instruções como `takeoff`, `land`, `move_forward` ou `rotate_clockwise` sejam executadas de forma mais segura e estruturada, permanecendo compatíveis com o protocolo definido pela DJI.

Devido à natureza do protocolo do Tello, um dos problemas mais frequentes durante o uso do SDK é a sobrecarga de comandos, que ocorre quando instruções são enviadas antes da finalização da anterior. Para evitar esse problema, o sistema adota uma estratégia de bloqueio temporário (mutex), representado pelo objeto `cmd_lock`. Sempre que um comando é enviado, o bloqueio impede que novas instruções sejam transmitidas simultaneamente. Além disso, foi implementado um sistema de cooldown que impõe um intervalo mínimo entre manobras, reduzindo a ocorrência de erros como “*Not joystick*”, perda de estabilidade ou rejeição de comandos pelo drone.

Cada comando é processado em threads independentes, garantindo que a interface gráfica permaneça responsiva e que o operador mantenha controle imediato sobre o equipamento. Comandos críticos, como decolagem, pouso e emergência, recebem tratamento isolado para evitar conflitos com processos de longa duração.

O streaming de vídeo é ativado pelo comando `streamon` e lido continuamente por meio da função `get_frame_read()`. O sistema converte o fluxo H.264 para matrizes manipuláveis pelo OpenCV, aplicando correções de brilho e cor antes da exibição. Esses mesmos quadros servem como entrada para o modelo de detecção YOLO quando a funcionalidade de visão computacional está ativa.

Contudo, devido às limitações estruturais do Tello, foi necessário implementar um mecanismo de suspensão automática do YOLO durante manobras. Embora a inferência ocorra no computador e não no drone, o processamento do vídeo gera atrasos na decodificação dos quadros, aumento de latência e congestionamento do buffer de comunicação. Como o Tello não aceita novos comandos enquanto aguarda confirmações internas nem tolera atrasos superiores a alguns milissegundos, qualquer sobrecarga causada pelo processo de visão computacional pode levar à rejeição de comandos, travamentos ou até pouso automático por segurança. Assim, o sistema prioriza o controle de voo, pausando temporariamente a detecção durante a execução de comandos críticos e retomando-a somente quando o drone encontra-se em estado estável.

Além disso, para evitar competição entre processamento de vídeo, comandos de controle e comunicação UDP, a detecção é executada apenas a cada N quadros, garantindo que o fluxo do SDK não seja impactado. Essa abordagem equilibra segurança, desempenho e responsividade, permitindo que o drone seja controlado com precisão ao mesmo tempo em que realiza detecção da praga lagarta-cartucho em tempo real.

3.2 COLETA DAS IMAGENS

Para execução da atividade de coleta de imagens foi realizado um estudo de viabilidade, considerando as limitações de banco de dados e resolução da câmera do drone, sendo assim foi escolhida a lagarta-cartucho como praga a ser identificada, pois há uma maior abrangência de dados, comparados a outras pragas do ramo agrícola e por sua relevância-, “A lagarta-do-cartucho *Spodoptera frugiperda* (Smith) (Lepidoptera: Noctuidae) é considerada uma praga-chave da cultura do milho em praticamente todas as áreas produtoras do País” (MOREIRA; ARAGÃO, 2009; CRUZ et al., 2010; TEODORO et al., 2013, p. 1).

As imagens foram coletadas na internet com o uso da ferramenta Google Imagens e do site biodiversity4all, ao todo 119 imagens foram coletadas, para que fosse possível gerar um *dataset* de qualidade.




Figura 12. Estrutura das imagens a serem coletadas pela câmera do drone. Fonte: Autoria própria 2025.

3.3 PREPARAÇÃO DO DATASET

O *dataset* na aplicação deste projeto trata-se de uma coletânea de dados organizados e divididos, para o treinamento de uma IA, seu processo de formação é uma pasta com o nome *dataset*, que contém dentro outras duas pastas sendo elas *images* e *labels*, em ambas contemplam outras 3 pastas sendo *test*, *train* e *val*. Com as pastas montadas, foi renomeado o nome das 119 imagens através de um comando do *PowerShell* para melhor organização, com isso obtivemos um padrão conforme a Figura 8.




Figura 13. Padrão de nomenclatura das imagens que compõe o *dataset*. Fonte: Autoria própria, 2025

Após a coleta e padronização das imagens escolhidas foram encaminhadas à plataforma *Make sense*, onde a anotação manual foi realizada. Cada ocorrência da praga nas imagens foi marcada com *bounding boxes*, da cor vermelha, com o rótulo “lagarta_cartucho”,

ver Figura 9, depois foi exportado as posições dos *bounding boxes* de cada imagem em forma de arquivo “.txt” um dedicado a cada imagem em uma pasta zip, conforme o padrão exigido pelo modelo YOLO.




Figura 14. Classificação do objeto de detecção através da *bounding-box* (em vermelho). Fonte: Autoria própria, 2025.

Com a totalidade de dados coletados, imagens e posições dos rótulos, é feito a divisão para as 3 últimas pastas, neste projeto foi dividido na proporção de 80% para *train*, 10% para *val* e 10% para *test*, onde o caminho *images* destina apenas as imagens, e o caminho *labels* os arquivos “.txt”. Os mesmos nomes que estiverem em uma pasta devem estar em outra, após a segregação por completo, portanto cria-se um arquivo pelo bloco de notas denominado “data”, salvo em .yaml, dentro da pasta *dataset*. A pasta estrutura-se de acordo com o exemplo abaixo:

EXEMPLO:

```
dataset/
  images/
    train/
      Lagarta_Cartucho_001.jpg
      Lagarta_Cartucho_002.jpeg
      ...
    val/
      Lagarta_Cartucho_096.jpg
      Lagarta_Cartucho_097.jpeg
```

```

...
test/
    Lagarta_Cartucho_108.jpg
    Lagarta_Cartucho_109.jpeg
...
labels/
train/
    Lagarta_Cartucho_001.txt
    Lagarta_Cartucho_002.txt
...
val/
    Lagarta_Cartucho_096.txt
    Lagarta_Cartucho_097.txt
...
test/
    Lagarta_Cartucho_108.txt
    Lagarta_Cartucho_109.txt
...

data.yaml

```

o arquivo *data.yaml* contém o seguinte código:

```

train: dataset/images/train
val: dataset/images/val
test: dataset/images/test

nc: 1
names: ['lagarta_cartucho']

```

Completos todos estes processos, a pasta foi compactada em .ZIP, resultando na “dataset.zip”.

3.4 TREINAMENTO DO MODELO YOLOV8

Concluído o *dataset*, é dado início ao treinamento do modelo de inteligência artificial, utilizando do Google Colab, grande facilitador para o processo de instalação e execução das bibliotecas.

Com a abertura de um Notebook no Google Colab, é alterado o ambiente de execução para o GPU's T4, fazendo com que o processamento seja mais rápido, em seguida o *dataset.zip* foi importado a plataforma, e descompactado através do comando:

```
!unzip dataset.zip
```

Logo após é necessário mover o arquivo *data.yaml* para a área externa a pasta *dataset*, em seguida executar o seguinte código:

```
from ultralytics import YOLO
model = YOLO("yolov8l.pt")
model.train(
    data="data.yaml",
    epochs=200,
    imgsz=640,
    batch=4,
    optimizer="AdamW",
    patience=50
)
```

Para execução do código foi definida a regra do treinamento de acordo com o seu tamanho. Utilizamos 200 épocas (*epochs*), o que de fato representa um número relativamente alto para *datasets* pequenos, mas em razão da variedade visual do conjunto de imagens e suas limitações, este número garante o aprendizado adequado quanto a característica do alvo.

3.5 TESTES E VALIDAÇÃO

Durante a etapa de testes, foram utilizadas imagens impressas da lagarta-do-cartucho com o objetivo de simular condições práticas de uso e avaliar a precisão do sistema em cenários reais. Essas imagens foram apresentadas diretamente à câmera do sistema, visando observar o

comportamento do modelo diante de variações como textura do papel, iluminação do ambiente e distância de captura.

Nos testes realizados, o modelo demonstrou capacidade satisfatória de reconhecer a lagarta-do-cartucho em diversas situações. Entretanto, também foram observados casos de detecções incorretas. Em algumas ocasiões, objetos visualmente semelhantes, como dedos posicionados próximos à imagem impressa, foram identificados pelo sistema como possíveis pragas. Esse comportamento evidencia que o modelo ainda pode confundir padrões alongados ou com tonalidades próximas às encontradas nas imagens utilizadas no treinamento.

Esses resultados reforçam a importância de ampliar o conjunto de dados utilizado no treinamento, priorizando imagens capturadas em ambientes reais, com diferentes condições de iluminação, texturas e contextos naturais. Apesar das limitações observadas, o sistema apresentou resultados consistentes dentro das condições de teste aplicadas, validando sua funcionalidade inicial e demonstrando potencial para aprimoramentos futuros.

Relatório de Detecção - lagarta_cartucho

Data/Hora: 2025-11-21 12:20:58

Confiança: 0.8865

Bounding box: 457, 178, 702, 288




Figura 15. Print PDF Relatório de detecção. Fonte: Autoria própria, 2025.

3.6 MATERIAS E MÉTODOS

Para o desenvolvimento deste trabalho, foram utilizados materiais físicos e ferramentas digitais que permitiram a coleta de imagens, a criação do conjunto de dados (dataset), o treinamento do modelo de detecção e a implementação do sistema de reconhecimento embarcado.

3.6.1 MATERIAIS

3.6.1.1 MATERIAIS FÍSICOS

- **Drone DJI Tello** – Utilizado para a captura aérea das imagens das plantas, possibilitando a visualização aproximada de folhas, caules e possíveis sinais de pragas, devido a seu tamanho pequeno e seu sistema aberto a comandos via programação.
 - **Especificações:** Aeronave (Modelo: TLW004)
 - **Tamanho:** 9,8 x 9,2 x 4,1 cm
 - **Massa Máxima de Decolagem (MTOM):** 87g
 - **Velocidade Máxima:** 17,8 mph (28,8 km/h)
 - **Tempo Máximo de Voo:** 13 minutos (0 vento a uma velocidade constante de 9 mph (15 km/h))
 - **Faixa de Temperatura Operacional:** 32° a 104° F (0° a 40° C)
 - **Faixa de Frequência Operacional:** 2,4 a 2,4835 GHz
 - **Transmissor (EIRP):**
 - 20dBm (FCC)
 - 19dBm (CE)
 - 19dBm (SRRC)
 - **Câmera:**
 - **Tamanho Máximo da Imagem:** 2592x1936
 - **Modos de Gravação de Vídeo:** HD/1280x720 30p
 - **Formato de Vídeo:** MP4
 - **Bateria de Voo:**
 - **Capacidade:** 1100 mAh
 - **Tensão (Voltagem):** 3,8 V
 - **Tipo de Bateria:** LiPo
 - **Energia:** 4,18 Wh

- **Peso Líquido:** 25 ± 2 g
- **Faixa de Temperatura de Carregamento:** 41° a 113° F (5° a 45° C)
- **Potência Máxima de Carregamento:** 10 W



Figura 16. Modelo DJI Tello Boost. Fonte: Autoria própria, 2025.

- **Notebook / Computador com Wi-Fi** – Empregado para o processamento das imagens, desenvolvimento da aplicação, organização do dataset, treinamento do modelo e execução do software de controle e detecção.

3.6.1.2 FERRAMENTAS DIGITAIS

- **Python 3** – Linguagem utilizada para o desenvolvimento de todo o sistema, incluindo o controle do drone, pré-processamento de imagens, execução do modelo e geração automática de relatórios.
- **MakeSense.ai** – Plataforma utilizada para a anotação manual das imagens, delimitando regiões contendo pragas e folhas saudáveis, gerando os arquivos de rotulagem no formato YOLO.
- **Google Colab** – Ambiente em nuvem utilizado para o treinamento do modelo de detecção YOLO, permitindo maior poder computacional e aceleração do processo de aprendizagem.
- **Google Imagens** – Fonte complementar de imagens para composição do dataset, especialmente em situações onde não foi possível capturar exemplos reais de pragas diretamente com o drone.

- **Biodiversity4All**– Repositório online utilizado para consulta e obtenção de imagens confiáveis de espécies e pragas, contribuindo para a diversidade e qualidade das amostras.

3.7 MÉTODOS

3.7.1 COLETA E PREPARAÇÃO DAS IMAGENS

Devido às limitações enfrentadas na captura por drone, todas as imagens utilizadas neste estudo foram obtidas na internet, por meio do Google Imagens e do portal Biodiversity4All. Foram selecionadas imagens contendo a lagarta-do-cartucho em diferentes estágios e condições, bem como imagens de folhas saudáveis para compor a classe negativa.

Após a coleta, as imagens foram padronizadas quanto ao formato e à resolução, garantindo maior credibilidade durante o treinamento.

3.7.2 ROTULAGEM MANUAL

A etapa de anotação foi realizada utilizando o MakeSense.ai. Cada ocorrência da lagarta-do-cartucho foi identificada manualmente com caixas delimitadoras (*bounding boxes*), permitindo ao modelo aprender a localização e o padrão visual da praga. As anotações foram exportadas no formato YOLO, amplamente compatível com modelos de detecção atuais.

3.7.3 TREINAMENTO DO MODELO

O treinamento do modelo YOLOv8 foi realizado no Google Colab, utilizando o *dataset* previamente anotado. Foram definidos parâmetros como número de épocas, taxa de aprendizado e divisão entre conjuntos de treino, validação e teste. O processo foi executado iterativamente, buscando otimizar o desempenho do modelo por meio da análise dos gráficos de perda (*loss*) e métricas de precisão.

3.7.4 IMPLEMENTAÇÃO E TESTES DO SISTEMA

Após o treinamento, o modelo final foi integrado ao sistema desenvolvido em Python, possibilitando a detecção da lagarta-do-cartucho em tempo real e a geração automática de relatórios. O sistema permite a exibição contínua de quadros processados, aplicação de filtros de estabilidade para evitar múltiplos relatórios da mesma detecção e o registro ordenado de evidências com data e hora.

Como não foram utilizadas imagens capturadas via drone, os testes foram realizados exclusivamente com imagens online e fotografias coletadas manualmente para validação do sistema.

3.8 RESULTADOS E DISCUSSÕES

A etapa de resultados permitiu avaliar o desempenho do sistema de detecção baseado no modelo YOLOv8, considerando tanto sua precisão quanto suas limitações práticas. Durante os testes, foram utilizadas imagens impressas da lagarta-do-cartucho com o objetivo de simular cenários próximos às condições reais de uso, bem como fotografias adicionais obtidas manualmente. Essa abordagem possibilitou observar o comportamento do modelo diante de diferentes variações de iluminação, textura, distância e enquadramento.

As respostas demonstraram que o modelo apresentou desempenho satisfatório ao identificar a lagarta-do-cartucho em grande parte das situações testadas. Em diversos casos, a rede neural reconheceu corretamente a praga mesmo em imagens com baixa resolução, leve desfoque ou pequenas variações de cor, evidenciando que o treinamento, ainda que realizado com um dataset limitado, forneceu um nível inicial de aprendizado consistente.

Entretanto, também foram identificadas ocorrências de falsos positivos, sobretudo quando elementos visuais com formato alongado ou coloração semelhante aos padrões presentes no dataset eram posicionados próximos à imagem. Em alguns testes realizados com imagens impressas, por exemplo, dedos segurando a folha foram interpretados como possíveis pragas, revelando que o modelo ainda apresenta dificuldade em diferenciar objetos que compartilham características geométricas básicas com a lagarta-do-cartucho. Esse comportamento já era esperado, considerando que o conjunto de dados foi construído em sua grande maioria a partir de imagens obtidas na internet, sem grande diversidade de cenários reais.

Outro ponto observado foi a sensibilidade do modelo à iluminação ambiente. Em situações com sombras mais intensas ou luz excessivamente difusa, houve variações nos níveis de confiança das detecções, o que reforça a necessidade de ampliar o dataset com imagens capturadas diretamente pelo drone, contemplando diferentes horários do dia, distâncias e condições climáticas.

Apesar das limitações encontradas, os testes validaram a funcionalidade geral do sistema. O modelo se mostrou capaz de realizar detecções em tempo real, integrar-se à interface de controle do drone e gerar relatórios automáticos conforme previsto no escopo do projeto. Os

resultados indicam que, com a expansão gradual do dataset, especialmente com imagens reais de campo, o sistema tende a evoluir significativamente em precisão e robustez, tornando-se uma ferramenta mais confiável para apoio ao monitoramento agrônômico.

4. CONCLUSÕES

O desenvolvimento do DAIA – Drone Agrônomo com Inteligência Artificial – demonstrou a viabilidade de integrar sistemas de visão computacional a drones de baixo custo para o monitoramento de pragas na agricultura. A motivação partiu das grandes perdas causadas por insetos e doenças nas lavouras, situação agravada pela dificuldade de detecção precoce. Para enfrentar esse desafio, projetou-se uma solução capaz de capturar imagens, processá-las em tempo real com a rede neural YOLOv8 e gerar relatórios para apoiar a tomada de decisão do produtor.

O projeto envolveu a criação de um *dataset* específico com imagens da lagarta-do-cartucho, a preparação e rotulação dessas imagens, o treinamento do modelo em ambiente de nuvem e a integração do algoritmo com o drone DJI Tello. Os testes indicaram que, mesmo com um conjunto de dados limitado, o sistema conseguiu detectar a praga em diversas condições de iluminação e enquadramento, embora ainda apresente falsos positivos e seja sensível a objetos semelhantes ao inseto. Esse resultado revela o potencial da solução, mas evidencia a necessidade de expandir e diversificar o banco de imagens e de realizar ensaios em campo para calibrar o modelo em situações reais.

A principal contribuição deste trabalho foi entregar uma prova de conceito funcional que combina hardware acessível e inteligência artificial para vigilância agrícola. Além disso, delineou-se uma metodologia de construção e anotação de bases de dados e de treinamento de modelos de detecção que pode ser reaplicada para outras pragas ou culturas. Para prosseguir, recomenda-se ampliar o *dataset* com imagens capturadas diretamente no ambiente de produção, testar câmeras de maior resolução ou sensores multispectrais, investigar arquiteturas mais recentes de redes neurais e aprimorar a autonomia do voo. Com esses avanços, espera-se que o DAIA se torne uma ferramenta robusta para reduzir perdas, otimizar o uso de insumos e promover a sustentabilidade no campo.

5. REFERÊNCIAS

1. AGRO ESTADÃO. *Agrishow 2025 terá maior drone de pulverização do Brasil*. 2025. Disponível em: <https://agro.estadao.com.br/agrishow-2025/agrishow-2025-tera-maior-drone-de-pulverizacao-do-brasil>. Acesso em: 11 jun. 2025.
2. AGROLINK. *Pragas causam perdas de até R\$ 55 bilhões à agricultura no Brasil*. 2015. Disponível em: https://www.agrolink.com.br/noticias/pragas-causam-perdas-de-ate-r-55-bilhoes-a-agricultura-no-brasil_220429.html. Acesso em: 11 jun. 2025.
3. AGROSABER. *Pragas agrícolas no Brasil*. Disponível em: <https://agrosaber.com.br/pragas-agricolas-no-brasil/>. Acesso em: 11 jun. 2025.
4. AHMED, Salman et al. *IoT based intelligent pest management system for precision agriculture*. Scientific Reports, v. 14, n. 31917, 2024. Disponível em: <https://doi.org/10.1038/s41598-024-83012-3>. Acesso em: 23 abr. 2025.
5. ALIF, Mujadded Al Rabbani; HUSSAIN, Muhammad. *YOLOv1 to YOLOv10: A comprehensive review of YOLO variants and their application in the agricultural domain*. Huddersfield University, 2024. Disponível em: <https://arxiv.org/abs/2406.10139>. Acesso em: 11 jun. 2025.
6. ALVES JR., Carlos. *Uso de VANTs para monitoramento agrícola*. Embrapa, 2015. Disponível em: <https://www.infoteca.cnptia.embrapa.br/bitstream/doc/1003261/1/cpamt2014shozodrones.pdf>. Acesso em: 11 jun. 2025.
7. ANAC. *Sistema de Aeronaves Não Tripuladas (SISANT)*. 2022. Disponível em: <https://www.anac.gov.br/sisant>. Acesso em: 11 jun. 2025.
8. ARPAC DRONES. *Drones agrícolas: como surgiram?* 2023. Disponível em: <https://arpacdrones.com.br/2023/01/12/drones-agricolas-como-surgiram/>. Acesso em: 11 jun. 2025.
9. YAHYA, N. *Agricultural 4.0: Its implementation toward future sustainability*. Green Energy and Technology, [S. l.], n. 9789811075773, p. 125–145, 2018. Disponível em: https://doi.org/10.1007/978-981-10-7578-0_5. Acesso em: 10 de jun. de 2025.

10. EOS DATA ANALYTICS. A importância da tecnologia na agricultura. 2022. Disponível em: <https://eos.com/pt/blog/tecnologia-na-agricultura/>. Acesso em: 10 jun. 2025.
11. SANTIN, W. O campo em tempo real. Globo Rural, n. 418, p. 14-19, ago. 2020.
12. BLOG AGROINTELI. *As 6 principais pragas agrícolas que você deveria se preocupar*. Disponível em: <https://blog.agrointeli.com.br/blog/principais-pragas-agricolas/>. Acesso em: 11 jun. 2025.
13. BLOG SENSIX. *Principais pragas na agricultura do Brasil*. Disponível em: <https://blog.sensix.ag/principais-pragas-na-agricultura-do-brasil/>. Acesso em: 11 jun. 2025.
14. BORBA, M. da C. et al. *Gestão no meio agrícola com o apoio da Inteligência Artificial: uma análise da digitalização da agricultura*. Revista Em Agronegócio e Meio Ambiente, v.15, n.3, p.1–22, 2022. <https://doi.org/10.17765/2176-9168.2022v15n3e9337>
15. CEPEA. *Número de pessoas no agronegócio brasileiro atinge recorde histórico*. Cepea/CNA, Piracicaba, 14 mar. 2024. Disponível em: <https://www.cepea.esalq.usp.br>. Acesso em: 22 abr. 2025.
16. CEPEA/ESALQ-USP. *O impacto econômico das pragas na lavoura*. 2024. Disponível em: <https://periodicos.fgv.br/agroanalysis/article/download/79707/76265>. Acesso em: 11 jun. 2025.
17. CROPLIFE BRASIL. *Estudo mostra os impactos econômicos do não controle de pragas nas lavouras*. 2024. Disponível em: <https://croplifebrasil.org/estudo-mostra-os-impactos-economicos-do-nao-controle-de-pragas-nas-lavouras/>. Acesso em: 11 jun. 2025.
18. DUTTA, Gopal; GOSWAMI, Purba. *Applications of drones in agriculture: a review*. International Journal of Research in Engineering, Science and Management, v. 3, n. 5, p. 258-261, 2020. Disponível em: https://www.ijresm.com/Vol3Iss5/paper_40.pdf. Acesso em: 20 abr. 2025.
19. EMBRAPA. *Monitoramento de pragas auxilia na aplicação correta de agrotóxicos, diz pesquisador*. 2012. Disponível em: <https://www.embrapa.br/busca-de-noticias/-/noticia/1110388/monitoramento-de-pragas-auxilia-na-aplicacao-correta-de-agrotoxicos-diz-pesquisador>. Acesso em: 20 abr. 2025.

20. FAO. *Pragas e doenças causam perda de até 40% da produção agrícola mundial todos os anos*. 2021. Disponível em: <https://www.fao.org/brasil/noticias/detail-events/fr/c/1411810/>. Acesso em: 20 abr. 2025.
21. FAO. *Pragas e doenças transfronteiriças das plantas*. [s.d.]. Disponível em: <https://www.fao.org/transboundary-plant-pests-diseases/fr>. Acesso em: 20 abr. 2025.
22. FARMFOR. *História do BQM-1BR*. 2021. Disponível em: <https://farmfor.com.br/historia-do-bqm-1br>. Acesso em: 10 jun. 2025.
23. FOLHA AGRÍCOLA. *Pragas e doenças podem comprometer até 90% da produção agrícola*. 2024. Disponível em: <https://folhaagricola.com.br/2024/01/02/pragas-e-doencas-podem-comprometer-ate-90-da-producao-agricola/>. Acesso em: 10 jun. 2025.
24. GLOBO RURAL. *Uso de drones cresce no agronegócio e modifica produção no campo*. 2025. Disponível em: <https://globorural.globo.com/podcasts/cbn-agro/noticia/2025/05/uso-de-drones-cresce-no-agronegocio-e-modifica-producao-no-campo-ouca-o-comentario.ghtml>. Acesso em: 10 jun. 2025.
25. AGROINTELI. *Drones para a agricultura de precisão: veja os principais modelos do mercado*. 2022. Disponível em: <https://blog.agrointeli.com.br/blog/drones-para-a-agricultura-de-precisao/>. Acesso em: 11 jun. 2025.
26. SERVIÇO NACIONAL DE APRENDIZAGEM RURAL (SENAR). *Agricultura de precisão: drones*. Brasília: SENAR, 2018. (Coleção SENAR, 249).
27. LIMA, F. R.; GOMES, R. *Conceitos e tecnologias da Indústria 4.0: Uma análise bibliométrica*. Revista Brasileira de Inovação, v.19, 2020. <https://doi.org/10.20396/rbi.v19i0.8658766>
28. MEGETO, G. A. S. et al. *Aplicações de inteligência artificial na era da agricultura 4.0*. Ciência Agrônômica, v.51(spe), e20207701, 2021. <https://www.scielo.br/j/rca/a/KP5mfyFddvVFzqtLmMDNK3H/abstract/?lang=pt>
29. MUNDOGEO. *DJI Agriculture traz dados inéditos sobre a revolução agrícola com drones no Brasil*. 2025. Disponível em: <https://mundogeo.com/2025/05/05/dji-agriculture-traz-dados-ineditos-sobre-a-revolucao-agricola-com-drones-no-brasil/>. Acesso em: 11 jun. 2025.

30. MYFARM. *Pragas agrícolas no Brasil: conheça as principais*. 2024. Disponível em: <https://www.myfarm.com.br/pragas-agricolas/>. Acesso em: 11 jun. 2025.

31. OLIVEIRA, A. J. de et al. *Potencialidades da utilização de drones na agricultura de precisão*. Brazilian Journal of Development, v.6, n.9, p.64140–64149, 2020. <https://doi.org/10.34117/bjdv6n9-010>. Acesso em: 10 jun. 2025.

32. PORTAL MAIS AGRO. *O desafio das pragas e o impacto na produtividade*. 2024. Disponível em: <https://maisagro.syngenta.com.br/dia-a-dia-do-campo/o-desafio-das-pragas-e-o-impacto-na-produtividade/>. Acesso em: 11 jun. 2025.

33. SAMPAIO, R. M.; FREDO, C. E. *Características socioeconômicas e tecnologias na agricultura*. Revista de Economia e Sociologia Rural, v.59, n.4, e236538, 2021. <https://doi.org/10.1590/1806-9479.2021.236538>

34. SANTOS, Murillo Dourado de Souza. *Utilização de drones na agricultura: uma revisão*. 2022. Disponível em: https://repositorio.pgsscogna.com.br/bitstream/123456789/40886/1/GABRIEL_FRAN%C3%87A.pdf. Acesso em: 11 jun. 2025.

35. SEBRAE. *Drones na agricultura: tecnologia e inovação para o campo*. 2024. Disponível em: <https://sebrae.com.br/sites/PortalSebrae/artigos/drones-na-agricultura-tecnologia-e-inovacao-para-o-campo>. Acesso em: 11 jun. 2025.

36. SUMMIT AGRO. *Quais são as 10 pragas que oferecem mais riscos à agropecuária?* 2022. Disponível em: <https://agro.estadao.com.br/summit-agro/quais-sao-as-10-pragas-que-oferecem-mais-riscos-a-agropecuaria>. Acesso em: 11 jun. 2025.

37. TAVARES, L. A.; MEIRA, M. C.; AMARAL, S. F. do. *Inteligência Artificial na Educação: Survey*. Brazilian Journal of Development, v.6, n.7, p.48699–48714, 2020. <https://doi.org/10.34117/bjdv6n7-496>. Acesso em: 10 jun. 2025.

38. TIMESBRASIL. *Na Agrishow 2025, drones e IA oferecem soluções versáteis e eficiência no campo*. 2025. Disponível em: <https://timesbrasil.com.br/empresas-e-negocios/agro/na-agrishow-2025-drones-e-ia-oferecem-solucoes-versateis-e-eficiencia-no-campo/>. Acesso em: 11 jun. 2025.

39. YAMAHA MOTOR. *Histórico dos drones agrícolas*. s.d. Disponível em: <https://www.yamaha-motor.com/agriculture/history>. Acesso em: 11 jun. 2025.

40. ZHAI, Zhaoyu; MARTÍNEZ, José Fernán; BELTRAN, Victoria; MARTÍNEZ, Néstor Lucas. *Decision support systems for agriculture 4.0: Survey and challenges*. Computers and Electronics in Agriculture, v. 170, p. 105256, 2020. Disponível em: <https://doi.org/10.1016/j.compag.2020.105256>. Acesso em: 20 abr. 2025.
41. DJI. *Tello SDK Documentation – Version 1.3*. Shenzhen: DJI, 2022. Disponível em: https://terra-1-g.djicdn.com/2d4dce68897a46b19fc717f3576b7c6a/Tello%E7%BC%96%E7%A8%8B%E7%9B%B8%E5%85%B3/For%20Tello/Tello%20SDK%20Documentation%20EN_1.3_1122.pdf. Acesso em: 10 nov. 2025.
42. REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You Only Look Once: Unified, Real-Time Object Detection. CVPR, 2016. Disponível em: <https://arxiv.org/pdf/1506.02640>. Acesso em: 12 nov. 2025.