



**Universidade de Brasília
Faculdade de Tecnologia
Departamento de Engenharia Mecânica**

**Estratégias para aprendizado de máquina com
poucas amostras na classificação de imagens
de insetos**

Kelly Rodrigues de Abreu

DISSERTAÇÃO DE MESTRADO
PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS MECATRÔNICOS

Brasília
2026

A769e Abreu, Kelly Rodrigues de .
Estratégias para aprendizado de máquina com poucas amostras na classificação de imagens de insetos / Kelly Rodrigues de Abreu; orientador Díbio Leandro Borges. -- Brasília, 2026.
85 p.

Dissertação de Mestrado (Programa de Pós-Graduação em Sistemas Mecatrônicos) -- Universidade de Brasília, 2026.

1. Aprendizado com Poucos Exemplos. 2. Estratégias de Amostragem. 3. Classificação da Maturidade de Insetos-Praga. 4. Detectores de Objetos YOLO. I. Borges, Díbio Leandro, orient. II. Título

**Universidade de Brasília
Faculdade de Tecnologia
Departamento de Engenharia Mecânica**

Estratégias para aprendizado de máquina com poucas amostras na classificação de imagens de insetos

Kelly Rodrigues de Abreu

Dissertação de Mestrado submetida ao Departamento de Engenharia Mecânica da Universidade Brasília como parte dos requisitos necessários para a obtenção do grau de Mestre

Orientador: Prof. Dr. Díbio Leandro Borges

Brasília

2026

**Universidade de Brasília
Faculdade de Tecnologia
Departamento de Engenharia Mecânica**

Estratégias para aprendizado de máquina com poucas amostras na classificação de imagens de insetos

Kelly Rodrigues de Abreu

Dissertação de Mestrado submetida ao Departamento de Engenharia Mecânica da Universidade Brasília como parte dos requisitos necessários para a obtenção do grau de Mestre

Trabalho aprovado. Brasília, 30 de janeiro de 2026:

Prof. Dr. Díbio Leandro Borges,
UnB/IE/CIC
Orientador

Prof. Dr. José Maurício Santos Torres da Motta, UnB/FT/ENM
Examinador interno

Profa. Dra. Lurdineide de Araújo Barbosa Borges, Ministério da Agricultura e Pecuária (MAPA)
Examinador externo

Brasília
2026

À minha família, pelo apoio e incentivo ao longo desta jornada.

*”If you find that you’re spending almost all your time on theory,
start turning some attention to practical things;
it will improve your theories.*

*If you find that you’re spending almost all your time on practice,
start turning some attention to theoretical things;
it will improve your practice.”*

(Donald Knuth)

Resumo

A detecção automática de pragas agrícolas a partir de imagens é um desafio central para a Agricultura de Precisão, sendo agravada pela escassez de dados anotados e pela elevada complexidade visual entre estágios de maturidade. Esta dissertação investiga a detecção de insetos sob o regime de aprendizado com poucas amostras a partir de uma perspectiva centrada em dados. Foram avaliadas múltiplas arquiteturas YOLO (v5, v8 e v11), integrando estratégias de amostragem inteligente, aumento de dados e modos de congelamento de camadas. A análise experimental revela que a Estratégia II (Amostragem por Diversidade Visual Multivariada) proporcionou ganhos significativos não apenas na estabilidade estatística, mas em todas as métricas primárias: precisão média (*mean average precision - mAP*), sensibilidade (*recall*) e pontuação F1 (*f1-score*). A configuração otimizada, composta pelo modelo YOLOv11n com congelamento de 10 camadas, sem o uso de aumento de dados *offline* e sob a Estratégia II, alcançou os melhores resultados absolutos. Para o estágio adulto, obteve-se uma precisão média (mAP_{50-95}) de $0,6372 \pm 0,0375$ e *recall* de 0,9054. No estágio jovem, o mais desafiador devido ao mimetismo biológico, o modelo atingiu uma precisão média (mAP_{50-95}) de $0,4534 \pm 0,0621$, representando um incremento de 14,4% em relação à seleção aleatória. Esses valores superam o desempenho do estado da arte de 2025, o modelo YOLO-YSTs, que reportou uma precisão média (mAP_{50-95}) de 0,4130. Além do desempenho superior, a estratégia proposta alcançou uma redução superior a 30% no coeficiente de variação, atingindo o patamar de 3,93% em métricas críticas. Tal avanço garante modelos mais robustos e previsíveis para implementação em dispositivos de borda. Os achados reforçam que a amostragem criteriosa do conjunto de suporte constitui um mecanismo de regularização mais eficaz que a redundância sintética para a Agricultura 4.0.

Palavras-chave: Aprendizado com Poucas Amostras; Estratégias de Amostragem; Classificação da Maturidade de Insetos-Praga; Detectores de Objetos YOLO.

Abstract

Automatic insect pest detection from images is a core challenge for Precision Agriculture, further complicated by the scarcity of labeled data and high visual complexity across maturity stages. This dissertation investigates insect detection under a few-shot learning (FSL) regime through a data-centric perspective. Multiple YOLO architectures (v5, v8, and v11) were evaluated, integrating intelligent sampling strategies, data augmentation, and layer freezing modes. Experimental analysis reveals that Strategy II (Multivariate Visual Diversity Sampling) provided significant gains not only in statistical stability but across all primary metrics: mean average precision (mAP), recall, and F1-score. The optimized configuration—comprising the YOLOv11n model with simple backbone freezing, excluding offline data augmentation, and utilizing Strategy II—achieved the best absolute results. For the adult stage, a mean average precision (mAP_{50-95}) of 0.6372 ± 0.0375 and a recall of 0.9054 were obtained. In the early stage, the most challenging due to biological mimicry, the model reached a mean average precision (mAP_{50-95}) of 0.4534 ± 0.0621 , representing a 14.4% increase over random selection. These values outperform the 2025 state-of-the-art model, YOLO-YSTs, which reported an mAP_{50-95} of 0.4130. Beyond superior performance, the proposed strategy achieved a reduction of over 30% in the coefficient of variation, reaching 3.93% in critical metrics, ensuring more robust and predictable models for deployment on edge devices. The findings reinforce that judicious sampling of the support set is a more effective regularization mechanism than synthetic redundancy for Agriculture 4.0.

Keywords: Few-Shot Learning; Sampling Strategies; Insect Pest Maturity Classification; YOLO Object Detectors.

Lista de ilustrações

Figura 1 – Diagrama cronológico mostrando a evolução da Agricultura de Precisão desde os anos 1980 até o presente, destacando os principais marcos tecnológicos e conceituais, como a introdução do GPS para uso civil, primeiros mapas de produtividade, sistemas com Tecnologia de Taxa Variável (<i>Variable Rate Technology - VRT</i>), sensoriamento remoto, IoT e inteligência artificial.	20
Figura 2 – Componentes tecnológicos da Agricultura de Precisão moderna	22
Figura 3 – Etapas do Manejo Integrado de Pragas de Precisão: da detecção à avaliação, integrando tecnologias como IA, SIG e VRT.	27
Figura 4 – Exemplos de classes do IP-FSL com dois estágios de maturidade (jovens e adultos, presentes nos subconjuntos das classes 17, 19 e 23).	38
Figura 5 – Diagrama esquemático da configuração estrutural de <i>Few-Shot Learning</i> (3-way, 5-shot), ilustrando a constituição do Conjunto de Suporte para o aprendizado das representações e a posterior avaliação no Conjunto de Consulta fixo.	40
Figura 6 – Macrofluxograma do desenho experimental proposto para detecção de pragas em regime de <i>few-shot learning</i>	44
Figura 7 – Resultados de mAP_{50-95} para os estágios de maturidade: (a) Adultos e (b) Jovens.	64
Figura 8 – Comparativo da métrica <i>Recall</i> para os estágios de maturidade: (a) Adultos e (b) Jovens.	64
Figura 9 – Comparativo do F1-Score para os estágios de maturidade: (a) Adultos e (b) Jovens.	65
Figura 10 – Exemplo de análise qualitativa para o estágio adulto: (a) Verdade Fundamental e (b) Predição do modelo YOLOv11.	67
Figura 11 – Exemplo de análise qualitativa para o estágio jovem: (a) Verdade Fundamental e (b) Predição do modelo YOLOv11.	68
Figura 12 – Mapas de ativação Grad-CAM evidenciando os padrões de atenção da rede YOLOv11 sob diferentes cenários de treinamento.	68

Lista de tabelas

Tabela 1 – Comparação entre métodos tradicionais e tecnológicos emergentes de monitoramento.	24
Tabela 2 – Estrutura do Dataset IP-FSL.	35
Tabela 3 – Funcionalidades dos modelos especializados por estágio biológico. . . .	38
Tabela 4 – Comparativo de Hiperparâmetros Fotométricos Dinâmicos: Controle vs. Híbrido.	42
Tabela 5 – Especificações técnicas e complexidade computacional das arquiteturas selecionadas.	43
Tabela 6 – Resultados Comparativos: Validação de Estratégias (Adultos vs. Jovens). Em destaque, a estabilidade da Estratégia II e a resiliência do YOLOv11.	56
Tabela 7 – Comparação de Desempenho: Baseline (Época 0) vs. Pior resultado FSL com ajuste fino.	58
Tabela 8 – Análise Estatística Detalhada - Estágio Adultos (15 Sementes). Linhas sombreadas indicam significância estatística ($p < 0,05$).	61
Tabela 9 – Análise Estatística Detalhada - Estágio Jovens (15 Sementes). Linhas sombreadas indicam significância estatística ($p < 0,05$).	62
Tabela 10 – Ranqueamento de Precisão Média (mAP_{50-95}) para os modelos no topo do torneio comparativo.	70
Tabela 11 – Ranqueamento de Sensibilidade (<i>Recall</i>) para os modelos no topo do torneio comparativo.	70
Tabela 12 – Ranqueamento de Equilíbrio Operacional (<i>F1-Score</i>) para os modelos no topo do torneio comparativo.	70
Tabela 13 – Comparação de desempenho entre a proposta deste trabalho (Few-Shot) e o estado da arte YOLO-YSTs.	71

Lista de abreviaturas e siglas

AP	Agricultura de Precisão (Molin; Amaral; Colaço, 2011; Inamasu; Bernardi, 2011)
CNN	Redes Neurais Convolucionais (<i>Convolutional Neural Networks</i>) (LeCun; Bengio; Hinton, 2015)
COCO	<i>Common Objects in Context</i> (Lin <i>et al.</i> , 2014)
CV	Coefficiente de Variação (Bouthillier <i>et al.</i> , 2021)
DGPS	<i>Differential Global Positioning System</i> (Pérez-Ruiz; Upadhyaya, 2012)
FDR	<i>False Discovery Rate</i> (Lapuschkin <i>et al.</i> , 2019)
FSOD	<i>Few-Shot Object Detection</i> (Fan <i>et al.</i> , 2020; Wang, X. <i>et al.</i> , 2020)
FSL	<i>Few-Shot Learning</i> (Aprendizado com Poucas Amostras) (Wang, Y. <i>et al.</i> , 2020; Vinyals <i>et al.</i> , 2016)
GNSS	<i>Global Navigation Satellite System</i> (Pérez-Ruiz; Upadhyaya, 2012; Zhang; Reid; Noguchi, 1999)
GPS	Sistema de Posicionamento Global (Gebbers; Adamchuk, 2010)
Grad-CAM	<i>Gradient-weighted Class Activation Mapping</i> (Lapuschkin <i>et al.</i> , 2019)
HSV	<i>Hue, Saturation, Value</i> (Matiz, Saturação, Valor) (Hamuda <i>et al.</i> , 2017)
IoU	<i>Intersection over Union</i> (Interseção sobre União) (Zheng <i>et al.</i> , 2020)
IoT	<i>Internet of Things</i> (Internet das Coisas) (Ahmed <i>et al.</i> , 2024; Duguma; Bai, 2025)
LBP	<i>Local Binary Patterns</i> (Padrões Binários Locais) (Ojala; Pietikainen; Maenpää, 2002)
mAP	<i>mean Average Precision</i> (Precisão Média) (Zhao <i>et al.</i> , 2019; Zou <i>et al.</i> , 2023)
MIP	Manejo Integrado de Pragas (Dent; Binks, 2020; Gallo; Nakano; Silveira Neto <i>et al.</i> , 2002)
MIPP	Manejo Integrado de Pragas de Precisão (Kanwal <i>et al.</i> , 2022)

NDVI	<i>Normalized Difference Vegetation Index</i> (Maes; Steppe, 2019)
NMS	<i>Non-Maximum Suppression</i> (Supressão Não Máxima) (Redmon <i>et al.</i> , 2016)
RTK	<i>Real-Time Kinematic</i> (Pérez-Ruiz; Upadhyaya, 2012)
SIG	Sistemas de Informação Geográfica (Pierce; Clay, 2007)
TP	Verdadeiro Positivo (<i>True Positive</i>) (Zheng <i>et al.</i> , 2020)
UAV	<i>Unmanned Aerial Vehicle</i> (Veículo Aéreo Não Tripulado / Drone) (Barbedo, 2019)
VRT	<i>Variable Rate Technology</i> (Tecnologia de Taxa Variável) (Grisso <i>et al.</i> , 2011)
XAI	<i>Explainable Artificial Intelligence</i> (Inteligência Artificial Explicável) (Lapuschkin <i>et al.</i> , 2019)
YOLO	<i>You Only Look Once</i> (Redmon <i>et al.</i> , 2016; Ultralytics, 2024)

Sumário

1	INTRODUÇÃO	15
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	Agricultura de Precisão e o Monitoramento de Pragas	19
2.1.1	Evolução histórica da Agricultura de Precisão	19
2.1.2	Componentes e tecnologias da Agricultura de Precisão	20
2.1.2.1	Sistemas de Posicionamento Global (GPS) e Navegação por Satélite	21
2.1.2.2	Sensoriamento Remoto e Proximal	21
2.1.2.3	Sistemas de Informação Geográfica (SIG)	21
2.1.2.4	Internet das Coisas (IoT) aplicada à agricultura	21
2.1.2.5	Equipamentos de Aplicação em Taxa Variável (VRT)	22
2.1.3	Monitoramento de pragas na Agricultura de Precisão	22
2.1.3.1	Métodos tradicionais e suas limitações	23
2.1.3.2	Abordagens tecnológicas emergentes	23
2.1.3.3	Impactos econômicos e ambientais das pragas agrícolas	24
2.1.3.4	Manejo Integrado de Pragas (MIP) e sua relação com a AP	26
2.2	Aprendizado Profundo para Detecção de Objetos	27
2.2.1	Paradigmas de Detecção de Objetos	28
2.2.2	A Família de Modelos YOLO (<i>You Only Look Once</i>)	28
2.2.3	Detecção de Objetos na Agricultura de Precisão	29
2.3	Aprendizado com Poucas Amostras (<i>Few-Shot Learning</i> - FSL)	29
2.3.1	Abordagens em <i>Few-Shot Learning</i>	30
2.3.2	Detecção de Objetos com Poucas Amostras (FSOD)	31
2.4	Estratégias de Amostragem de Dados para FSOD na Agricultura	31
2.4.1	Desafios Amplificados no Contexto Agrícola	32
2.4.2	Estratégias de Amostragem Inteligente para Ajuste Fino (<i>Fine-Tuning</i>)	33
2.4.2.1	Amostragem Baseada na Qualidade da Imagem	33
2.4.2.2	Amostragem Baseada na Diversidade	33
2.4.2.3	Diferença entre Amostragem e Aumento de Dados	34
3	MATERIAIS E MÉTODOS	35
3.1	Conjunto de Dados	35
3.1.1	Classificação por Estágios de Maturidade	35
3.1.2	Seleção das Classes para o Estudo	36
3.2	Diretrizes para Aquisição e Qualidade de Imagens	38

3.2.1	Dimensionamento do Conjunto de Dados e Restrições de Amostragem	39
3.3	Aumento de Dados Híbrido e Invariância de Domínio	40
3.3.1	Aumento Offline: Simulação de Ruído de Captura	40
3.3.2	Dinâmica Condicional e Atenuação de Hiperparâmetros (HSV)	41
3.4	Arquiteturas dos Modelos	42
3.4.1	Inicialização e Aprendizado por Transferência	43
3.5	Desenho Experimental	43
3.5.1	Configurações de Treinamento e Hiperparâmetros	43
3.5.1.1	Configuração da Linha de Base (Pré-treino COCO)	45
3.5.2	Estratégias Data-Cêntricas	45
3.5.2.1	Estratégia I: Amostragem Guiada pela Nitidez	45
3.5.2.2	Estratégia II: Amostragem por Diversidade Visual Multivariada	47
3.5.3	Estratégias de Aprendizado por Transferência	48
3.5.3.1	Ajuste-fino Completo	48
3.5.3.2	Estratégia de Congelamento Simples (Regularização)	49
3.6	Métricas de Avaliação e Análise Estatística	49
3.6.1	Controle e Reprodutibilidade	50
3.6.2	Avaliação e Rigor Estatístico	50
3.6.3	Explicabilidade Visual via Grad-CAM	51
3.6.4	O Efeito Clever Hans em Visão Computacional	52
3.7	Ambiente Computacional	53
3.7.1	Ambiente de Hardware	53
3.7.2	Ambiente de Software e Bibliotecas	54
4	RESULTADOS E DISCUSSÃO	55
4.1	Experimentos Exploratórios e Prova de Conceito (N=5)	55
4.1.1	Singularidade Estatística da Estratégia II no Modelo YOLOv5	56
4.1.2	Refinamentos Metodológicos e Transição para o Estudo de Caso do Milho	57
4.1.3	Resultados Detalhados para a Detecção de Pragas da Cultura do Milho	58
4.1.4	Incomensurabilidade e Dificuldade Intrínseca dos Estágios	63
4.1.5	Síntese de Performance e Melhores Médias por Estágio	63
4.1.6	Análise da Variabilidade e Performance	63
4.1.6.1	Precisão Média (mAP)	63
4.1.6.2	Análise da Sensibilidade (<i>Recall</i>)	64
4.1.6.3	Análise do Equilíbrio Operacional (<i>F1-Score</i>)	65
4.1.7	O Impacto do Modo de Congelamento como Mecanismo de Regularização	65
4.1.8	Análise do Aumento de Dados: Volume <i>versus</i> Qualidade	66
4.1.9	A Superioridade da Arquitetura Nano Moderna frente ao Modelo Legado	66
4.1.10	Análise Qualitativa e Índices de Confiança	67

4.1.11	Interpretabilidade Fenotípica e Viés de Fundo (Grad-CAM)	67
4.2	Torneio dos Campeões: Análise Multi-métrica	69
4.2.1	Visão I: Precisão Média (<i>mAP</i>)	69
4.2.2	Visão II: Sensibilidade (<i>Recall</i>)	69
4.2.3	Visão III: Equilíbrio Operacional (<i>F1-Score</i>)	70
4.2.4	Discussão Comparativa com o Estado da Arte: YOLO-YSTs (2025)	71
4.3	Síntese e Veredito Técnico	71
5	CONCLUSÃO	73
5.1	Síntese das Descobertas e Contribuições Técnicas	73
5.2	Rigor Estatístico e Confiabilidade do Modelo	74
5.3	Implicações para a Agricultura Digital	74
5.4	Sugestões de Trabalhos Futuros	74
	REFERÊNCIAS	76

1 Introdução

A crescente demanda por soluções eficientes no monitoramento agrícola, especialmente no reconhecimento de pragas em diferentes estágios de maturidade, impulsiona o uso de técnicas avançadas de visão computacional. Contudo, a escassez de dados rotulados limita a aplicação de modelos convencionais de aprendizado profundo nesse contexto. Esta dissertação investiga o uso do *Few-Shot Learning* (FSL) em combinação com detectores da família YOLO, propondo estratégias de amostragem de dados para melhorar a classificação de insetos-praga em cenários com poucos exemplos. A pesquisa busca responder se tais estratégias podem aprimorar o desempenho desses modelos, contribuindo para o desenvolvimento de ferramentas mais eficazes e acessíveis à Agricultura de Precisão.

Caracterização do Problema

A proteção eficaz das culturas agrícolas depende, em grande parte, da identificação precisa e oportuna de pragas em seus diferentes estágios de desenvolvimento (Dent; Binks, 2020). Nesse cenário, a Agricultura de Precisão se destaca como um paradigma moderno que busca integrar tecnologias digitais para otimizar o manejo agrícola (Pierpaoli *et al.*, 2013). No âmbito das grandes culturas, a produção de milho (*Zea mays* L.) apresenta-se como um campo crítico para essas inovações, dada a sua relevância econômica e a pressão constante de pragas que, se não identificadas precocemente, podem causar perdas severas na produtividade e na qualidade dos grãos (Oerke, 2006; Oliveira *et al.*, 2014).

Entre os pilares tecnológicos da Agricultura de Precisão, os modelos de aprendizado profundo desempenham um papel central, especialmente em tarefas de visão computacional, como a detecção automatizada de pragas. No entanto, esses modelos frequentemente requerem grandes volumes de dados anotados para alcançar um desempenho satisfatório (LeCun; Bengio; Hinton, 2015), o que representa uma barreira significativa no contexto agrícola, marcado por elevada variabilidade de espécies, estágios de vida e condições ambientais (Wu, X. *et al.*, 2019).

Além disso, atrasos ou falhas na identificação de pragas podem levar ao uso indiscriminado de pesticidas, elevando custos e riscos à saúde humana e ao meio ambiente (Popp; Petó; Nagy, 2013). Diante disso, torna-se urgente desenvolver métodos capazes de operar de forma eficaz, mesmo sob condições de dados limitados.

O *Few-Shot Learning* (FSL) emerge como uma abordagem promissora nesse contexto. Inspirado na capacidade humana de aprender a partir de poucas amostras, o FSL visa treinar modelos capazes de generalizar a partir de apenas uma ou algumas amostras por

classe (Wang, Y. *et al.*, 2020). Técnicas baseadas em aprendizado por métricas, como as Redes Prototípicas (Snell; Swersky; Zemel, 2017), têm se mostrado eficazes em tarefas de classificação, mas apresentam limitações quando aplicadas a problemas que exigem não apenas classificar, mas também localizar objetos, como a detecção de pragas.

O uso de técnicas de aprendizado profundo para o reconhecimento automático de insetos-praga em imagens agrícolas tem sido investigado há vários anos. Abordagens iniciais já demonstravam o potencial de modelos baseados em redes neurais convolucionais para a identificação de pragas em ambientes de cultivo, mesmo diante de desafios como variações de iluminação, oclusões e complexidade do fundo (Souza, W. S. R.; Alves; Borges, D. L., 2019).

Detectores da família YOLO (*You Only Look Once*) (Redmon *et al.*, 2016) têm sido amplamente adotados em aplicações agrícolas devido à sua eficiência computacional e capacidade de operar em tempo quase real. Trabalhos recentes demonstram o uso bem-sucedido de variantes do YOLOv8 na detecção de insetos-praga em imagens de campo, evidenciando seu potencial para aplicações práticas em sistemas de monitoramento agrícola (Lima *et al.*, 2024). No entanto, tais modelos dependem tradicionalmente de grandes volumes de dados anotados, tornando sua aplicação direta em cenários com poucas amostras um desafio técnico significativo (Wu, J. *et al.*, 2020).

Imagens adquiridas diretamente em campo agrícola impõem desafios adicionais aos sistemas de visão computacional, como a grande variabilidade de fundo, a iluminação não controlada e a sobreposição entre insetos e elementos naturais da lavoura. Estudos anteriores evidenciam que essas condições impactam significativamente o desempenho de modelos de aprendizado profundo, exigindo arquiteturas e estratégias capazes de generalizar adequadamente em cenários reais (Alves; Souza, W. S.; Borges, D. L., 2020).

A adaptação de detectores YOLO ao paradigma FSL requer não apenas ajustes arquiteturais, mas também estratégias específicas para mitigar o risco de sobreajuste e maximizar a generalização com um número limitado de imagens. Estratégias de amostragem de dados desempenham um papel fundamental nesse processo, pois a escolha criteriosa das imagens pode influenciar diretamente a eficácia do treinamento em cenários de escassez de dados (Kim; Wang, Z., 2018).

Esta dissertação propõe e avalia duas estratégias de amostragem de dados com foco na classificação da maturidade de insetos-praga em contextos de poucos exemplos. A primeira estratégia é baseada na nitidez da imagem, utilizando critérios de qualidade visual para selecionar amostras mais informativas. A segunda estratégia foca na diversidade visual multivariada, agrupando imagens segundo suas características, como cor, iluminação e grau de desordem, conforme a proposta adaptada de Aboah *et al.* (2023).

Neste trabalho, o termo estratégia de amostragem refere-se ao método sistemático

de seleção das poucas imagens (*support set*) que serão utilizadas para o ajuste fino (*fine-tuning*) do modelo no regime de FSL. Em vez de uma escolha aleatória, a amostragem inteligente busca substituir a incerteza por critérios deliberados de qualidade visual (nitidez) ou diversidade visual, visando maximizar a informação extraída de um conjunto limitado de dados.

Perguntas de Pesquisa

Diante dos desafios associados à detecção de insetos-praga em cenários caracterizados pela escassez de dados rotulados e pela elevada variabilidade visual, esta pesquisa busca responder às seguintes perguntas:

- É possível adaptar modelos da família YOLO (YOLOv5, YOLOv8 e YOLOv11) para cenários de aprendizado com poucas amostras, mantendo desempenho competitivo na detecção e classificação da maturidade de insetos-praga na cultura do milho?
- Estratégias de amostragem de dados orientadas por critérios de qualidade da imagem, como nitidez, ou por diversidade visual, contribuem para a melhoria do desempenho e da estabilidade dos detectores YOLO em regime de Few-Shot Learning?
- Quais são os impactos dessas estratégias sobre as métricas tradicionais de desempenho, como a *mean average precision* (mAP@0.5:0.95), sobre a variabilidade dos resultados e a reprodutibilidade entre diferentes inicializações de treinamento?

Objetivo Geral

Investigar e avaliar estratégias de amostragem de dados aplicadas a modelos da família YOLO, visando aprimorar o desempenho, a estabilidade e a robustez da detecção da maturidade de insetos-praga em cenários de aprendizado com poucas amostras.

Objetivos Específicos

- Desenvolver e comparar estratégias de amostragem de dados voltadas ao FSL, incluindo:
 - uma estratégia baseada na qualidade da imagem, com ênfase na nitidez;
 - uma estratégia fundamentada na diversidade visual multivariada das imagens.
- Analisar o impacto de diferentes configurações de treinamento dos modelos YOLO em cenários de poucos dados, considerando o aprendizado por transferência por meio de dois modos: o ajuste integral de parâmetros (sem congelamento) e o congelamento parcial das camadas do *backbone*.

- Avaliar comparativamente o desempenho dos modelos YOLOv5, YOLOv8 e YOLOv11 no conjunto de dados IP-FSL (Gomes; Borges, D. L., 2022), considerando as métricas *mean average precision* ($mAP@0.5 : 0.95$), *Recall*, *f1-score* e a variabilidade dos resultados obtidos a partir de múltiplas inicializações aleatórias.

Contribuições Específicas

Complementarmente, esta dissertação apresenta as seguintes contribuições:

- A proposição e implementação de estratégias de seleção de imagens orientadas por critérios visuais, aplicadas a cenários de aprendizado com poucas amostras;
- Uma metodologia experimental abrangente e reprodutível, que inclui a utilização de múltiplas inicializações aleatórias, diferentes modos de aprendizado por transferência e análise estatística formal dos resultados;
- Uma análise comparativa do desempenho e da estabilidade dos modelos YOLOv5, YOLOv8 e YOLOv11 no conjunto de dados IP-FSL, evidenciando o papel das estratégias de amostragem na redução da variabilidade e no aumento da confiabilidade dos modelos.
- Os resultados preliminares relativos à estabilidade das estratégias de amostragem e à performance das arquiteturas YOLO em regime de poucas amostras foram publicados nos anais do 21st International Conference on Computer Vision Theory and Applications (VISAPP 2026) (Abreu; Costa; Borges, D., 2026).

Organização do Trabalho

A estrutura desta dissertação está organizada da seguinte forma:

O Capítulo 2 apresenta a fundamentação teórica, revisando os conceitos essenciais para a compreensão do trabalho. O Capítulo 3 descreve em detalhes os materiais e métodos utilizados, incluindo o conjunto de dados, as estratégias de amostragem propostas e a configuração experimental. O Capítulo 4 apresenta e discute os resultados obtidos. Finalmente, o Capítulo 5 sumariza as conclusões do trabalho, aponta suas limitações e sugere direções para pesquisas futuras.

2 Fundamentação Teórica

Este capítulo apresenta a revisão da literatura e os conceitos fundamentais que embasam esta dissertação. Serão abordados os temas de Agricultura de Precisão, com foco no monitoramento de pragas, o Aprendizado Profundo aplicado à detecção de objetos, com ênfase nos modelos YOLO, e o paradigma do Aprendizado com Poucas Amostras (*Few-Shot Learning* - FSL). Por fim, serão discutidos os desafios inerentes à detecção de pragas agrícolas utilizando FSL e a importância de estratégias de amostragem de dados nesse contexto.

2.1 Agricultura de Precisão e o Monitoramento de Pragas

2.1.1 Evolução histórica da Agricultura de Precisão

A Agricultura de Precisão (AP) surgiu como um conceito na década de 1980, mas suas raízes remontam aos primeiros esforços de mapeamento de solo e gerenciamento localizado de culturas no início do século XX. O termo "Agricultura de Precisão" foi cunhado oficialmente na década de 1990, quando avanços tecnológicos, especialmente o Sistema de Posicionamento Global (GPS) para uso civil, permitiram a implementação prática desses conceitos (Council, 1997; Franzen; Mulla, 2015).

A evolução da Agricultura de Precisão (AP) pode ser compreendida a partir de três grandes fases tecnológicas que moldaram sua consolidação como um sistema moderno de gestão agrícola. A primeira fase foi impulsionada pelos avanços em geoinformação, sensores e técnicas de mapeamento, que permitiram reconhecer a variabilidade espacial das lavouras e fundamentaram cientificamente o conceito de manejo localizado. Trabalhos como (Gebbers; Adamchuk, 2010) destacam que essa etapa inicial estabeleceu as bases da AP ao introduzir medições espacialmente explícitas e processos agrônômicos orientados por dados.

A segunda fase foi marcada pela introdução e disseminação dos sistemas GNSS em operações agrícolas, possibilitando o guiamento automático de máquinas e o uso de correções diferenciais (DGPS e RTK), que elevaram significativamente a precisão do posicionamento no campo. Conforme discutido em (Pérez-Ruiz; Upadhyaya, 2012), essa evolução tecnológica permitiu aplicações em taxa variável, mapeamentos de produtividade e automação operacional.

A terceira fase corresponde à transição para a agricultura digital e conectada, caracterizada pela incorporação de computação em nuvem, Internet das Coisas (IoT), análise

massiva de dados e integração de múltiplas fontes de informação. Revisões abrangentes como (Wolfert *et al.*, 2017; Kamilaris; Kartakoullis; Prenafeta-Boldú, 2017) descrevem esse período como a era do Big Data na agricultura, em que plataformas digitais, sensores remotos e algoritmos de inteligência artificial ampliam a capacidade de monitoramento, diagnóstico e tomada de decisão. Em perspectiva histórica, (Franzen; Mulla, 2015) ressalta que a AP evoluiu de um conjunto de ferramentas operacionais para um ecossistema digital complexo, no qual conectividade e automação promovem decisões agrônômicas mais precisas e sustentáveis.

No Brasil, a adoção da AP começou efetivamente no final da década de 1990, com a importação de colhedoras equipadas com monitores de produtividade e sistemas de GPS (Molin; Amaral; Colaço, 2011). Desde então, o país tem se destacado na pesquisa e na implementação de tecnologias de AP, especialmente em culturas de grande escala como soja, milho e cana-de-açúcar, com instituições como a Embrapa liderando iniciativas de pesquisa e desenvolvimento nessa área (Inamasu; Bernardi, 2011).

Assim, a trajetória da Agricultura de Precisão reflete um processo contínuo de evolução tecnológica, passando do reconhecimento da variabilidade espacial, avançando para automação e georreferenciamento de alta precisão, e culminando em sistemas integrados e inteligentes que caracterizam a agricultura contemporânea.



Figura 1 – Diagrama cronológico mostrando a evolução da Agricultura de Precisão desde os anos 1980 até o presente, destacando os principais marcos tecnológicos e conceituais, como a introdução do GPS para uso civil, primeiros mapas de produtividade, sistemas com Tecnologia de Taxa Variável (*Variable Rate Technology - VRT*), sensoriamento remoto, IoT e inteligência artificial.

2.1.2 Componentes e tecnologias da Agricultura de Precisão

A Agricultura de Precisão opera a partir de um ciclo estruturado em quatro etapas principais: coleta de dados, análise e interpretação, tomada de decisão e implementação de manejos específicos, conforme apresentado em Gebbers e Adamchuk (2010) e reforçado por revisões recentes sobre tecnologias de AP e sustentabilidade, como Getahun, Kefale *et al.* (2024). Para operacionalizar esse ciclo, diversos componentes tecnológicos são integrados:

2.1.2.1 Sistemas de Posicionamento Global (GPS) e Navegação por Satélite

O GPS e outros sistemas de navegação por satélite (GNSS), combinados com sensores inerciais e visuais, proporcionam geolocalização centimétrica para equipamentos agrícolas e viabilizam sistemas de direção automática (auto-steering). A evolução dos sistemas de correção diferencial, como RTK (Real-Time Kinematic), aumentou significativamente a precisão do posicionamento, permitindo operações com precisão de nível centimétrico (tipicamente 2–3 cm) (Pérez-Ruiz; Upadhyaya, 2012).

2.1.2.2 Sensoriamento Remoto e Proximal

O sensoriamento remoto em Agricultura de Precisão evoluiu do uso de satélites e aeronaves para a adoção crescente de VANTs (drones), que oferecem maior resolução espacial e flexibilidade operacional no monitoramento das condições das culturas e do solo. Sensores multiespectrais e hiperespectrais capturam informações além do espectro visível, permitindo o cálculo de índices de vegetação, como o NDVI (Índice de Vegetação por Diferença Normalizada), que é um indicador do vigor e da saúde das plantas (Jensen, 2009). Tais sensores desempenham um papel central no monitoramento agrícola por UAVs, conforme discutido em Barbedo (2019)

O sensoriamento proximal envolve sensores instalados em máquinas agrícolas ou dispositivos portáteis que coletam dados em contato direto ou próximo às plantas e ao solo. Exemplos incluem sensores de condutividade elétrica do solo, clorofila, umidade, temperatura e câmeras RGB de alta resolução (Hardie, 2020).

2.1.2.3 Sistemas de Informação Geográfica (SIG)

Os SIGs são ferramentas essenciais para a AP, permitindo a integração, análise e visualização de dados espaciais (Pierce; Clay, 2007). Eles possibilitam a criação de mapas temáticos que representam a variabilidade espacial de atributos, como a fertilidade do solo, a produtividade, a infestação de pragas e doenças, entre outros. A evolução dos SIGs para plataformas baseadas em nuvem facilitou o acesso e o compartilhamento de dados entre diferentes stakeholders da cadeia agrícola (Pierce; Clay, 2007; Wolfert *et al.*, 2017; Kamilaris; Kartakoullis; Prenafeta-Boldú, 2017).

2.1.2.4 Internet das Coisas (IoT) aplicada à agricultura

A IoT desempenha um papel crescente na Agricultura de Precisão ao conectar sensores, máquinas e sistemas de processamento, permitindo monitoramento contínuo e respostas automatizadas em tempo real (Duguma; Bai, 2025). Sensores distribuídos no campo monitoram condições ambientais, o estado das culturas e a presença de pragas, transmitindo dados para sistemas centrais de processamento. Atuadores conectados podem



Figura 2 – Componentes tecnológicos da Agricultura de Precisão moderna

responder automaticamente a condições específicas, como sistemas de irrigação que se ajustam com base na umidade do solo ou armadilhas inteligentes para pragas que notificam os agricultores quando capturam insetos-alvo (Ahmed *et al.*, 2024; Kamilaris; Prenafeta-Boldü, 2018).

2.1.2.5 Equipamentos de Aplicação em Taxa Variável (VRT)

Os sistemas VRT permitem a aplicação de insumos (fertilizantes, defensivos, sementes, água) em quantidades variáveis de acordo com as necessidades específicas de cada ponto do campo. Esses equipamentos são controlados por computadores de bordo que ajustam as taxas de aplicação com base em mapas de prescrição ou sensores em tempo real, otimizando o uso de recursos e minimizando impactos ambientais (Robert, 2002).

2.1.3 Monitoramento de pragas na Agricultura de Precisão

O monitoramento de pragas é um componente crítico da AP, fornecendo informações essenciais para o Manejo Integrado de Pragas (MIP), uma abordagem que combina

métodos biológicos, culturais, físicos e químicos para controlar pragas de forma econômica e ambientalmente sustentável (Dent; Binks, 2020).

2.1.3.1 Métodos tradicionais e suas limitações

Tradicionalmente, o monitoramento de pragas é realizado por meio de inspeções visuais periódicas, utilizando técnicas como o pano-de-batida, armadilhas adesivas, armadilhas luminosas e contagem direta de insetos em plantas amostradas (Dent; Binks, 2020). Embora eficazes, esses métodos apresentam limitações significativas:

- **Intensidade de mão de obra:** requer pessoal treinado e tempo considerável para amostragem e identificação.
- **Subjetividade:** A identificação visual de espécies e estágios de desenvolvimento pode variar entre observadores.
- **Cobertura espacial limitada:** Amostragens pontuais podem não representar adequadamente a distribuição espacial das pragas em grandes áreas.
- **Frequência temporal insuficiente:** Intervalos entre amostragens podem permitir que infestações atinjam níveis críticos antes de serem detectadas.
- **Dificuldade em condições adversas:** Condições climáticas desfavoráveis podem impedir ou comprometer as amostragens.

Essas limitações podem resultar em aplicações desnecessárias ou tardias de defensivos, levando a perdas econômicas e impactos ambientais negativos (Pimentel, 2005).

2.1.3.2 Abordagens tecnológicas emergentes

A integração de tecnologias avançadas está transformando o monitoramento de pragas, superando muitas das limitações dos métodos tradicionais.

- **Armadilhas inteligentes:** Equipadas com câmeras, sensores e conectividade, capturam imagens de insetos e as transmitem para análise automatizada, permitindo a identificação e contagem em tempo real (Ahmed *et al.*, 2024).
- **Sensoriamento remoto:** Imagens multiespectrais e hiperespectrais de satélites e drones podem detectar alterações na reflectância das plantas causadas por estresse biótico, incluindo danos por pragas, antes que sejam visíveis a olho nu (Barbedo, 2019).
- **Redes de sensores sem fio:** Distribuídas pelo campo, monitoram as condições ambientais que influenciam o desenvolvimento e o comportamento de pragas, como

temperatura, umidade e velocidade do vento, permitindo previsões mais precisas de surtos (Ahmed *et al.*, 2024; Leybourne; Musa; Yang, 2024).

- **Feromônios e sensores químicos:** Feromônios são amplamente utilizados no monitoramento e controle (ex.: mating disruption); pesquisas também exploram a detecção química/volátil associada a infestações.(Witzgall; Kirsch; Cork, 2010).
- **Visão computacional e inteligência artificial:** Sistemas baseados em aprendizado profundo analisam imagens de plantas para detectar, identificar e quantificar pragas e danos, com potencial para operação em tempo real durante operações de campo (Kariyanna; Sowjanya, 2024).

Para sintetizar as diferenças estruturais e operacionais entre os paradigmas discutidos nesta seção, a Tabela 1 contrapõe as limitações intrínsecas das abordagens convencionais de campo às vantagens proporcionadas pela integração de tecnologias emergentes no manejo agrícola.

Tabela 1 – Comparação entre métodos tradicionais e tecnológicos emergentes de monitoramento.

Aspecto	Métodos Tradicionais	Tecnologias Emergentes
Cobertura espacial	Limitada (amostras pontuais)	Ampla (drones e redes IoT)
Frequência de amostragem	Baixa (visitas periódicas)	Alta (contínua / tempo real)
Precisão	Moderada (inspeção subjetiva)	Alta (análise automatizada via IA)
Custo	Baixo inicial, alto operacional	Alto inicial, baixo operacional
Mão de obra	Alta demanda (esforço braçal)	Baixa demanda (foco em manutenção)
Principais limitações	Viés humano e barreiras climáticas	Dependência de conectividade e hardware

Fonte: Elaborada pela autora.

2.1.3.3 Impactos econômicos e ambientais das pragas agrícolas

As pragas agrícolas representam um dos principais entraves à segurança alimentar e à balança comercial brasileira, com perdas anuais que, somadas a doenças e plantas daninhas, superam a marca de **R\$ 60 bilhões** (AGRO URBANO, 2025). Esse montante, fundamentado em monitoramentos da Embrapa e consultorias setoriais, reflete a vulnerabilidade de culturas estratégicas em ambientes tropicais sob pressão biótica contínua.

No contexto da cultura do milho (*Zea mays*), a relevância econômica é evidenciada pelo alto valor agregado de sua cadeia genética. Segundo o boletim *CropData* (CROPLIFE

BRASIL, 2025), o milho representou aproximadamente **50% do valor total das exportações de sementes do Brasil em 2024**. Todavia, essa estabilidade produtiva enfrenta pressões bióticas severas em janelas críticas de desenvolvimento. Tais ameaças são representadas em *benchmarks* de Visão Computacional, como o *dataset* IP102 (Wu, X. *et al.*, 2019), destacando-se:

- ***Conoderus scalaris* (Wireworm - Classe 17)**: Inseto de hábito holometábolo e comportamento edáfico, cujas larvas (larva-arame) atacam o sistema radicular e o mesocótilo das plântulas. A infestação compromete a emergência e o vigor inicial da cultura, podendo acarretar uma redução severa no estande de até 25% quando o ataque ocorre entre a semeadura e os estágios fenológicos V2/V3 (AEGRO, 2025). Representa um desafio para a visão computacional devido ao seu mimetismo com o solo e resíduos orgânicos.
- ***Agrotis ipsilon* (Black Cutworm - Classe 19)**: Praga de superfície caracterizada pelo comportamento alimentar de seccionamento transversal do colo das plântulas rente ao solo. Devido à voracidade e ao hábito da lagarta-rosca de destruir múltiplas plantas em sucessão na linha de plantio, as perdas de estande podem exceder 50% em áreas negligenciadas ou com monitoramento intempestivo (EMBRAPA, 2024). Sua detecção automática é dificultada pelo hábito noturno e pela tendência de se enrolar em "C" quando perturbada.
- ***Ostrinia nubilalis* (European Corn Borer - Classe 23)**: Inseto de importância econômica global e classificado como Praga Quarentenária Ausente (Categoria A1) no Brasil. Conforme detalhado por Cordeiro, Benito e Polez (2008), a introdução dessa espécie representaria um risco fitossanitário crítico, uma vez que suas larvas penetram nos colmos e espigas do milho, interrompendo o fluxo de fotoassimilados e fragilizando a estrutura mecânica da planta. A inclusão desta classe no treinamento do modelo visa a validação de sistemas de visão computacional (como armadilhas inteligentes baseadas em IoT) aplicados à defesa fitossanitária e ao alerta precoce em fronteiras e áreas de risco. O desafio computacional reside na identificação precisa de suas características morfológicas para evitar falsos negativos em barreiras de biossegurança.

A aplicação de modelos de Visão Computacional sob o paradigma *Data-centric AI* torna-se, portanto, um requisito técnico e jurídico. O **Artigo 10 da Lei 14.785/2023** exige que a comercialização de defensivos seja embasada em um diagnóstico no local de uso, permitindo expressamente o uso de registros digitais georreferenciados (fotos ou vídeos) para tal laudo (Brasil, 2023). Esta previsão legal valida o papel da IA na automação do diagnóstico fitossanitário e na transição para o uso assertivo de biodefensivos.

2.1.3.4 Manejo Integrado de Pragas (MIP) e sua relação com a AP

O MIP é uma abordagem ecológica que utiliza múltiplas táticas de controle para manter as populações de pragas abaixo de níveis economicamente danosos, minimizando riscos para o ambiente e a saúde humana (Dent; Binks, 2020). A AP potencializa o MIP ao fornecer informações espacialmente explícitas sobre a distribuição e a densidade de pragas, permitindo intervenções localizadas e precisas. Tecnologias de sensoriamento remoto embarcadas em UAVs, capazes de detectar estresses bióticos antes de sintomas visíveis, reforçam esse potencial ao gerar mapas detalhados do estado das plantas (Barbedo, 2019).

A integração entre MIP e AP resulta no conceito de Manejo Integrado de Pragas de Precisão, que incorpora a variabilidade espacial e temporal das populações de pragas e seus fatores reguladores nas estratégias de manejo (Kanwal *et al.*, 2022). Essa integração utiliza tecnologias como SIG, GPS, sensoriamento remoto e modelos preditivos para:

- Mapear a distribuição espacial de pragas e seus danos;
- Identificar padrões de infestação e fatores ambientais correlacionados;
- Prever surtos com base em dados históricos e condições atuais;
- Aplicar defensivos apenas onde e quando necessário, em doses ajustadas à intensidade da infestação;
- Preservar áreas de refúgio para inimigos naturais;
- Avaliar a eficácia das intervenções ao longo do tempo e do espaço.

Estudos empíricos no Brasil apontam que a adoção do MIP — especialmente nas unidades de referência do Programa MIP-Soja (Embrapa/Emater-PR) — reduziu as aplicações de defensivos de 5 para 2,6 vezes por safra (redução de 48%) e manteve a produtividade, demonstrando ganhos ambientais e econômicos significativos (Embrapa-Soja; Emater-PR, 2014).

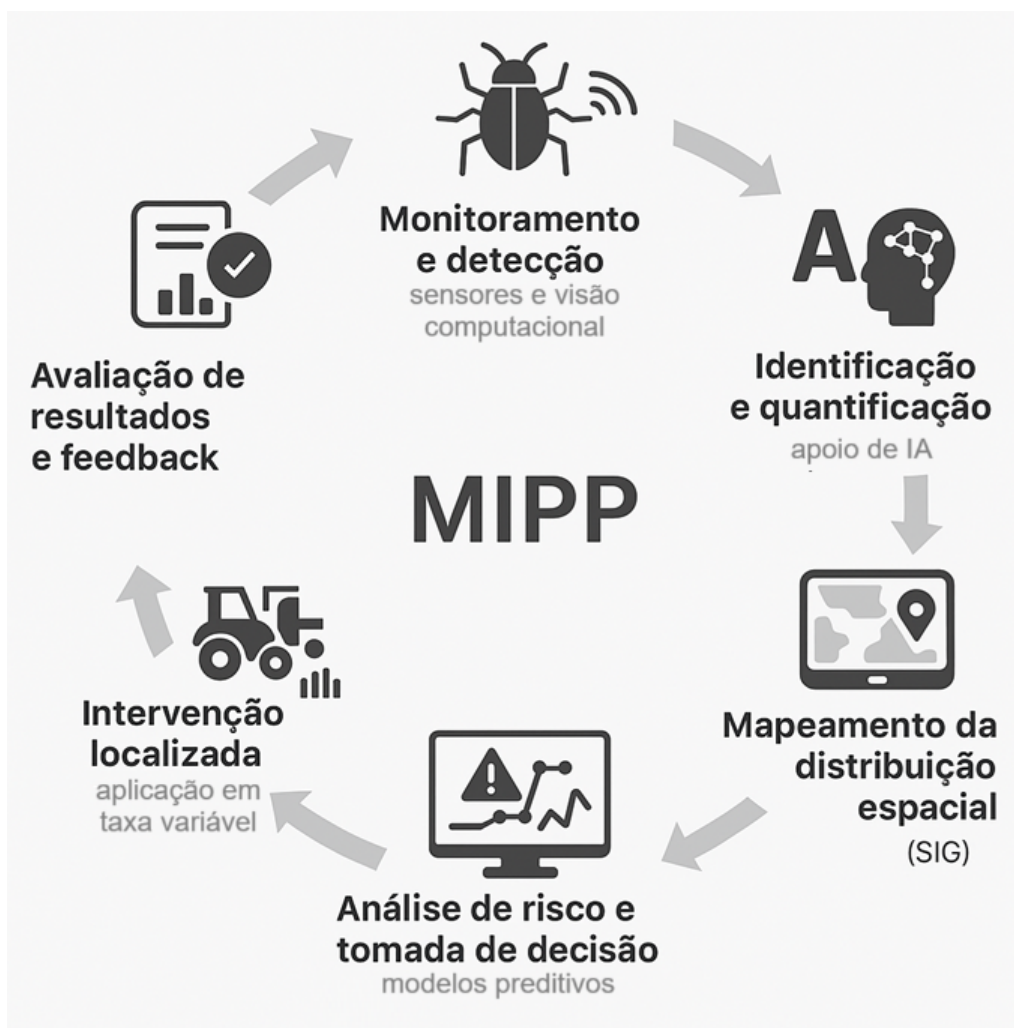


Figura 3 – Etapas do Manejo Integrado de Pragas de Precisão: da detecção à avaliação, integrando tecnologias como IA, SIG e VRT.

2.2 Aprendizado Profundo para Detecção de Objetos

O Aprendizado Profundo (*Deep Learning*) tornou-se uma ferramenta essencial em visão computacional, permitindo que modelos aprendam representações hierárquicas de características diretamente a partir de dados brutos. Essa abordagem eliminou a necessidade de extração manual de características, que era uma etapa crítica e limitante em sistemas de visão tradicionais (LeCun; Bengio; Hinton, 2015). Em tarefas complexas como a detecção de objetos, caracterizada por alta variabilidade visual, o aprendizado profundo oferece uma capacidade de generalização e precisão sem precedentes (Zhao *et al.*, 2019).

A base do aprendizado profundo em visão computacional são as Redes Neurais Convolucionais (CNNs), cuja arquitetura evoluiu de modelos pioneiros como o LeNet-5 (LeCun; Bottou *et al.*, 1998) para arquiteturas muito mais profundas e eficientes, como a ResNet (He *et al.*, 2016) e a EfficientNet (Tan; Le, 2019). Essas inovações, focadas em otimizar o fluxo de gradientes e a eficiência computacional, estabeleceram as CNNs como o

padrão para a maioria das tarefas de análise de imagem.

2.2.1 Paradigmas de Detecção de Objetos

Os detectores de objetos baseados em aprendizado profundo são categorizados principalmente em duas abordagens: duas etapas (*two-stage*) e uma etapa (*one-stage*) (Zou *et al.*, 2023). As abordagens de duas etapas, como a família R-CNN (Girshick *et al.*, 2014; Ren *et al.*, 2015), primeiro geram propostas de regiões de interesse e, em seguida, classificam essas regiões. Embora alcancem alta precisão, seu custo computacional é elevado, o que as torna menos adequadas para aplicações em tempo real.

Por outro lado, abordagens de uma etapa, como o *Single Shot MultiBox Detector* (SSD) (Liu, W. *et al.*, 2016) e a família *You Only Look Once* (YOLO) (Redmon *et al.*, 2016), tratam a detecção como um problema de regressão único, prevendo caixas delimitadoras e probabilidades de classe diretamente a partir da imagem inteira em uma única passagem. Essa arquitetura unificada resulta em uma velocidade de inferência significativamente maior, tornando-a ideal para aplicações que exigem processamento em tempo real, como o monitoramento de pragas em campo, que é o foco desta dissertação (Kamilaris; Prenafeta-Boldü, 2018).

2.2.2 A Família de Modelos YOLO (*You Only Look Once*)

Os modelos YOLO se destacam pelo seu equilíbrio entre velocidade e precisão. Desde sua primeira versão, a família YOLO passou por uma rápida evolução, incorporando os avanços mais recentes em arquiteturas de redes neurais e estratégias de treinamento (Zou *et al.*, 2023). As versões mais recentes, como YOLOv5 (Ultralytics, 2020), YOLOv8 (Ultralytics, 2023) e YOLOv11 (Ultralytics, 2024), que são objeto de estudo neste trabalho, apresentam uma arquitetura modular composta por três partes principais:

- **Backbone:** Uma CNN profunda (ex: CSPDarknet) responsável pela extração de características da imagem em diferentes escalas.
- **Neck:** Estruturas como a *Path Aggregation Network* (PANet) que agregam características de diferentes níveis do *backbone* para enriquecer a representação e melhorar a detecção de objetos de vários tamanhos.
- **Head:** A parte final da rede que realiza as previsões de caixas delimitadoras e classes. As versões mais recentes, como o YOLOv8, adotaram uma abordagem *anchor-free*, que simplifica o processo de detecção e melhora o desempenho em comparação com os métodos baseados em âncoras das versões anteriores.

O sucesso dos modelos YOLO também se deve às sofisticadas estratégias de aumento de dados (*data augmentation*), como *Mosaic* e *MixUp*, e às funções de perda avançadas, como a CIoU (*Complete Intersection over Union*), que otimizam diretamente a métrica de avaliação de caixas delimitadoras (Bochkovskiy; Wang, C.-Y.; Liao, 2020; Zheng *et al.*, 2020). Essa combinação de inovações arquiteturais e de treinamento permite que os modelos YOLO apresentem um equilíbrio superior entre precisão média (mAP) e latência de inferência em comparação com detectores de dois estágios, justificando sua aplicação em cenários de monitoramento agrícola em tempo real no escopo desta dissertação.

2.2.3 Detecção de Objetos na Agricultura de Precisão

A aplicação de detectores de objetos na agricultura tem impulsionado avanços significativos no monitoramento de culturas, na detecção de doenças e, crucialmente, na identificação de insetos-praga (Kamilaris; Prenafeta-Boldü, 2018). A capacidade de detectar e classificar pragas em tempo real permite a aplicação localizada de defensivos, uma prática central da Agricultura de Precisão que reduz custos e o impacto ambiental. Modelos como o YOLO têm sido empregados com sucesso para identificar diferentes espécies e estágios de maturidade de insetos em imagens de campo e armadilhas (Fuentes *et al.*, 2017; Neupane *et al.*, 2024).

No entanto, a aplicação em cenários agrícolas enfrenta desafios específicos, como a grande variabilidade nas condições de iluminação, a oclusão de objetos por folhagens e, principalmente, a escassez de dados anotados para treinar os modelos (Barbedo, 2016). A dificuldade em obter grandes conjuntos de dados anotados para espécies de pragas e seus estágios de maturidade torna o aprendizado com poucas amostras **Few-Shot Learning - FSL** uma área de pesquisa de grande relevância, motivando o desenvolvimento de estratégias de amostragem de dados, como as exploradas neste trabalho de Y. Wang *et al.* (2020). Gomes e D. L. Borges (2022) propuseram uma abordagem baseada em aprendizado com poucas amostras que considera os estágios de maturidade dos insetos, demonstrando resultados promissores, mesmo em cenários de alta similaridade visual entre classes.

2.3 Aprendizado com Poucas Amostras (*Few-Shot Learning - FSL*)

Embora os modelos de aprendizado profundo, como o YOLO, sejam extremamente poderosos, seu desempenho é tradicionalmente dependente de grandes volumes de dados rotulados para o treinamento. Em muitos domínios práticos, como na agricultura, a obtenção desses dados constitui um obstáculo significativo devido ao custo, ao tempo e à necessidade de especialistas para a anotação (Wang, Y. *et al.*, 2020). A detecção de pragas,

por exemplo, envolve uma vasta gama de espécies, estágios de maturidade e condições de captura, tornando inviável a criação de um conjunto de dados exaustivo.

Nesse contexto, é preciso distinguir conceitualmente o dado rotulado do anotado, termos frequentemente sobrepostos, mas com implicações distintas na Visão Computacional. O dado rotulado refere-se à atribuição de uma etiqueta global à imagem (classificação), indicando a presença de uma classe. Já o dado anotado exige um processo de marcação estruturada, onde se define a localização exata do objeto por meio de coordenadas espaciais, as caixas limitadoras. Na detecção de pragas, a anotação é a etapa mais crítica e onerosa, pois demanda que o especialista não apenas identifique a espécie, mas delimite cada indivíduo em cenários de alta oclusão e camuflagem, gerando os dados de referência necessários para o treinamento supervisionado.

O Aprendizado com Poucas Amostras (*Few-Shot Learning* - FSL) surge como uma solução para esse desafio, buscando desenvolver modelos capazes de generalizar a partir de um número muito limitado de amostras de treinamento. O objetivo é emular a capacidade humana de aprender novos conceitos rapidamente, aproveitando o conhecimento prévio para se adaptar a novas tarefas com poucas amostras (Wang, Y. *et al.*, 2020; Fei-Fei; Fergus; Perona, 2006). Gomes, L. d. A. B. Borges e D. L. Borges (2023) propuseram um método de fusão de características em múltiplas camadas, demonstrando ganhos consistentes de desempenho com menor complexidade, reforçando a importância da representação visual na generalização de modelos treinados com conjuntos reduzidos de amostras.

2.3.1 Abordagens em *Few-Shot Learning*

As estratégias de FSL fundamentam-se na capacidade de generalização a partir de um conhecimento prévio (*prior knowledge*), mitigando a escassez de dados no domínio alvo. Segundo a taxonomia consolidada por Y. Wang *et al.* (2020), as abordagens de FSL podem ser categorizadas sob três perspectivas fundamentais: dados, modelo e algoritmo. No escopo desta dissertação, o foco recai sobre a convergência entre o enriquecimento de dados e o ajuste fino de modelos:

- **Abordagens baseadas em dados:** Visam aumentar a experiência do modelo por meio do enriquecimento do conjunto de treinamento. Isso inclui desde técnicas convencionais de aumento de dados (Shorten; Khoshgoftaar, 2019) até estratégias de amostragem inteligente (*few-shot data sampling*), essenciais para selecionar instâncias que representem melhor a variância morfológica das pragas (Aboah *et al.*, 2023). A seleção baseada em métricas de nitidez e diversidade, explorada neste trabalho, alinha-se a essa vertente de *Data-centric AI*.
- **Abordagens baseadas em modelos (Transfer Learning):** Representam a estratégia

mais eficaz para a adaptação de detectores profundos. O paradigma consiste em aproveitar as hierarquias de características extraídas de grandes conjuntos de dados genéricos, como o COCO (Lin *et al.*, 2014), e transferi-las para o domínio agrícola (Kamilaris; Prenafeta-Boldü, 2018). O processo de ajuste fino (*fine-tuning*), associado ao congelamento seletivo de camadas (*layer freezing*), é empregado para evitar o esquecimento catastrófico e o sobreajuste (*overfitting*) em regimes de baixa amostragem (Yosinski *et al.*, 2014), servindo de base para a implementação dos modelos YOLO (*You Only Look Once*) nesta pesquisa (Ultralytics, 2023).

Embora métodos baseados em métricas ou meta-aprendizado sejam áreas ativas (Vinyals *et al.*, 2016), a combinação de aprendizado por transferência com estratégias de dados representa o caminho mais robusto para a Detecção de Objetos com Poucas Amostras (*Few-Shot Object Detection* - FSOD), especialmente com detectores de propósito geral (Wang, X. *et al.*, 2020; Huang *et al.*, 2025).

2.3.2 Detecção de Objetos com Poucas Amostras (FSOD)

A FSOD estende os desafios do FSL ao exigir não apenas a classificação semântica, mas a localização espacial precisa via regressão de caixas delimitadoras (Zou *et al.*, 2023). Essa tarefa é particularmente complexa no cenário agrícola devido à alta variabilidade de aparência dos insetos, oclusões por folhagens e o desequilíbrio entre o objeto e o plano de fundo (Kang *et al.*, 2019; Barbedo, 2016).

Nesta dissertação, a FSOD é aplicada na classificação de estágios de maturidade de insetos-praga, uma tarefa que exige que o modelo aprenda características discriminativas sutis com poucas amostras de suporte (Gomes; Borges, D. L., 2022). O sucesso desta adaptação depende criticamente da qualidade das amostras *K*-shot utilizadas (Wang, X. *et al.*, 2020). A avaliação do desempenho segue o rigor estatístico da área, utilizando a Precisão Média (*mean Average Precision* - mAP) como métrica primária para validar a eficácia das estratégias de amostragem propostas frente ao estado da arte (Wu, X. *et al.*, 2019; Lima *et al.*, 2024).

2.4 Estratégias de Amostragem de Dados para FSOD na Agricultura

A aplicação de modelos como YOLO em um regime de Aprendizado com Poucas Amostras (FSL) para a detecção de pragas agrícolas é uma abordagem poderosa, mas que herda e amplifica os desafios de ambas as áreas. A eficácia do aprendizado por transferência, especialmente o *fine-tuning*, depende fundamentalmente da qualidade e da representa-

tividade das poucas amostras utilizadas para o ajuste fino. Quando essas amostras são insuficientes ou mal selecionadas, o modelo pré-treinado pode não apenas falhar em aprender as características das novas classes, mas também sofrer de esquecimento catastrófico, perdendo o conhecimento generalista adquirido no pré-treinamento (Wang, Y. *et al.*, 2020). Portanto, a estratégia de como os dados de suporte são selecionados — a amostragem de dados — torna-se um fator determinante para o sucesso da tarefa.

2.4.1 Desafios Amplificados no Contexto Agrícola

Os problemas inerentes à detecção de objetos em campo são particularmente severos em um cenário com poucas amostras, onde cada imagem carrega um peso desproporcional no processo de aprendizado.

- **Variabilidade Intraclasse e Similaridade Interclasse:** Insetos-praga apresentam uma vasta gama de aparências dentro da mesma espécie devido a estágios de maturidade, dimorfismo sexual e polimorfismo. Ao mesmo tempo, espécies distintas (pragas, predadores, insetos neutros) podem ser visualmente muito parecidas (Liu, L. *et al.*, 2019). Com poucas amostras, é estatisticamente improvável que uma amostragem aleatória capture essa diversidade. O modelo pode aprender características espúrias de um único exemplar (e.g., uma pose ou condição de iluminação específica) e falhar em generalizar para a classe como um todo.
- **Qualidade da Imagem e Condições de Campo:** A aquisição de imagens em campo é descontrolada, resultando em variações extremas de iluminação, oclusão por folhagens, fundos complexos e artefatos como desfoque (Fuentes *et al.*, 2017). Em FSL, uma única imagem de baixa qualidade (e.g., desfocada ou com o inseto em sombra profunda) pode introduzir mais ruído do que sinal no processo de *fine-tuning*, degradando o desempenho do modelo em vez de melhorá-lo. A questão central passa a ser: é preferível treinar com uma imagem de baixa qualidade ou não treinar com ela?
- **Desequilíbrio de Classes e Raridade:** A distribuição de pragas na natureza é inerentemente desequilibrada. Estágios de vida mais curtos ou mais crípticos (como ovos e pupas) são naturalmente mais raros. Em um regime FSL, isso significa que, para algumas classes de interesse, o número de amostras disponíveis pode ser próximo de zero, tornando o *fine-tuning* quase impossível e exigindo abordagens que maximizem a informação de cada exemplar disponível (Mahlein *et al.*, 2017; Oliveira *et al.*, 2014).

Diante desses desafios, a seleção aleatória de amostras para o conjunto de suporte é uma estratégia de alto risco. Torna-se imperativo adotar métodos de **amostragem inteligente** que visem selecionar um subconjunto de dados que seja o mais informativo e representativo possível para guiar o *fine-tuning* do modelo.

2.4.2 Estratégias de Amostragem Inteligente para Ajuste Fino (*Fine-Tuning*)

O objetivo da amostragem inteligente é substituir a incerteza da seleção aleatória por um processo deliberado que otimiza o conjunto de suporte (*support set*) para o *fine-tuning*. As duas principais filosofias, que são o foco desta dissertação, são a seleção por qualidade e a seleção por diversidade.

2.4.2.1 Amostragem Baseada na Qualidade da Imagem

Esta estratégia parte da premissa de que, em um regime de dados extremamente limitados, a prioridade é fornecer ao modelo os sinais de aprendizado mais claros e livres de ruído possíveis. Amostras de alta qualidade podem ajudar o modelo a aprender as características essenciais do objeto de forma mais eficiente durante o *fine-tuning*. Os critérios de qualidade podem ser quantificados por diversas métricas, sendo a **nitidez (sharpness)** uma das mais importantes para a detecção de pequenos objetos, como insetos.

A nitidez pode ser estimada computacionalmente aplicando-se um filtro Laplaciano à imagem e calculando a variância do resultado. Uma variância mais alta indica bordas mais bem definidas e, portanto, uma imagem mais nítida (Pech-Pacheco *et al.*, 2000). Ao classificar as imagens candidatas por essa métrica, pode-se selecionar as K imagens mais nítidas para compor o conjunto de suporte. A hipótese é que essas imagens, ricas em detalhes de alta frequência, permitirão ao detector aprender contornos e texturas discriminativas com maior eficácia.

Outras métricas de qualidade, como contraste, brilho e ausência de oclusão, também podem ser utilizadas. A desvantagem potencial dessa abordagem é o risco de selecionar um conjunto de amostras de alta qualidade, porém visualmente muito homogêneo (e.g., todas as fotos tiradas no mesmo ângulo e iluminação), o que poderia limitar a capacidade de generalização do modelo para condições de campo mais variadas.

2.4.2.2 Amostragem Baseada na Diversidade

Em contraposição à estratégia de qualidade, a amostragem por diversidade visa compor um conjunto de suporte que capture a máxima variabilidade visual da classe. A ideia é que, ao expor o modelo a uma gama mais ampla de aparências durante o *fine-tuning*, ele se torne mais robusto e capaz de generalizar para amostras não vistas. Esta abordagem é particularmente relevante para o domínio agrícola, onde as condições são heterogêneas.

Uma maneira de implementar essa estratégia é por meio da análise das características da imagem. Em vez de focar apenas no objeto, analisa-se todo o contexto em que ele aparece. Por exemplo, pode-se usar um modelo de extração de características (como uma CNN pré-treinada) para obter um vetor de características de cada imagem e, em seguida, aplicar algoritmos de *clustering* (como K-Means) para agrupar as imagens em clusters visualmente

semelhantes (Sener; Savarese, 2018). A seleção de um representante de cada um dos K clusters principais garante que o conjunto de suporte contenha uma variedade de cores, iluminações e contextos.

Esta abordagem, explorada neste trabalho, busca garantir que o modelo não aprenda a associar o inseto a um tipo específico de fundo (e.g., apenas folhas verdes e bem iluminadas), forçando-o a focar nas características intrínsecas do próprio inseto. A combinação de diferentes imagens atua como uma forma implícita de regularização, melhorando a robustez do detector.

2.4.2.3 Diferença entre Amostragem e Aumento de Dados

É crucial entender que a amostragem de dados e o aumento de dados são estratégias complementares. A amostragem seleciona o "material bruto" para o treinamento, enquanto o aumento de dados expande artificialmente esse material. Uma estratégia robusta combina ambos: primeiro, seleciona-se um conjunto de suporte de alta qualidade ou alta diversidade; em seguida, aplicam-se técnicas de aumento de dados (rotação, *mosaic*, *mixup*, etc.) a essas amostras selecionadas para criar um conjunto de treinamento final mais rico e variado (Shorten; Khoshgoftaar, 2019). Essa abordagem sinérgica, adotada nesta dissertação, visa maximizar a informação extraída de um conjunto de dados inerentemente limitado (Fan *et al.*, 2020), otimizando o processo de *fine-tuning* dos modelos YOLO para a desafiadora tarefa de classificação de maturidade de insetos-praga.

3 Materiais e Métodos

Esta seção detalha a metodologia empregada para investigar o impacto de estratégias de amostragem de dados e configurações de aprendizado por transferência no desempenho dos detectores de objetos da família YOLO (v5, v8 e v11) para a tarefa de classificação de maturidade de insetos-praga em um cenário de poucos dados. O desenho experimental foi estruturado para permitir uma análise sistemática e aprofundada dos fatores que influenciam a eficácia desses modelos em um contexto agrícola realista.

3.1 Conjunto de Dados

O estudo foi conduzido utilizando o conjunto de dados (*dataset*) **IP-FSL** (Gomes; Borges, D. L., 2022), um subconjunto curado do IP102 (Wu, X. *et al.*, 2019), projetado especificamente para cenários de *Few-Shot Learning* (FSL). O IP102 é um *benchmark* de larga escala para reconhecimento de pragas agrícolas, contendo aproximadamente 75.000 imagens que abrangem 102 classes de insetos em diversas condições de campo e estágios de desenvolvimento.

O IP-FSL, por sua vez, foi criado para avaliar a capacidade de generalização dos modelos em um regime de dados limitados, sendo composto por 6.817 imagens distribuídas em 142 classes, das quais 97 são de insetos adultos e 45 são de estágios jovens (compostos por ovos, larvas, pupas). A Tabela 2 detalha a estrutura do *dataset*. A separação explícita entre os estágios de maturidade permite uma análise refinada de como os modelos lidam com a alta variabilidade intraclasse e a similaridade interclasse, desafios comuns na detecção de pragas.

Tabela 2 – Estrutura do Dataset IP-FSL.

Subconjunto	Classes	Imagens
Estágio jovem	45	2050
Estágio Adulto	97	4767
Total	142	6817

Fonte: Adaptada de Gomes e D. L. Borges (2022).

3.1.1 Classificação por Estágios de Maturidade

A correta identificação do estágio de desenvolvimento dos insetos-praga é um requisito fundamental para o Manejo Integrado de Pragas (MIP). Como observado por Neupane *et*

al. (2024), modelos de Inteligência Artificial têm demonstrado alta capacidade em classificar estágios de desenvolvimento, o que permite o uso de fotografias de ciência comunitária para monitoramento conservacionista e agrícola. No contexto desta pesquisa, a distinção entre as fases de vida é crucial, dado que a morfologia e o comportamento de dano de espécimes jovens (ninfas ou larvas) diferem significativamente dos adultos.

Para a estruturação dos experimentos de *Few-Shot Learning* (FSL), os dados foram categorizados em dois grandes grupos de maturidade, seguindo a taxonomia proposta em *datasets* de referência como o IP102 (Wu, X. *et al.*, 2019):

- **Estágios Jovens:** Incluem as fases jovens do ciclo de vida, como larvas (em insetos holometábolos) ou ninfas (em hemimetábolos). Nesta fase, o foco da detecção reside na identificação precoce de infestações que podem causar danos severos ao estande da cultura (Corteva Agriscience, 2024).
- **Adultos:** Referem-se aos espécimes em fase reprodutiva, geralmente possuindo maior mobilidade e características morfológicas distintas, como a presença de asas funcionais e órgãos reprodutores desenvolvidos.

A separação dessas classes no treinamento de modelos permite que a rede aprenda características discriminativas específicas de cada fase. Esta abordagem está alinhada ao trabalho de Gomes e D. L. Borges (2022), que destaca que a inclusão da classificação por estágios de maturidade em abordagens de *few-shot* não apenas aumenta a granularidade da detecção, mas também fornece informações biológicas valiosas para a tomada de decisão no campo.

Além disso, a diferenciação por maturidade mitiga erros de falso-negativo onde espécimes jovens, por vezes menores ou camuflados, poderiam ser ignorados por modelos treinados exclusivamente com imagens de adultos. Este refinamento metodológico reforça a perspectiva de *Data-centric AI*, priorizando a qualidade e o significado biológico do rótulo sobre o simples volume de dados.

3.1.2 Seleção das Classes para o Estudo

A definição das classes alvo para esta pesquisa pautou-se no **potencial de dano fitossanitário** que estas espécies representam para a cultura do milho (*Zea mays* L.), aliado aos desafios de detecção inerentes aos modelos de Visão Computacional. Foram selecionadas três categorias provenientes do conjunto de dados **IP-FSL** (Gomes; Borges, D. L., 2022).

A estratégia adotada fundamenta-se em uma abordagem integrada de **monitoramento preditivo e preventivo**. O caráter **preditivo** está associado à detecção de indivíduos em estágios jovens (larvais), nos quais o dano à cultura já se manifesta ou é iminente. Por

sua vez, o caráter **preventivo** relaciona-se à identificação de insetos no estágio adulto, permitindo inferir padrões de dispersão, oviposição e dinâmica populacional, viabilizando intervenções antecipadas antes da ocorrência do dano econômico.

Esta estratégia justifica-se pela necessidade de suporte à decisão no Manejo Integrado de Pragas (MIP), conforme detalhado para cada grupo:

- ***Conoderus scalaris* (Classe 17):**

- **Caráter Preventivo (Adulto):** A detecção do besouro-clic permite o mapeamento de áreas de risco para oviposição antes do plantio ou em estágios iniciais, mitigando a infestação subterrânea.
- **Caráter Preditivo (jovem):** A identificação de larvas-aramé no solo ou em raízes fornece subsídios para prever perdas de estande e vigor radicular (AEGRO, 2025), permitindo intervenções focadas no mesocótilo.

- ***Agrotis ipsilon* (Classe 19):**

- **Caráter Preventivo (Adulto):** O monitoramento de mariposas adultas atua como um sistema de alerta precoce para a presença de voos de dispersão, visando prevenir a eclosão massiva sob a palhada (SPD).
- **Caráter Preditivo (jovem):** A detecção da lagarta-rosca permite prever o seccionamento de plântulas em sucessão na linha de plantio (EMBRAPA, 2024), estimando a necessidade de replantio imediato.

- ***Ostrinia nubilalis* (Classe 23):**

- **Caráter Preventivo (Adulto):** A identificação de adultos nas folhas auxilia na interrupção do ciclo reprodutivo e prevenção de posturas em áreas de refúgio e milho Bt.
- **Caráter Preditivo e de Biossegurança (jovem):** Sendo a *Ostrinia nubilalis* uma Praga Quarentenária Ausente no Brasil, a identificação de larvas em instares iniciais atua como uma barreira de alerta precoce em fronteiras ou áreas de risco. Essa antecipação é fundamental para evitar a introdução e o estabelecimento de uma espécie que, segundo Cordeiro, Benito e Polez (2008), causaria danos fisiológicos e estruturais severos caso introduzida no bioma nacional.

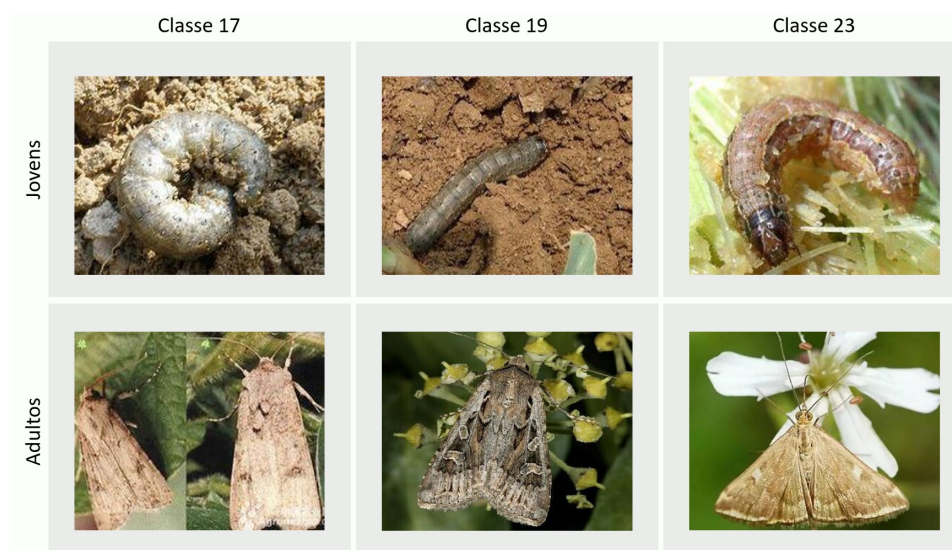
Exemplos dessas classes do IP-FSL com dois estágios de maturidade são ilustrados na Figura 4.

Tabela 3 – Funcionalidades dos modelos especializados por estágio biológico.

Praga Alvo	Estágio	Caráter do Modelo	Ação no MIP
<i>Conoderus spp.</i>	Adulto	Preventivo	Mapeamento de oviposição
	Jovem	Preditivo	Estimativa de perda de estande
<i>Agrotis ipsilon</i>	Adulto	Preventivo	Alerta de dispersão/voo
	Jovem	Preditivo	Diagnóstico de corte de plantas
<i>Ostrinia nubilalis</i>	Adulto	Preventivo	Prevenção de postura foliar
	Jovem	Preditivo	Predição de galerias no colmo

Fonte: Elaborada pela autora.

Figura 4 – Exemplos de classes do IP-FSL com dois estágios de maturidade (jovens e adultos, presentes nos subconjuntos das classes 17, 19 e 23).



Fonte: Adaptada de Gomes e D. L. Borges (2022).

3.2 Diretrizes para Aquisição e Qualidade de Imagens

A eficácia de modelos treinados em regime *Few-Shot Learning* (FSL) é altamente sensível à variabilidade e à qualidade das amostras de suporte. Conforme observado na Figura 4, a distinção entre estágios de maturidade exige a preservação de detalhes morfológicos sutis. Para fundamentar a curadoria do conjunto de dados e estabelecer diretrizes para futuras expansões do *dataset*, adotou-se um protocolo de aquisição baseado nos desafios elencados por Barbedo (2016):

1. **Condições de Iluminação e Brilho:** Deve-se priorizar a luz natural difusa. A incidência direta de luz solar sobre o exoesqueleto de espécimes adultos, como o besouro metálico *Agrotis ipsilon* (Classe 19), gera reflexos especulares que mascaram caracte-

rísticas cromáticas essenciais. O protocolo recomenda o uso de difusores em campo para uniformizar a iluminação.

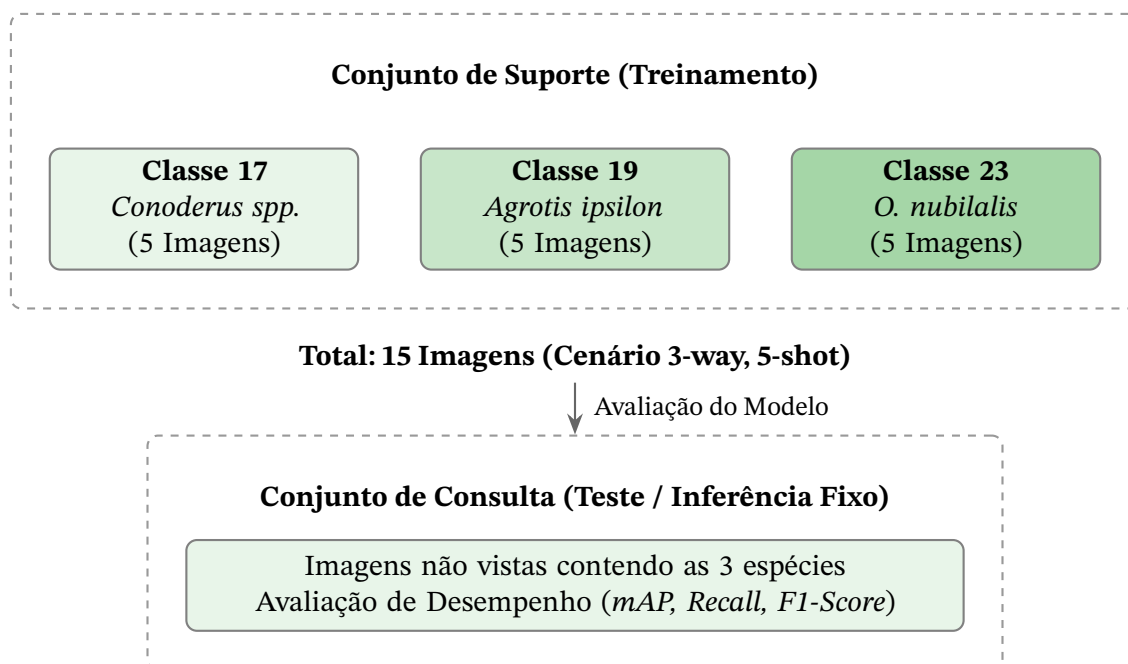
2. **Nitidez e Plano Focal:** Dado que o estágio jovem de espécies como *Ostrinia nubilalis* (Classe 23) apresenta morfologia cilíndrica e alongada, o foco deve ser mantido no plano central do corpo do inseto. A falta de nitidez compromete a extração da Variância Laplaciana (base da Estratégia I, Seção 3.5.2.1), dificultando a convergência do modelo (Pech-Pacheco *et al.*, 2000).
3. **Padronização do Background:** Embora o cenário agrícola seja inerentemente complexo, a aquisição deve buscar o contraste adequado entre a praga e o substrato (folha ou solo). Fundos com excesso de detritos orgânicos podem induzir o modelo ao erro de "viés de fundo", onde a rede aprende o contexto em vez do objeto de interesse.
4. **Angulação e Perspectiva:** Recomenda-se a captura em ângulo zenital (90°) para a identificação de proporções corporais em larvas, e ângulos laterais para adultos, visando capturar a inserção alar e a segmentação abdominal, pontos-chave na distinção de maturidade (Neupane *et al.*, 2024).

Este protocolo não apenas assegura a qualidade das amostras utilizadas neste estudo, mas reforça o pilar de *Data-centric AI*, onde a curadoria rigorosa da imagem precede a complexidade da arquitetura profunda.

3.2.1 Dimensionamento do Conjunto de Dados e Restrições de Amostragem

Para os experimentos desta dissertação, foi adotada uma configuração de **5-shots** e **3-ways**. Isso significa que, para cada experimento, foram selecionadas 5 imagens de cada uma das 3 espécies de insetos, totalizando 15 imagens para cada estágio de maturidade (jovem e adulto). Essa configuração está alinhada com as práticas da literatura de FSL, que frequentemente utilizam entre 2 e 10 exemplos por classe (Wang, Y. *et al.*, 2020; Snell; Swersky; Zemel, 2017). A escolha de 5-shots oferece um equilíbrio entre a restrição de dados, que simula um cenário realista de escassez, e a quantidade mínima de informação necessária para que o modelo possa construir representações robustas durante o *fine-tuning* (Vinyals *et al.*, 2016; Snell; Swersky; Zemel, 2017).

Figura 5 – Diagrama esquemático da configuração estrutural de *Few-Shot Learning* (3-way, 5-shot), ilustrando a constituição do Conjunto de Suporte para o aprendizado das representações e a posterior avaliação no Conjunto de Consulta fixo.



Fonte: Elaborada pela autora.

3.3 Aumento de Dados Híbrido e Invariância de Domínio

Para mitigar o risco de sobreajuste (*overfitting*) inerente ao cenário de *Few-Shot Learning* (FSL) e ampliar a robustez do detector frente às variações ambientais do cenário agrícola, adotou-se uma estratégia de aumento de dados híbrida, composta por etapas de processamento *offline* (estático) e *online* (dinâmico).

3.3.1 Aumento Offline: Simulação de Ruído de Captura

O aumento *offline* foi projetado para simular as condições estocásticas de captura em campo, como instabilidade luminosa e limitações ópticas de sensores embarcados (Kamilaris; Prenafeta-Boldü, 2018). Para cada imagem original do conjunto de treinamento, foram geradas três versões sintéticas (proporção 1:3), totalizando o parâmetro *offline_augs_per_image* = 3 definido no protocolo experimental. As transformações aplicadas concentraram-se na variabilidade fotométrica:

- **Ajustes de Iluminação:** Variações de brilho, contraste e saturação em uma faixa de $[0,8; 1,2]$.

- **Perturbações Ópticas:** Aplicação de desfoque Gaussiano e filtros de nitidez (*sharpening*), mimetizando falhas de autofoco ou desfoque de movimento (*motion blur*) causados pela oscilação da vegetação (Pech-Pacheco *et al.*, 2000).

Diferente das transformações geométricas, estas alterações preservam a validade das anotações originais (*bounding boxes*), garantindo que o modelo aprenda características visuais invariantes à qualidade do sensor (Shorten; Khoshgoftaar, 2019).

3.3.2 Dinâmica Condicional e Atenuação de Hiperparâmetros (HSV)

O desenho experimental desta pesquisa previu a avaliação do impacto do aumento de dados sob uma ótica condicional (presença versus ausência da etapa *offline*). Essa formulação exige uma coordenação cuidadosa com os hiperparâmetros nativos das arquiteturas YOLO para evitar o fenômeno de *Domain Shift* (deslocamento de domínio) causado por distorção cromática (Neupane *et al.*, 2024).

Dessa forma, a etapa de aumento de dados *online* — executada dinamicamente pelo *framework* durante o *loop* de treinamento — foi parametrizada de duas maneiras distintas, dependendo do cenário avaliado:

1. **Cenário de Controle (Sem Aumento Offline):** O modelo é alimentado apenas com as 15 amostras originais do conjunto de suporte. Neste caso, o aumento *online* opera em sua configuração padrão (*default*), aplicando transformações intensas no espaço de cor HSV e variações espaciais (como *Mosaic* e *Flip*), concebidas originalmente pelos autores da arquitetura YOLO.
2. **Cenário Híbrido (Com Aumento Offline):** Quando a geração sintética *offline* é ativada (proporção 1:3), a aplicação cumulativa de variações de cor — tanto na etapa estática quanto no *loop* de treino — descaracteriza severamente a morfologia fenotípica das pragas. Para neutralizar este efeito, implementou-se uma estratégia de **atenuação (*throttling*)** dos hiperparâmetros fotométricos da rede.

No cenário híbrido, enquanto o aumento *online* permaneceu responsável pela invariância espacial e geométrica, as frações de ganho de Matiz (*hsv_h*), Saturação (*hsv_s*) e Brilho (*hsv_v*) foram severamente restritas. A Tabela 4 contrapõe os hiperparâmetros utilizados no cenário de controle em relação àqueles adotados no cenário híbrido.

Esta dinâmica condicional assegura que o modelo receba um grau ótimo de variabilidade, permitindo investigar cientificamente se a simulação dedicada de ruído de sensores (*offline*) supera a técnica de augmentação genérica nativa da rede YOLO (*online*).

Tabela 4 – Comparativo de Hiperparâmetros Fotométricos Dinâmicos: Controle vs. Híbrido.

Parâmetro	Descrição	Padrão (Controle)	Atenuado (Híbrido)
hsv_h	Fração de ganho de matiz (<i>hue</i>)	0.015	0.000
hsv_s	Fração de ganho de saturação	0.700	0.200
hsv_v	Fração de ganho de brilho (<i>value</i>)	0.400	0.200
<i>mosaic</i>	Augmentação espacial de mosaico	1.000	1.000

Fonte: Elaborada pela autora.

Nota: O modo híbrido atenua as distorções fotométricas para preservar a fidelidade colorimétrica das pragas (essencial devido ao criptismo do estágio jovem), enquanto mantém a augmentação espacial (*mosaic*) inalterada.

3.4 Arquiteturas dos Modelos

A seleção dos modelos para este estudo pautou-se na necessidade de equilibrar a acurácia diagnóstica com a eficiência computacional, requisito primordial para a detecção de pragas agrícolas em dispositivos de borda. Foram selecionadas três gerações da família YOLO (*You Only Look Once*): **YOLOv5su**, **YOLOv8n** e **YOLOv11n**.

O **YOLOv5su** representa uma versão atualizada (*Updated*) da arquitetura clássica YOLOv5. Diferente das versões originais de 2020, o modelo *su* incorpora uma *Decoupled Head* (Cabeça de Detecção Desacoplada), separando as tarefas de classificação e localização de caixas delimitadoras. Esta modificação arquitetural alinha o mecanismo de predição do YOLOv5 aos padrões modernos das versões subseqüentes. Neste trabalho, o YOLOv5su é adotado como um *baseline* de maior capacidade (categoria *Small*), possuindo aproximadamente 9,1 milhões de parâmetros.

As variantes **YOLOv8n** e **YOLOv11n** representam o estado da arte em modelos ultra-leves (categoria *Nano*). O YOLOv8 introduziu uma abordagem *anchor-free*, eliminando a necessidade de caixas âncoras pré-definidas e otimizando o fluxo de gradientes através de um *backbone* CSPDarknet modificado. Já o YOLOv11, a iteração mais recente da família, introduz o bloco *C3k2*, uma evolução do módulo C3 que utiliza kernels de tamanhos variados para uma extração de características mais granular, mantendo uma contagem de parâmetros reduzida.

A Tabela 5 detalha as disparidades estruturais entre os modelos. A decisão metodológica de comparar um modelo de escala *Small* (v5su) com modelos de escala *Nano* (v8n e v11n) visa investigar a hipótese de que as inovações arquiteturais recentes e a melhoria na eficiência dos *backbones* podem compensar a redução drástica (superior a 70%) no número de parâmetros, mantendo a viabilidade técnica em cenários de *Few-Shot Learning*.

Tabela 5 – Especificações técnicas e complexidade computacional das arquiteturas selecionadas.

Modelo	Versão/Escala	Mecanismo	Parâmetros (M)	GFLOPs	Entrada (px)
YOLOv5su	v6.1+ (Small)	Anchor-based*	9,1	24,0	640
YOLOv8n	v8.0 (Nano)	Anchor-free	3,2	8,7	640
YOLOv11n	v11.0 (Nano)	Anchor-free	2,6	6,5	640

Fonte: Elaborada pela autora.

* **Nota:** O YOLOv5su utiliza *Decoupled Heads* integradas ao ecossistema moderno da Ultralytics.

3.4.1 Inicialização e Aprendizado por Transferência

Dada a especificidade do domínio agrícola e a disponibilidade limitada de amostras anotadas, os modelos não foram treinados a partir de uma inicialização aleatória de pesos. Em vez disso, aplicou-se a técnica de **Aprendizado por Transferência** (*Transfer Learning*).

Esta abordagem consiste em reaproveitar os parâmetros (pesos) de modelos previamente treinados em conjuntos de dados de larga escala, como o *dataset COCO* (Lin et al., 2014), adotado nesta pesquisa, o qual contém mais de 330 mil imagens distribuídas em 80 categorias genéricas. Tecnicamente, essa estratégia permite que a rede neural inicie o processo de treinamento já dotada da capacidade de detectar características visuais fundamentais — como bordas, formas geométricas e texturas básicas — antes mesmo de ser exposta aos dados específicos do domínio agrícola.

A partir dessa base de conhecimento genérico, realizou-se o **Ajuste Fino** (*Fine-tuning*) das camadas da rede para que os extratores de características se especializassem na morfologia detalhada das pragas alvo desta pesquisa. Essa metodologia é essencial para mitigar o risco de sobreajuste (*overfitting*) e garantir a convergência do modelo em cenários de aprendizado com poucos dados (*Few-Shot Learning*).

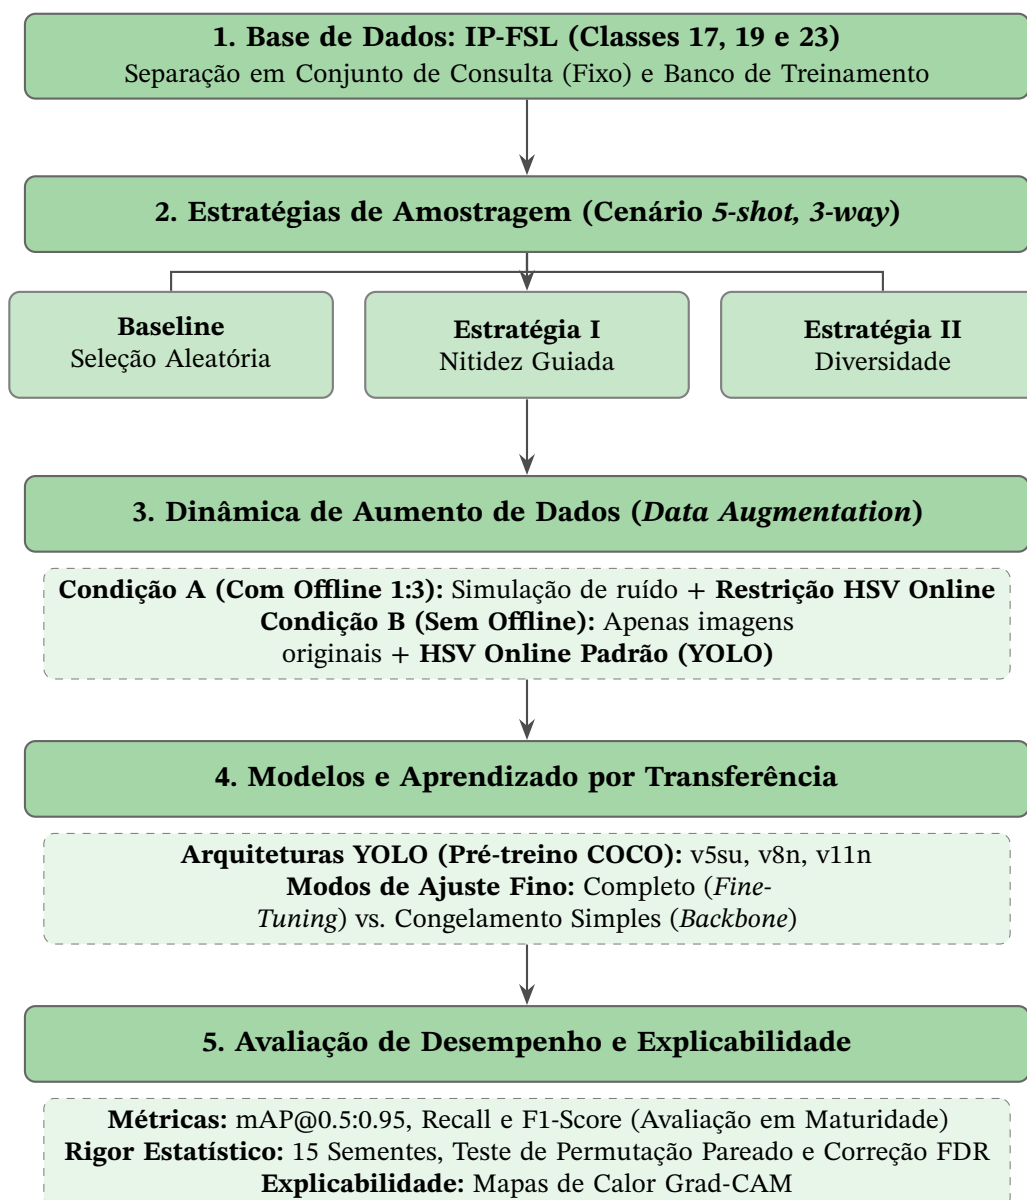
3.5 Desenho Experimental

O desenho experimental foi centrado em uma análise comparativa multifatorial, avaliando o desempenho dos modelos YOLOv5su, YOLOv8n e YOLOv11n sob diferentes condições.

3.5.1 Configurações de Treinamento e Hiperparâmetros

Para garantir a reprodutibilidade computacional e a justiça na comparação entre os modelos e estratégias, um conjunto rigoroso de hiperparâmetros foi mantido fixo em todos os experimentos. O tamanho do lote (*batch size*) foi definido como 8, e a resolução geométrica de entrada das imagens padronizada em 640×640 pixels para todas as arquiteturas (YOLOv5su,

Figura 6 – Macrofluxograma do desenho experimental proposto para detecção de pragas em regime de *few-shot learning*.



Fonte: Elaborada pela autora (2026).

Nota: O *pipeline* evidencia o fluxo sequencial desde a curadoria da base de dados até a validação rigorosa via *Grad-CAM* e testes de hipótese.

YOLOv8n e YOLOv11n). O treinamento de cada modelo estendeu-se por um limite máximo de 150 épocas.

Além disso, para avaliar o ganho real das estratégias de amostragem sem o viés de variação do conjunto de teste, utilizou-se uma separação fixa do conjunto de validação e teste. Dessa forma, as diferentes amostragens propostas pelas Estratégias I, II e pela Seleção Aleatória operaram estritamente sobre o conjunto de treinamento, sendo avaliadas contra

as mesmas imagens de consulta.

No escopo da avaliação das predições, uma detecção foi contabilizada como Verdadeiro Positivo (TP) se, e somente se, satisfizesse dois critérios simultâneos: apresentar uma Interseção sobre União (IoU) geométrica igual ou superior a 0,5 em relação à caixa delimitadora anotada manualmente, e prever corretamente o rótulo de maturidade da praga (Jovem ou Adulto). Para o processo de inferência, o limiar de confiança mínimo adotado foi de 0,25, aliado a um limiar de Supressão Não Máxima (NMS) de 0,45.

Por fim, no nível de *hardware*, adotou-se o determinismo estrito na Unidade de Processamento Gráfico (GPU). O *backend* CuDNN do *framework* PyTorch foi configurado no modo determinístico (`deterministic = True` e `benchmark = False`). Essa configuração assegura que as 15 repetições estatísticas executadas variem unicamente em função da semente estocástica inicial definida metodologicamente, anulando variações de concorrência computacional.

3.5.1.1 Configuração da Linha de Base (Pré-treino COCO)

Para estabelecer uma linha de base de desempenho, avaliamos os modelos YOLO em seu estado inicial de aprendizado por transferência (época zero). Isso mede a capacidade dos modelos de detectar objetos de interesse sem qualquer exposição prévia ao domínio alvo durante o treinamento. A avaliação foi conduzida utilizando os modelos oficiais com pesos pré-treinados no *dataset* COCO (Lin *et al.*, 2014). O *dataset* COCO compreende 80 categorias de objetos comuns, nenhuma das quais é uma espécie de inseto específica, garantindo, assim, uma avaliação rigorosa do estado pré-treinado frente ao nosso conjunto de dados de pragas agrícolas. Essa lacuna de domínio entre categorias de objetos gerais e pragas agrícolas especializadas torna a avaliação da época zero particularmente desafiadora; no entanto, proporciona uma avaliação realista de quão bem os modelos pré-treinados conseguem generalizar para domínios não vistos sem treinamento adicional.

Os resultados desta linha de base são apresentados no Capítulo 4, fornecendo um *benchmark* claro contra o qual as estratégias de *few-shot* são comparadas.

3.5.2 Estratégias Data-Cêntricas

Duas estratégias de amostragem de dados foram desenvolvidas e avaliadas, comparando-se com uma linha de base de seleção aleatória.

3.5.2.1 Estratégia I: Amostragem Guiada pela Nitidez

Esta estratégia visa otimizar o conjunto de poucas imagens para treinamento, priorizando amostras visualmente mais informativas e com transições estruturais mais marcadas.

A seleção é baseada na métrica de **nitidez**, calculada a partir da variância do operador Laplaciano aplicado à imagem.

Originalmente, este método foi proposto por Pech-Pacheco *et al.* (2000) no contexto de microscopia de campo claro. No trabalho de referência, os autores buscaram determinar algoritmos rápidos e robustos de autofocus para automatizar a detecção e identificação de diatomáceas (algas unicelulares). A métrica avaliava um empilhamento de imagens sequenciais de um mesmo organismo em diferentes planos focais (movimentação no eixo Z) para encontrar a captura com o foco perfeito.

No contexto da identificação de pragas agrícolas abordada nesta dissertação, o princípio matemático foi transposto do controle físico de lentes de microscópios para um *pipeline* de seleção de imagens em *software*. A aplicação do filtro Laplaciano, por ser um operador de segunda derivada, reage a mudanças de intensidade espacial (Pech-Pacheco *et al.*, 2000).

Matematicamente, dada uma imagem em tons de cinza $I(x,y)$, o Laplaciano $\nabla^2 I$ é definido como a soma das segundas derivadas espaciais não mistas:

$$\nabla^2 I = \frac{\partial^2 I}{\partial x^2} + \frac{\partial^2 I}{\partial y^2}, \quad (3.1)$$

O escore de nitidez (S) de cada imagem é então obtido pelo cálculo da variância global da matriz resultante da convolução da imagem com o filtro Laplaciano:

$$S = \sigma^2 = \frac{1}{M \times N} \sum_{x=1}^M \sum_{y=1}^N (\nabla^2 I(x,y) - \mu)^2, \quad (3.2)$$

onde M e N representam as dimensões da imagem em pixels e μ é o valor médio de $\nabla^2 I(x,y)$.

Imagens desfocadas apresentam transições de cor suaves, resultando em baixa variância. Em contrapartida, contornos perfeitamente focados apresentam bordas contrastantes, maximizando a variância calculada (Pech-Pacheco *et al.*, 2000).

Do ponto de vista prático da engenharia de *software*, essa fundamentação teórica foi traduzida de forma computacionalmente eficiente utilizando a biblioteca OpenCV. O Algoritmo 3.1 ilustra a implementação exata utilizada neste trabalho para atribuir a nota de nitidez a cada amostra do *dataset*.

Código 3.1 – Cálculo computacional do escore de nitidez utilizando a variância do Laplaciano.

```

1 def _sharpness_score(img_bgr: np.ndarray) -> float:
2     gray = cv2.cvtColor(img_bgr, cv2.COLOR_BGR2GRAY)
3     return float(cv2.Laplacian(gray, cv2.CV_64F).var())

```

Fonte: Elaborado pela autora.

A hipótese central desta estratégia é que, em um cenário com escassez de dados, fornecer ao modelo YOLO as amostras com a maior definição computacional de contornos

acelera o aprendizado das características morfológicas discriminativas fundamentais para a correta classificação do estágio de maturidade do inseto.

3.5.2.2 Estratégia II: Amostragem por Diversidade Visual Multivariada

Uma revisão recente publicada por [Aziz et al. \(2025\)](#) destaca como técnicas de sensoriamento remoto e inteligência artificial têm transformado o manejo de pragas, enfatizando a importância da variabilidade contextual (iluminação, padrões morfológicos e estrutura da vegetação) para a robustez dos modelos de detecção. Esse panorama reforça a motivação da Estratégia II, que adota uma abordagem centrada em dados para garantir que o conjunto de treinamento contenha a máxima variabilidade visual possível da praga.

O conceito de amostragem inteligente para balanceamento de cenários, proposto originalmente por [Aboah et al. \(2023\)](#), foi adaptado para o domínio agrícola. Nesta pesquisa, a classificação de cenários foi substituída pela extração de um vetor de características multivariado que descreve a imagem como um todo. Para cada amostra do conjunto de dados, o algoritmo extrai três componentes descritores:

1. **Histograma de Cores (HSV):** A imagem é convertida para o espaço de cores HSV, conhecido por sua robustez a variações de iluminação em ambientes de campo ([Hamuda et al., 2017](#)). O algoritmo extrai histogramas independentes para os canais de Matiz, Saturação e Valor, utilizando 16 subdivisões por canal, formando o perfil de cor da amostra.
2. **Descritor de Textura (LBP):** A imagem é convertida para tons de cinza e submetida ao descritor de Padrões Binários Locais (*Local Binary Patterns*). Utilizou-se a variação uniforme e invariante à rotação, com raio igual a 1 e 8 vizinhos, configurando um método eficiente para capturar a textura do exoesqueleto do inseto e da folhagem ([Ojala; Pietikainen; Maenpaa, 2002](#)).
3. **Complexidade da Informação:** A Entropia de Shannon é calculada sobre a distribuição de frequências das intensidades de cinza da imagem. Esse escalar atua como uma medida de complexidade estrutural, diferenciando imagens homogêneas daquelas com alta densidade de detalhes.

Esses componentes são concatenados em um único vetor numérico e normalizados para evitar distorções de escala. O Algoritmo 3.2 demonstra a implementação computacional dessa fusão de características.

Código 3.2 – Extração do vetor de características multivariado unindo Cor (HSV), Textura (LBP) e Complexidade (Entropia).

```
1 def _extract_multivariate_features(img_bgr: np.ndarray) -> np.ndarray:
```

```

2     hsv = cv2.cvtColor(img_bgr, cv2.COLOR_BGR2HSV)
3     hist_h = cv2.calcHist([hsv], [0], None, [16], [0, 180]).flatten()
4     hist_s = cv2.calcHist([hsv], [1], None, [16], [0, 256]).flatten()
5     hist_v = cv2.calcHist([hsv], [2], None, [16], [0, 256]).flatten()
6     color_feat = np.concatenate([hist_h, hist_s, hist_v])
7     color_feat /= (color_feat.sum() + 1e-6)
8
9     gray = cv2.cvtColor(img_bgr, cv2.COLOR_BGR2GRAY)
10    lbp = local_binary_pattern(gray, 8, 1, method='uniform')
11    lbp_hist, _ = np.histogram(lbp.ravel(), bins=np.arange(0, 11),
12                             range=(0, 10))
13
14    lbp_hist = lbp_hist.astype(float) / (lbp_hist.sum() + 1e-6)
15
16    hist_gray, _ = np.histogram(gray, bins=256, range=(0, 256))
17    p = hist_gray / (hist_gray.sum() + 1e-6)
18    entropy = -np.sum(p[p > 0] * np.log2(p[p > 0]))
19
20    return np.concatenate([color_feat, lbp_hist, [entropy]])

```

Fonte: Elaborado pela autora.

Após a extração, todos os vetores de uma mesma classe são submetidos a uma padronização estatística de média nula e variância unitária. Em seguida, aplica-se o algoritmo de agrupamento K-Médias (*K-Means*), onde o número de agrupamentos (K) é estritamente igual ao número de amostras desejadas para o treinamento daquela classe.

Por fim, o algoritmo identifica e seleciona a imagem mais próxima do centroide de cada agrupamento. Essa abordagem garante a construção de um conjunto de suporte coeso e balanceado, forçando o modelo YOLO a aprender representações intrínsecas a partir do espectro completo de diversidade visual da praga, mitigando o risco de enviesamento por redundância.

3.5.3 Estratégias de Aprendizado por Transferência

Para investigar o balanço entre a adaptação ao domínio e o risco de *overfitting*, foram avaliadas duas estratégias de aprendizado por transferência.

3.5.3.1 Ajuste-fino Completo

Nesta abordagem, todos os parâmetros do modelo, incluindo o *backbone* e o *head* de detecção, são atualizados durante o treinamento. Essa estratégia permite a máxima adaptação ao domínio alvo, mas, com dados limitados, corre um risco maior de *overfitting*, onde o modelo pode memorizar os poucos exemplos de treinamento em vez de aprender características generalizáveis.

3.5.3.2 Estratégia de Congelamento Simples (Regularização)

Esta estratégia atua como uma forma de regularização estrutural, referenciada nos experimentos como modo de congelamento simples. Nela, as 10 primeiras camadas da rede neural (*backbone*), equivalentes à base do extrator de características espaciais, são congeladas, o que significa que seus pesos não recebem atualizações de gradiente durante o treinamento.

Apenas as camadas mais profundas e a cabeça de detecção são ajustadas aos dados agrícolas. O objetivo fundamental desta restrição metodológica é preservar as representações visuais robustas de baixo nível (como bordas, contrastes e texturas básicas) já consolidadas no pré-treinamento inicial em larga escala. Concomitantemente, permite-se a especialização das camadas superiores para a identificação da maturidade dos insetos, mitigando o risco de sobreajuste aos poucos exemplos fornecidos pelo regime restrito de dados.

3.6 Métricas de Avaliação e Análise Estatística

O desempenho dos modelos foi avaliado por meio da métrica *mean Average Precision* (mAP), amplamente utilizada em tarefas de detecção de objetos para sintetizar a relação entre precisão e revocação ao longo de diferentes níveis de confiança (Zhao *et al.*, 2019; Zou *et al.*, 2023). Em particular, adotou-se o **mAP@0.5:0.95**, métrica introduzida pelo *benchmark* MS COCO, que calcula a média do mAP em múltiplos limiares de *Intersection over Union* (IoU), variando de 0,5 a 0,95 com incrementos de 0,05 (Lin *et al.*, 2014). Por incorporar limiares elevados, essa métrica impõe uma avaliação rigorosa da qualidade espacial das detecções, penalizando previsões que, embora classifiquem corretamente o objeto, apresentam baixa aderência geométrica às anotações originais.

Adicionalmente, foram reportados o **Recall** (revocação) e o **F1-score**, métricas fundamentais para uma análise holística do detector. O *Recall* quantifica a capacidade do modelo em identificar todas as instâncias relevantes presentes na imagem, sendo definido pela razão entre os verdadeiros positivos (*TP*) e o total de anotações reais (*TP + FN*). Em aplicações agrícolas, a minimização de falsos negativos é crucial para garantir que pragas não passem despercebidas pelo sistema de monitoramento automático, o que poderia resultar em prejuízos econômicos severos.

Contudo, dado que o aumento isolado do *Recall* pode elevar o número de alarmes falsos (falsos positivos), utilizou-se o **F1-score** como medida de equilíbrio harmônico entre precisão e revocação. O *F1-score* é definido conforme a Equação 3.3:

$$F1 = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3.3)$$

Essa métrica provê um indicador robusto de desempenho que penaliza valores extremos, sendo especialmente útil na comparação de estratégias de *Few-Shot Learning* e modelos de diferentes arquiteturas (como a família YOLO). A análise conjunta dessas métricas permite verificar a estabilidade do modelo sob restrição de dados e a eficácia das técnicas de aumento de dados propostas nesta dissertação.

3.6.1 Controle e Reprodutibilidade

Para mitigar o viés de inicialização aleatória dos pesos e garantir a significância estatística dos ganhos observados (conforme detalhado na Seção de Resultados), cada experimento foi executado em um ciclo de 15 sementes (*seeds*) distintas (0 a 14).

Todos os resultados reportados baseiam-se na **média das 15 sementes**, e não em resultados isolados de pico.

É comum que, em experimentos individuais, os modelos apresentem valores de *mAP* (Precisão Média) superiores aos listados nas Tabelas 8 e 9. Contudo, no cenário FSL, o desempenho é altamente dependente das imagens selecionadas para o treino. Ao reportar a média e o desvio padrão de 15 execuções, esta dissertação mitiga o efeito do "acaso" e apresenta o desempenho esperado real do sistema, diferenciando o **desempenho de pico** (fortuito) da **robustez média** (metodológica).

3.6.2 Avaliação e Rigor Estatístico

Para garantir a reprodutibilidade e a robustez das inferências sobre o desempenho das estratégias propostas, adotou-se um protocolo experimental fundamentado em múltiplas inicializações e testes de hipóteses não paramétricos, seguindo as recomendações de Demvšar (2006) e Bouthillier *et al.* (2021) para a mitigação da variância em *benchmarks* de aprendizado de máquina.

Cada experimento foi repetido com $N = 15$ sementes aleatórias distintas. Este número de repetições é superior ao padrão comumente encontrado na literatura de *Few-Shot Learning* (FSL), visando capturar com maior precisão a variabilidade estocástica inerente ao treinamento de arquiteturas YOLOv5, YOLOv8 e YOLOv11 (Ultralytics, 2024) em cenários de escassez de dados. As métricas de desempenho analisadas foram o mAP_{50-95} , *Recall* e *F1 – Score*, alinhadas com os *benchmarks* do estado da arte em detecção de pragas (Wu, X. *et al.*, 2019; Huang *et al.*, 2025).

A análise estatística seguiu os seguintes passos sequenciais:

1. **Estatística Descritiva:** Calculou-se a média (μ), o desvio padrão (σ) e o Coeficiente de Variação ($CV = \frac{\sigma}{\mu} \times 100\%$). O uso do *CV* é justificado pela necessidade de avaliar

a estabilidade dos modelos em diferentes estágios fenológicos das pragas, uma abordagem relevante em estudos de classificação por maturidade (Neupane *et al.*, 2024; Gomes; Borges, D. L., 2022). Adicionalmente, esta metodologia segue o protocolo experimental validado em Abreu, Costa e Dibio Borges (2026), onde se observou que estratégias data-céntricas reduzem significativamente a dispersão dos resultados e aumentam a estabilidade do treinamento.

2. **Verificação de Normalidade:** A aderência das diferenças pareadas à distribuição normal foi verificada através do teste de Shapiro-Wilk. Dado que a hipótese de normalidade foi frequentemente rejeitada ($p < 0,05$), priorizou-se o uso de métodos não paramétricos, conforme sugerido por Demvšar (2006).
3. **Testes de Hipótese Pareados:** A comparação entre as estratégias propostas (Estratégia I e II) e o *baseline* de Seleção Aleatória foi realizada de forma pareada (semente a semente). Utilizou-se o teste de postos sinalizados de Wilcoxon e o **Teste de Permutação Pareado** (10^4 permutações). O teste de permutação é especialmente robusto para cenários FSL, pois não assume distribuições teóricas prévias e fornece p-valores exatos baseados na estatística da média das diferenças intrapares.
4. **Correção para Múltiplas Comparações:** Para controlar a inflação do erro do Tipo I decorrente dos múltiplos testes realizados entre diferentes arquiteturas e estágios, aplicou-se o procedimento de *False Discovery Rate* (FDR) de Benjamini-Hochberg. Esta abordagem garante que a taxa de falsas descobertas seja mantida abaixo de $\alpha = 0,05$, conferindo rigor às alegações de ganho de desempenho.

As análises foram implementadas em Python, integrando o pipeline de treinamento aos métodos estatísticos das bibliotecas SciPy e Statsmodels. A visualização dos dados foi estruturada para comparar a eficácia de detecção e o custo computacional, métrica crítica para aplicações em agricultura de precisão (Aboah *et al.*, 2023; Alves; Souza, W. S.; Borges, D. L., 2020).

3.6.3 Explicabilidade Visual via Grad-CAM

Para transcender as métricas estritamente quantitativas e auditar o comportamento cognitivo das redes neurais sob escassez de dados, implementou-se o método de explicabilidade Grad-CAM (*Gradient-weighted Class Activation Mapping*) adaptado para as arquiteturas YOLO. Nesta pesquisa, a técnica foi aplicada de forma estritamente *post-hoc* (a posteriori) sobre o conjunto de teste, atuando como uma ferramenta de validação qualitativa dos melhores modelos selecionados após a fase de treinamento.

Devido à natureza multiescala e às cabeças de detecção desacopladas (*Decoupled Heads*) inerentes às arquiteturas YOLOv8 e YOLOv11, o algoritmo Grad-CAM tradicional

exigiu uma adequação metodológica. Em vez de monitorar estritamente a última camada da rede — que pode apresentar gradientes nulos caso a predição ocorra em uma escala espacial diferente —, desenvolveu-se um rastreamento autoadaptativo. O método varre dinamicamente as camadas convolucionais mais profundas em busca de derivadas não nulas. A partir desses gradientes matemáticos, o algoritmo produz um mapa de calor espacial que destaca as regiões da imagem que exerceram maior influência na definição da maturidade do inseto.

Nesta dissertação, essa técnica foi fundamental para verificar se a rede neural efetivamente aprendeu a extrair características morfológicas intrínsecas da praga ou se estava sofrendo do fenômeno de viés de fundo (*background bias*), onde o modelo memoriza elementos irrelevantes do substrato agrícola (como folhas, nervuras ou solo) para tomar decisões espúrias. Os mapas de ativação resultantes dessa auditoria, que ilustram visualmente a capacidade de abstração das estratégias *Few-Shot* frente à linha de base (Pré-treino COCO), são apresentados e detalhados na Seção 4.1.11.

Cabe ressaltar uma delimitação técnica pertinente à execução da análise de explicabilidade. Embora a arquitetura YOLOv5 tenha sido mantida no escopo quantitativo da pesquisa atuando como um modelo de linha de base (*baseline*) histórico, os mapas de ativação Grad-CAM foram extraídos exclusivamente para os modelos pertencentes ao estado da arte contemporâneo (YOLOv8 e YOLOv11). Tal restrição justifica-se por uma incompatibilidade arquitetural de *framework*: os pesos da geração V5 foram treinados sob um repositório legado, cujos grafos computacionais e serialização de módulos no PyTorch diferem estruturalmente da biblioteca unificada da Ultralytics. Desse modo, a fim de garantir a integridade da retropropagação matemática e manter um ambiente de comparação hermético e metodologicamente justo, a auditoria cognitiva *post-hoc* foi delimitada às arquiteturas que compartilham o mesmo paradigma de cabeças de detecção desacopladas (*Decoupled Heads*).

3.6.4 O Efeito Clever Hans em Visão Computacional

No contexto do aprendizado de máquina, o fenômeno conhecido como *Clever Hans effect* (efeito Clever Hans) descreve situações em que um modelo obtém um desempenho aparentemente elevado ao aprender correlações espúrias presentes nos dados de treinamento, em vez de extrair as características semânticas reais da classe alvo (Lapuschkin *et al.*, 2019). O termo remete ao cavalo Hans, que no início do século XX acreditava-se ser capaz de realizar operações aritméticas, quando, na verdade, ele apenas reagia a pistas visuais sutis e involuntárias de seu treinador.

Em problemas de classificação de pragas agrícolas, esse efeito representa um risco crítico. Devido à natureza dos *datasets* coletados em campo, certas classes de insetos podem

estar sistematicamente associadas a tipos específicos de folhagens, condições de iluminação ou artefatos de captura. Sem o uso de técnicas de Inteligência Artificial Explicável (*Explainable AI - XAI*), um modelo baseado em redes neurais convolucionais (CNNs) ou arquiteturas YOLO pode ser treinado para identificar a “planta hospedeira” em vez do “inseto-praga”, mantendo uma alta precisão, mas falhando em termos de generalização e robustez científica.

Nesta dissertação, a aplicação do método Grad-CAM (*Gradient-weighted Class Activation Mapping*) visa mitigar o risco do efeito Clever Hans. Através da visualização das regiões de interesse que maximizam a predição, é possível verificar se a rede está efetivamente discriminando as características morfológicas dos espécimes em diferentes estágios de maturidade, garantindo que o aprendizado seja *data-centric* e biologicamente coerente.

3.7 Ambiente Computacional

Nesta seção, detalha-se o ecossistema computacional mobilizado para a execução dos experimentos de treinamento, validação e inferência das arquiteturas YOLOv8, YOLOv11 e YOLOv5. O rigor na descrição do ambiente visa assegurar a reprodutibilidade dos resultados e a compreensão dos tempos de processamento observados.

3.7.1 Ambiente de Hardware

Os experimentos foram conduzidos em uma estação de trabalho de alto desempenho, configurada para suportar cargas de trabalho intensivas de *Deep Learning*. A especificação do *hardware* é composta por:

- **Processador (CPU):** Intel® Core™ i7-8700 com frequência base de 3.20 GHz, dotado de 6 núcleos físicos e 12 núcleos lógicos (*threads*), permitindo a paralelização eficiente do carregamento de dados.
- **Memória RAM:** 64 GB DDR4, operando em regime que minimiza gargalos de transferência entre a CPU e a GPU.
- **Unidades de Processamento Gráfico (GPU):** Duas unidades NVIDIA GeForce RTX 2080, cada uma com 8 GB de memória de vídeo dedicada (VRAM) e arquitetura Turing, totalizando 16 GB de capacidade computacional acelerada por *Tensor Cores*.
- **Armazenamento e I/O:** O sistema operacional e as bibliotecas de base residem em uma unidade de estado sólido (SSD) Western Digital Green de 240 GB. Para o armazenamento dos *datasets* e registro dos *logs* de treinamento, utilizou-se um disco rígido (HDD) Seagate BarraCuda de 1 TB (7200 RPM, SATA III), garantindo espaço suficiente para a volumosa quantidade de pesos gerados durante as rodadas experimentais.

3.7.2 Ambiente de Software e Bibliotecas

O suporte lógico foi estruturado sobre uma distribuição Linux, garantindo estabilidade e compatibilidade com os *drivers* de aceleração por *hardware*. As versões específicas são detalhadas a seguir:

- **Sistema Operacional:** Ubuntu 22.04.4 LTS (Kernel 6.8.0).
- **Ecosistema Python:** Versão 3.9.13, gerenciada via plataforma Anaconda para isolamento de dependências.
- **Frameworks de Deep Learning:** PyTorch v2.0.1, integrado com a biblioteca Ultralytics v8.3.240.
- **Aceleração de Hardware:** *Driver* NVIDIA 535.288.01 com suporte ao *toolkit* CUDA v11.7 para operações em GPU.
- **Processamento de Dados:** Bibliotecas auxiliares NumPy e OpenCV para manipulação de matrizes e pré-processamento de imagens.

4 Resultados e Discussão

Neste capítulo, analisam-se os resultados experimentais fundamentados na eficácia de detecção, estabilidade estatística e eficiência computacional. A estrutura desta seção visa validar as estratégias de amostragem propostas e recomendar a arquitetura ideal para operação em cenários reais de agricultura de precisão.

4.1 Experimentos Exploratórios e Prova de Conceito (N=5)

Previamente à análise exaustiva das pragas da cultura do milho, realizou-se um estudo exploratório utilizando as classes 22, 23 e 26 do conjunto de dados IP-FSL. Esta fase teve como propósito validar a eficácia das estratégias de amostragem frente à seleção puramente aleatória (*baseline*). Os resultados, consolidados na Tabela 6, serviram de prova de conceito para a manutenção das estratégias de amostragem nas fases subsequentes da pesquisa.

A avaliação dos resultados (Tabela 6) indica que a eficácia das estratégias de amostragem transcende o ganho isolado em mAP_{50-95} , fundamentando-se em três eixos determinantes:

- **Confiabilidade e Reprodutibilidade:** A **Estratégia II** atuou como um regulador de variância, reduzindo o Coeficiente de Variação (CV) para **3,70%** (YOLOv5/Jovens). Comparada à seleção aleatória (CV até 22,2%), a amostragem inteligente mitiga a dependência da semente inicial, garantindo estabilidade estatística em cenários de *Few-Shot Learning*.
- **Sensibilidade e Cobertura:** Para o monitoramento agrícola, o **Recall** médio superior a **0,97** nos modelos YOLOv8 e YOLOv11 demonstra a capacidade das estratégias em minimizar falsos negativos. O equilíbrio é ratificado pelo **F1-Score** de **0,960**, indicando que a diversidade contextual das amostras permite a detecção eficaz de indivíduos jovens, apesar do mimetismo biológico.
- **Eficiência e Resiliência Arquitetural:** O **YOLOv11** consolidou-se como a arquitetura de melhor custo-benefício. Diferente do YOLOv5, que apresentou queda de 66% no mAP sob congelamento (`freeze: simple`), o YOLOv11 manteve métricas estáveis com tempos de treinamento otimizados, viabilizando sua aplicação em sistemas de borda com baixo recurso computacional.

Tabela 6 – Resultados Comparativos: Validação de Estratégias (Adultos vs. Jovens). Em destaque, a estabilidade da Estratégia II e a resiliência do YOLOv11.

Estágio	Modelo	Estratégia	Freeze	mAP_{50-95}	DV	CV (%)	Precisão	Recall	Tempo (m)	F1-Score
Adultos	YOLOv5	Seleção aleatória	sem congelamento	0.5472	0.0854	15.60%	0.919	0.845	17.50	0.880
	YOLOv5	Seleção aleatória	com congelamento	0.3207	0.0191	5.90%	0.681	0.749	7.16	0.713
	YOLOv5	Estratégia I	sem congelamento	0.4836	0.0712	14.70%	0.911	0.854	17.91	0.882
	YOLOv5	Estratégia I	com congelamento	0.3306	0.0416	12.60%	0.714	0.822	18.85	0.764
	YOLOv5	Estratégia II	sem congelamento	0.3929	0.0498	12.70%	0.868	0.819	10.35	0.843
	YOLOv5	Estratégia II	com congelamento	0.3433	0.0463	13.50%	0.796	0.856	8.21	0.825
	YOLOv8	Seleção aleatória	sem congelamento	0.4864	0.1081	22.20%	0.939	0.946	9.52	0.942
	YOLOv8	Seleção aleatória	com congelamento	0.4659	0.1110	23.80%	0.925	0.965	12.35	0.945
	YOLOv8	Estratégia I	sem congelamento	0.4131	0.0915	22.10%	0.948	0.935	7.44	0.941
	YOLOv8	Estratégia I	com congelamento	0.3981	0.0630	15.80%	0.934	0.938	17.28	0.936
	YOLOv8	Estratégia II	sem congelamento	0.3912	0.0644	16.50%	0.944	0.969	7.45	0.956
	YOLOv8	Estratégia II	com congelamento	0.3559	0.0510	14.40%	0.880	0.975	17.40	0.925
	YOLOv11	Seleção aleatória	sem congelamento	0.4826	0.1063	22.00%	0.879	0.967	31.05	0.921
	YOLOv11	Seleção aleatória	com congelamento	0.4871	0.1161	23.80%	0.905	0.970	12.55	0.936
	YOLOv11	Estratégia I	sem congelamento	0.4231	0.0563	13.30%	0.909	0.967	13.87	0.937
	YOLOv11	Estratégia I	com congelamento	0.4087	0.0540	13.20%	0.873	0.966	13.84	0.917
	YOLOv11	Estratégia II	sem congelamento	0.3589	0.0729	20.30%	0.869	0.967	18.86	0.915
	YOLOv11	Estratégia II	com congelamento	0.3528	0.0580	16.50%	0.852	0.967	19.54	0.906
Jovens	YOLOv5	Estratégia I	sem congelamento	0.4538	0.0308	6.80%	0.894	0.812	18.83	0.851
	YOLOv5	Seleção aleatória	sem congelamento	0.4396	0.0851	19.30%	0.846	0.767	10.50	0.805
	YOLOv5	Seleção aleatória	com congelamento	0.1481	0.0330	22.30%	0.459	0.780	8.68	0.578
	YOLOv5	Estratégia I	com congelamento	0.1130	0.0210	18.60%	0.357	0.826	8.02	0.499
	YOLOv5	Estratégia II	sem congelamento	0.4378	0.0161	3.70%	0.883	0.808	41.02	0.844
	YOLOv5	Estratégia II	com congelamento	0.1986	0.0240	12.10%	0.447	0.850	19.98	0.586
	YOLOv8	Seleção aleatória	sem congelamento	0.3285	0.0610	18.60%	0.820	0.965	28.50	0.887
	YOLOv8	Seleção aleatória	com congelamento	0.3343	0.0660	19.80%	0.850	0.975	17.77	0.908
	YOLOv8	Estratégia I	sem congelamento	0.3685	0.0554	15.00%	0.889	0.987	22.17	0.935
	YOLOv8	Estratégia I	com congelamento	0.3561	0.0570	16.00%	0.910	0.985	17.65	0.946
	YOLOv8	Estratégia II	sem congelamento	0.3406	0.0221	6.50%	0.947	0.974	17.26	0.960
	YOLOv8	Estratégia II	com congelamento	0.3524	0.0160	4.50%	0.910	0.978	6.06	0.943
	YOLOv11	Seleção aleatória	sem congelamento	0.3281	0.0710	21.60%	0.802	0.945	14.81	0.868
	YOLOv11	Seleção aleatória	com congelamento	0.3281	0.0580	17.70%	0.805	0.944	13.71	0.869
	YOLOv11	Estratégia I	sem congelamento	0.3653	0.0475	13.00%	0.886	0.973	13.88	0.927
	YOLOv11	Estratégia I	com congelamento	0.3705	0.0420	11.30%	0.880	0.960	13.70	0.918
	YOLOv11	Estratégia II	sem congelamento	0.3541	0.0231	6.50%	0.856	0.970	12.56	0.909
	YOLOv11	Estratégia II	com congelamento	0.3475	0.0200	5.80%	0.835	0.975	13.54	0.900

Fonte: Elaborada pela autora.

Nota: Os resultados reportados nesta tabela referem-se à fase exploratória inicial de validação das estratégias, conduzida com hiperparâmetros. Para o estudo de caso definitivo da cultura do milho, o rigor estatístico foi ampliado para $N = 15$ sementes, tornando a significância dos testes de hipótese.

Em suma, a combinação da **Estratégia II** com o **YOLOv11** oferece o equilíbrio ideal entre precisão diagnóstica, robustez estatística e viabilidade operacional para a classificação de pragas em diferentes estágios de maturidade.

4.1.1 Singularidade Estatística da Estratégia II no Modelo YOLOv5

Um achado de particular relevância na fase exploratória foi a detecção de significância estatística em uma configuração específica: o modelo **YOLOv5 em modo integral (sem congelamento) utilizando a Estratégia II**. Enquanto as demais arquiteturas apresentaram tendências de melhora que não atingiram o limiar de $p < 0,05$ devido ao baixo poder estatístico da amostra ($N = 5$), o YOLOv5 demonstrou uma resposta robusta à amostragem inteligente, especialmente no estágio **Jovens**, sendo o valor-p **0,039** para Test T e **0,40** para

Permutação.

Neste cenário, a Estratégia II não apenas elevou o desempenho médio, mas atuou como o principal fator de estabilização, registrando o menor Coeficiente de Variação (CV) de todo o experimento: **3,70%**. Este fenômeno sugere que arquiteturas baseadas em âncoras (*anchors*), como o YOLOv5, são mais dependentes da qualidade e diversidade do conjunto de suporte para convergir de forma confiável.

Este resultado isolado foi o "divisor de águas" metodológico desta dissertação: ele forneceu a evidência empírica de que a Estratégia II possuía um potencial de regularização superior. Contudo, a ausência de significância nos modelos YOLOv8 e YOLOv11 sob as mesmas 5 sementes, foi o que motivou a decisão de expandir o protocolo experimental para **15 sementes** no estudo de caso do milho, garantindo que a superioridade técnica não fosse mascarada pela insuficiência amostral.

4.1.2 Refinamentos Metodológicos e Transição para o Estudo de Caso do Milho

Os resultados exploratórios obtidos com as classes 22, 23 e 26 revelaram lacunas que demandaram um refinamento no protocolo experimental para a fase definitiva da pesquisa. Embora a Estratégia II tenha demonstrado superioridade qualitativa, a variabilidade inerente ao cenário de baixa amostragem sugeriu três ajustes fundamentais para garantir a validade científica do trabalho:

1. **Ampliação do Poder Estatístico ($N = 15$):** A observação de que o uso de apenas 5 sementes resultava em distribuições de alta variância motivou a elevação para **15 sementes independentes**. Este ajuste visa mitigar o erro tipo II (falso negativo estatístico), garantindo que a superioridade da Estratégia II não seja mascarada pela insuficiência amostral em testes de hipótese não-paramétricos como o de Wilcoxon.
2. **Isolamento da Variável de Amostragem:** Para validar a eficácia da seleção inteligente sob a ótica da *Data-centric AI*, estabeleceu-se um *baseline* operando estritamente sem o aumento de dados *offline*. Isso permite isolar o ganho real proveniente da informatividade das amostras selecionadas pela Estratégia II frente à redundância sintética gerada por transformações mecânicas.
3. **Especialização no Domínio da Cultura do Milho:** Visando a futura escalabilidade via *Transfer Learning*, optou-se por focar o experimento principal nas pragas do milho (Classes 17, 19 e 23). Esta especialização permite extrair assinaturas visuais e contextuais mais profundas, servindo de base sólida para a posterior adaptação do modelo a outros hospedeiros agrícolas.

Tais refinamentos pavimentaram o caminho para a execução dos experimentos cujos resultados são detalhados a seguir, integrando indicadores de precisão, sensibilidade e eficiência operacional sob um rigoroso protocolo experimental.

4.1.3 Resultados Detalhados para a Detecção de Pragas da Cultura do Milho

A adoção de arquiteturas modernas de detecção de objetos de estágio único, como as iterações da família YOLO (*You Only Look Once*) (Redmon *et al.*, 2016; Ultralytics, 2023, 2024), pressupõe uma alta capacidade de generalização decorrente do pré-treinamento maciço em conjuntos de dados de domínio aberto, como o MS COCO (Lin *et al.*, 2014). No entanto, em cenários complexos de agricultura de precisão, a inferência direta com pesos genéricos não adaptados (baseline da época zero) frequentemente apresenta limitações severas. A literatura aponta que a transição de características genéricas para domínios altamente específicos sofre com o chamado *domain gap* (distanciamento de domínio), exigindo abordagens que mitiguem a escassez de dados (Kamilaris; Prenafeta-Boldü, 2018).

Para evidenciar a necessidade crítica da adaptação de domínio no contexto agrícola, a Tabela 7 contrapõe as médias de desempenho do modelo base (época zero) com os **piores** resultados médios alcançados pelas estratégias de *Few-Shot Learning* (FSL) (Wang, Y. *et al.*, 2020; Gomes; Borges, D. L., 2022) conduzidas neste estudo. A fim de manter a consistência avaliativa desta seção, os modelos foram analisados sob a ótica da exatidão de localização (mAP_{50-95}), harmonia global de predição (*F1-Score*) e da taxa de detecção efetiva (*Recall*).

Tabela 7 – Comparação de Desempenho: Baseline (Época 0) vs. Pior resultado FSL com ajuste fino.

Estágio	Modelo	Pré-treino COCO (Época 0)			Few-shot (Pior Configuração Média)		
		mAP_{50-95}	Recall	F1-Score	mAP_{50-95}	Recall	F1-Score
Adultos	YOLOv5	0.1817	0.6222	0.2036	0.3333	0.3620	0.6320
	YOLOv8	0.1414	0.6889	0.2116	0.5455	0.8420	0.8091
	YOLOv11	0.2018	0.7333	0.2481	0.5498	0.8356	0.7794
Jovens	YOLOv5	0.0817	0.2523	0.2053	0.2345	0.4077	0.4414
	YOLOv8	0.0544	0.2710	0.1611	0.2566	0.4721	0.3615
	YOLOv11	0.0644	0.2897	0.1761	0.2506	0.4790	0.3391

Fonte: Elaborada pela autora.

Nota: Os valores do baseline representam as execuções na época zero, sem ajuste de pesos para o domínio agrícola. Os valores de Few-shot ilustram a configuração de treinamento com o pior mAP_{50-95} médio das seeds alcançado pela respectiva combinação para estágio × modelo × modo de aumento de dados × modo de congelamento, atestando o ganho basal fornecido pela adaptação.

A análise dos resultados demonstra um salto substancial em métricas críticas quando inserida a etapa de ajuste fino (*fine-tuning*), ainda que com um suporte amostral ínfimo. No estágio de insetos **Adultos**, a arquitetura YOLOv8 não adaptada (baseline) atingiu um mAP_{50-95} de apenas 0.1414. Em contrapartida, a configuração de *Few-Shot* de pior desempenho para este mesmo modelo entregou um mAP_{50-95} de 0.5455 (um aumento

expressivo de aproximadamente 285%), com o *F1-Score* saltando de 0.2116 para 0.8091. Destaca-se também a elevação na métrica de *Recall*, que subiu de 0.6889 para 0.8420. Do ponto de vista agrônomo, garantir um alto *Recall* de forma balanceada (refletido pelo alto *F1-Score*) é imperativo, pois minimiza a ocorrência de falsos negativos — pragas não detectadas que poderiam ocasionar focos de infestação descontrolados na lavoura. Este comportamento corrobora as observações de [Aboah et al. \(2023\)](#) sobre o impacto de técnicas de amostragem de dados (*data sampling*) em redes YOLO.

Ademais, a deficiência do aprendizado generalista se mostra ainda mais gritante perante alvos desafiadores. No estágio de insetos **Jovens** — que inerentemente exibem menor contraste fenotípico e dimensão reduzida em relação ao fundo das folhas ([Gomes; Borges, D. L., 2022](#)) —, as redes não-adaptadas falham de modo contundente. O modelo YOLOv11 anotou meros 0.0644 de mAP_{50-95} e 0.2897 de *Recall* na linha de base não adaptada. Ao expormos o modelo às escassas amostras do domínio alvo, o mAP_{50-95} elevou-se para 0.2506 (um incremento de quase 290%) e o *Recall* aumentou para 0.4790. O YOLOv8 obteve comportamento semelhante, quadruplicando o seu mAP_{50-95} basal. Esse fenômeno demonstra que as representações de características (*features*) extraídas pelas redes pré-treinadas não contemplam as complexas assinaturas visuais de pragas jovens sem uma ancoragem baseada em dados reais do agrossistema ([Yosinski et al., 2014](#)).

Tendo comprovada a necessidade da adaptação de domínio por meio do *Few-Shot Learning*, emerge um segundo desafio sob a ótica da *Data-centric AI*: a seleção das amostras. Quando a disponibilidade de dados anotados é restrita, a seleção aleatória pode falhar em capturar a variabilidade intra-classe e inter-classe necessária para uma generalização robusta da rede. É neste contexto que a transição de um modelo amostral aleatório para estratégias de amostragem, torna-se o diferencial para extrair o máximo de desempenho computacional.

Para validar esta premissa metodológica, as Tabelas 8 e 9 contrapõem o *baseline* aleatório aos métodos propostos. A análise das linhas sombreadas confirma a robustez da Estratégia II. No estágio **Jovens**, observa-se uma dominância de resultados estatisticamente significativos ($p < 0,05$), com ganhos de mAP_{50-95} atingindo **+0,0820** no modelo YOLOv11. Este fenômeno é particularmente notável pois ocorre mesmo na ausência de técnicas de aumento de dados, sugerindo que a qualidade e a diversidade informacional das amostras selecionadas pela Estratégia II suprem a necessidade de redundância sintética em arquiteturas *anchor-free*.

Inversamente, no estágio **Adultos**, embora o patamar de desempenho do *baseline* seja naturalmente elevado (devido à menor complexidade de detecção do alvo), a Estratégia II ainda proporcionou incrementos significativos em configurações críticas (ex.: YOLOv8 sem aumento de dados, com ganho de **+0,0396**), demonstrando que a amostragem inteligente otimiza o aprendizado independentemente da facilidade visual intrínseca à classe.

Notavelmente, a análise detalhada das sementes revela uma instabilidade crítica na convergência do modelo YOLOv11 quando submetido à Estratégia I sem a aplicação de data augmentation e sem o congelamento de pesos basais. Sob esta configuração, a arquitetura registrou um F1-Score de $0,6960 \pm 0,3602$, cujo desvio padrão superior a 50% da média indica falhas catastróficas de aprendizado em parcelas significativas das 15 execuções independentes. Esse comportamento anômalo é inerente à elevada capacidade paramétrica do YOLOv11. Tais dados corroboram empiricamente a premissa de que a aplicação direta de arquiteturas *state-of-the-art* em domínios agrícolas de dados escassos exige abordagens restritivas, evidenciando o valor do congelamento seletivo e da Estratégia II propostos neste trabalho para garantir a robustez estocástica do modelo.

Tabela 8 – Análise Estatística Detalhada - Estágio Adultos (15 Sementes). Linhas sombreadas indicam significância estatística ($p < 0,05$).

Modelo	Freeze	Aug.	Est.	mAP Baseline	mAP Estratégia	Ganho	CV (%)	p-valor	Tempo	Recall	F1-Score
YOLOv5	Não	Não	I	0.3941 ± 0.0518	0.4007 ± 0.0516	+0.0067	12.88%	0.6935	3.05	0.7472 ± 0.0630	0.7207 ± 0.0625
	Não	Não	II	0.3941 ± 0.0518	0.3761 ± 0.0685	-0.0179	18.21%	0.9998	2.99	0.6983 ± 0.1033	0.6699 ± 0.0864
	Não	Sim	I	0.5700 ± 0.0543	0.5737 ± 0.0556	+0.0037	9.69%	0.7365	3.46	0.8811 ± 0.0539	0.8733 ± 0.0445
	Não	Sim	II	0.5700 ± 0.0543	0.6051 ± 0.0374	+0.0351	6.19%	0.0413	3.46	0.8751 ± 0.0376	0.8703 ± 0.0366
	Sim	Não	I	0.3333 ± 0.0413	0.3364 ± 0.0384	+0.0031	11.41%	0.6935	2.50	0.6559 ± 0.0923	0.6257 ± 0.0583
	Sim	Não	II	0.3333 ± 0.0413	0.3617 ± 0.0541	+0.0284	14.97%	0.1264	2.49	0.6320 ± 0.0879	0.6350 ± 0.0556
	Sim	Sim	I	0.5405 ± 0.0423	0.5508 ± 0.0371	+0.0103	6.74%	0.5838	2.68	0.8544 ± 0.0635	0.8410 ± 0.0442
	Sim	Sim	II	0.5405 ± 0.0423	0.5453 ± 0.0334	+0.0048	6.12%	0.6935	2.66	0.8360 ± 0.0703	0.8354 ± 0.0562
YOLOv8	Não	Não	I	0.5587 ± 0.0465	0.5591 ± 0.0610	+0.0004	10.90%	0.7781	1.28	0.8975 ± 0.0462	0.8142 ± 0.2277
	Não	Não	II	0.5587 ± 0.0465	0.5983 ± 0.0489	+0.0396	8.18%	0.0240	1.36	0.8623 ± 0.0551	0.8502 ± 0.0403
	Não	Sim	I	0.5455 ± 0.0717	0.5599 ± 0.0354	+0.0145	6.33%	0.5838	2.00	0.8591 ± 0.0493	0.8719 ± 0.0350
	Não	Sim	II	0.5455 ± 0.0717	0.5825 ± 0.0463	+0.0371	7.96%	0.1580	2.01	0.8517 ± 0.0472	0.8588 ± 0.0402
	Sim	Não	I	0.6067 ± 0.0424	0.6160 ± 0.0390	+0.0093	6.32%	0.5943	1.12	0.8938 ± 0.0582	0.9003 ± 0.0487
	Sim	Não	II	0.6067 ± 0.0424	0.6290 ± 0.0386	+0.0222	6.14%	0.1611	1.12	0.9035 ± 0.0388	0.8887 ± 0.0392
	Sim	Sim	I	0.5843 ± 0.0402	0.5697 ± 0.0330	-0.0146	5.79%	0.9998	1.43	0.8940 ± 0.0359	0.8903 ± 0.0308
	Sim	Sim	II	0.5843 ± 0.0402	0.5940 ± 0.0544	+0.0097	9.16%	0.5611	1.56	0.8915 ± 0.0371	0.8851 ± 0.0427
YOLOv11	Não	Não	I	0.5922 ± 0.0583	0.5676 ± 0.0512	-0.0246	9.02%	0.9998	1.35	0.9090 ± 0.0665	0.6960 ± 0.3602
	Não	Não	II	0.5922 ± 0.0583	0.5928 ± 0.0488	+0.0005	8.23%	0.7781	1.45	0.8629 ± 0.0419	0.8613 ± 0.0367
	Não	Sim	I	0.5718 ± 0.0635	0.5498 ± 0.0217	-0.0220	3.95%	0.9998	2.19	0.8726 ± 0.0388	0.8596 ± 0.0394
	Não	Sim	II	0.5718 ± 0.0635	0.5897 ± 0.0360	+0.0179	6.11%	0.3967	2.21	0.8667 ± 0.0549	0.8661 ± 0.0452
	Sim	Não	I	0.6126 ± 0.0517	0.5960 ± 0.0441	-0.0166	7.40%	0.9998	1.10	0.8356 ± 0.1601	0.7794 ± 0.2393
	Sim	Não	II	0.6126 ± 0.0517	0.6372 ± 0.0375	+0.0246	5.88%	0.2427	1.19	0.9054 ± 0.0356	0.8846 ± 0.0406
	Sim	Sim	I	0.6091 ± 0.0548	0.5864 ± 0.0504	-0.0228	8.60%	0.9998	1.65	0.8944 ± 0.0574	0.8185 ± 0.2277
	Sim	Sim	II	0.6091 ± 0.0548	0.6027 ± 0.0433	-0.0064	7.18%	0.9341	1.72	0.8681 ± 0.0570	0.8778 ± 0.0446

Fonte: Elaborada pela autora.

Nota: O teste estatístico reportado no p -valor avalia a hipótese nula de que não há diferença entre o mAP Baseline e o mAP da Estratégia. "Freeze" indica o uso de congelamento de pesos basais e "Aug." refere-se à aplicação de *data augmentation* offline.

Tabela 9 – Análise Estatística Detalhada - Estágio Jovens (15 Sementes). Linhas sombreadas indicam significância estatística ($p < 0,05$).

Modelo	Freeze	Aug.	Est.	mAP Baseline	mAP Estratégia	Ganho	CV (%)	p-valor	Tempo	Recall	F1-Score
YOLOv5	Não	Não	I	0.1349 ± 0.0337	0.1209 ± 0.0198	-0.0140	16.39%	0.9998	3.46	0.3175 ± 0.0747	0.3442 ± 0.0495
	Não	Não	II	0.1349 ± 0.0337	0.1381 ± 0.0368	+0.0032	26.63%	0.6935	3.45	0.3460 ± 0.0738	0.3679 ± 0.0608
	Não	Sim	I	0.3824 ± 0.0737	0.3795 ± 0.0430	-0.0029	11.32%	0.8818	3.77	0.5138 ± 0.0567	0.6112 ± 0.0476
	Não	Sim	II	0.3824 ± 0.0737	0.4431 ± 0.0658	+0.0607	14.85%	0.0294	3.82	0.6099 ± 0.0767	0.6866 ± 0.0611
	Sim	Não	I	0.1441 ± 0.0285	0.1035 ± 0.0192	-0.0407	18.53%	0.9998	2.95	0.2934 ± 0.1440	0.2901 ± 0.0663
	Sim	Não	II	0.1441 ± 0.0285	0.1473 ± 0.0306	+0.0031	20.75%	0.6851	2.91	0.3376 ± 0.0374	0.3696 ± 0.0394
	Sim	Sim	I	0.3545 ± 0.0616	0.3655 ± 0.0340	+0.0110	9.30%	0.5838	3.00	0.5219 ± 0.0590	0.5927 ± 0.0424
	Sim	Sim	II	0.3545 ± 0.0616	0.4100 ± 0.0527	+0.0555	12.86%	0.0240	2.99	0.5661 ± 0.0670	0.6421 ± 0.0514
YOLOv8	Não	Não	I	0.3327 ± 0.0938	0.2847 ± 0.0801	-0.0480	28.15%	0.9998	1.36	0.5640 ± 0.2543	0.3752 ± 0.2353
	Não	Não	II	0.3327 ± 0.0938	0.3806 ± 0.1034	+0.0479	27.17%	0.1795	1.38	0.5298 ± 0.2324	0.5197 ± 0.2391
	Não	Sim	I	0.2863 ± 0.0775	0.2286 ± 0.0701	-0.0578	30.65%	0.9998	1.96	0.3801 ± 0.2207	0.3477 ± 0.1849
	Não	Sim	II	0.2863 ± 0.0775	0.3699 ± 0.0533	+0.0835	14.41%	0.0072	2.13	0.5042 ± 0.0865	0.5935 ± 0.0705
	Sim	Não	I	0.3903 ± 0.0705	0.3574 ± 0.0593	-0.0328	16.59%	0.9998	1.23	0.5430 ± 0.1406	0.5428 ± 0.1580
	Sim	Não	II	0.3903 ± 0.0705	0.4479 ± 0.0642	+0.0577	14.34%	0.0304	1.26	0.5852 ± 0.1431	0.6524 ± 0.1360
	Sim	Sim	I	0.3374 ± 0.0834	0.3171 ± 0.0639	-0.0203	20.14%	0.9998	1.57	0.4921 ± 0.1659	0.4858 ± 0.1556
	Sim	Sim	II	0.3374 ± 0.0834	0.4009 ± 0.0615	+0.0635	15.35%	0.0294	1.62	0.5492 ± 0.1105	0.6089 ± 0.0911
YOLOv11	Não	Não	I	0.3472 ± 0.0706	0.2781 ± 0.0755	-0.0691	27.14%	0.9998	1.45	0.5619 ± 0.2128	0.3928 ± 0.2423
	Não	Não	II	0.3472 ± 0.0706	0.4220 ± 0.0609	+0.0748	14.43%	0.0048	1.58	0.5860 ± 0.1042	0.6055 ± 0.1724
	Não	Sim	I	0.2802 ± 0.0673	0.2506 ± 0.0646	-0.0296	25.77%	0.9998	2.13	0.5126 ± 0.2756	0.3391 ± 0.2117
	Não	Sim	II	0.2802 ± 0.0673	0.3622 ± 0.0645	+0.0820	17.81%	0.0096	2.24	0.5451 ± 0.1762	0.5134 ± 0.2153
	Sim	Não	I	0.3963 ± 0.0812	0.3321 ± 0.0572	-0.0642	17.23%	0.9998	1.23	0.5966 ± 0.2106	0.4151 ± 0.2554
	Sim	Não	II	0.3963 ± 0.0812	0.4534 ± 0.0621	+0.0571	13.70%	0.0864	1.29	0.5958 ± 0.0945	0.6671 ± 0.0841
	Sim	Sim	I	0.3527 ± 0.0680	0.3001 ± 0.0654	-0.0526	21.80%	0.9998	1.66	0.5715 ± 0.2503	0.3935 ± 0.2568
	Sim	Sim	II	0.3527 ± 0.0680	0.4247 ± 0.0568	+0.0720	13.38%	0.0216	1.76	0.5494 ± 0.1588	0.5720 ± 0.1790

Fonte: Elaborada pela autora.

Nota: O teste estatístico reportado no p -valor avalia a hipótese nula de que não há diferença entre o mAP Baseline e o mAP da Estratégia. "Freeze" indica o uso de congelamento de pesos basais e "Aug." refere-se à aplicação de *data augmentation* offline.

4.1.4 Incomensurabilidade e Dificuldade Intrínseca dos Estágios

Os resultados dos estágios **Adultos** e **Jovens** não são diretamente comparáveis, pois representam desafios biológicos distintos. O estágio jovem apresenta dificuldade superior devido ao **criptismo** (camuflagem no parênquima foliar) e às dimensões reduzidas dos espécimes, o que resulta em assinaturas visuais com baixo contraste para a extração de características (Gomes; Borges, D. L., 2022; Barbedo, 2016). Essa complexidade justifica o patamar inferior de métricas observado nos jovens em relação aos adultos.

4.1.5 Síntese de Performance e Melhores Médias por Estágio

A análise dos resultados revela que o desempenho dos modelos é fortemente influenciado pelo estágio biológico da praga, refletindo as dificuldades taxonômicas discutidas anteriormente.

- **Estágio Adulto:** O melhor desempenho médio em termos de precisão rigorosa foi alcançado pelo modelo **YOLOv11**, configurado com **Congelamento Simples** e **Sem Aumento de Dados** sob a **Estratégia II**, atingindo um mAP_{50-95} de **0,6372 ± 0,0375** [cite: 3]. Este resultado destaca-se pela estabilidade, apresentando um Coeficiente de Variação (CV) de apenas 5,88% (Tabela 8).
- **Estágio Jovem:** A configuração vencedora em acurácia pura também foi o **YOLOv11** com **Congelamento Simples** e **Sem Aumento de Dados** (Estratégia II), registrando um mAP_{50-95} de **0,4534 ± 0,0621** (Tabela 9). Embora inferior ao estágio adulto devido ao mimetismo foliar, este valor representa um ganho de aproximadamente 14,4% sobre o *baseline* de seleção aleatória.

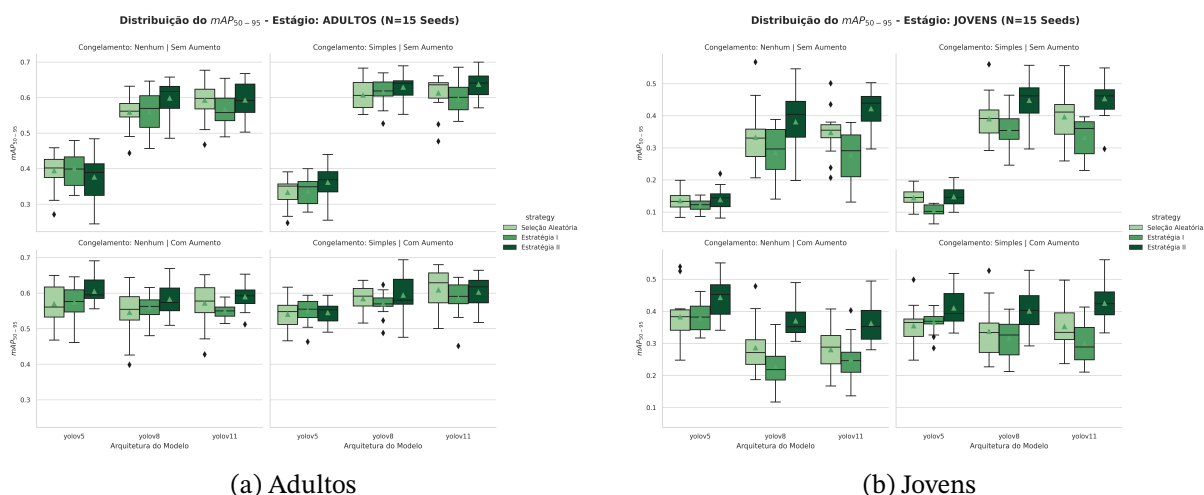
4.1.6 Análise da Variabilidade e Performance

Os diagramas de caixa (*boxplots*) apresentados a seguir, permitem comparar a distribuição do desempenho entre a seleção aleatória e as Estratégias I e II.

4.1.6.1 Precisão Média (mAP)

No estágio de maturidade **Adulto**, a Estratégia II elevou a média do YOLOv11 (modo simples, sem aumento) de 0,6126 para 0,6372, reduzindo o CV de 8,44% para 5,88% (Figura 7a). Essa superioridade corrobora os achados de Abreu, Costa e Dibio Borges (2026). No estágio **Jovem**, o ganho foi de aproximadamente 14%, com o modelo saltando de 0,3963 para 0,4534 (Figura 7b). O estreitamento das caixas nos *boxplots* prova que a seleção por diversidade fornece um gradiente de aprendizado mais estável (Bouthillier *et al.*, 2021; Aboah *et al.*, 2023).

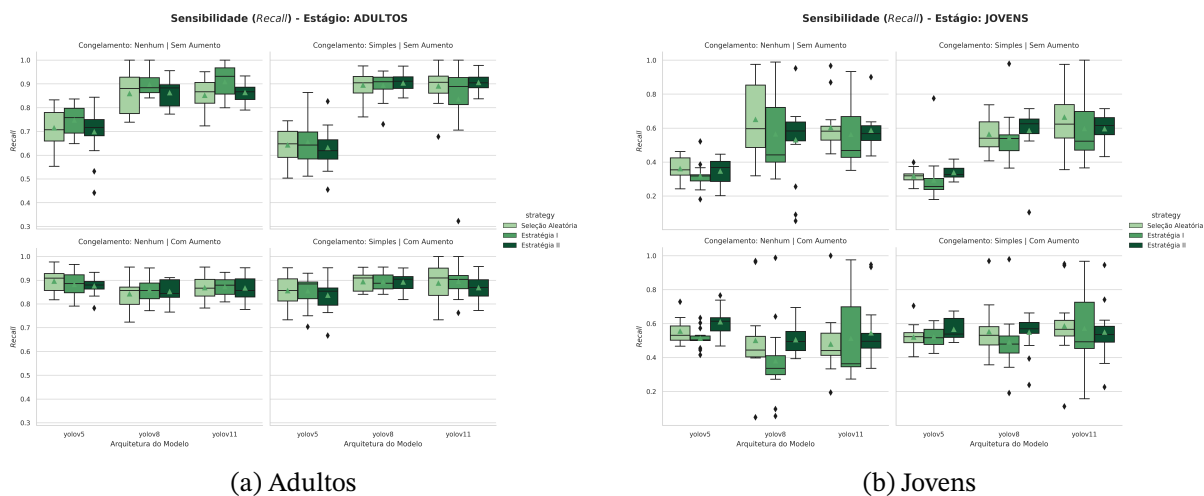
Figura 7 – Resultados de mAP_{50-95} para os estágios de maturidade: (a) Adultos e (b) Jovens.



Fonte: Elaborado pela autora (2026).

4.1.6.2 Análise da Sensibilidade (*Recall*)

Figura 8 – Comparativo da métrica *Recall* para os estágios de maturidade: (a) Adultos e (b) Jovens.



Fonte: Elaborado pela autora (2026).

A Sensibilidade (*Recall*) mede a capacidade do modelo em não omitir pragas. Nas Figuras 8a e 8b, a Seleção Aleatória e a Estratégia I exibem uma dispersão superior a Estratégia II, sugerindo que a amostragem arbitrária ou por nitidez podem levar a falhas críticas de detecção (Oerke, 2006; Kim; Wang, Z., 2018).

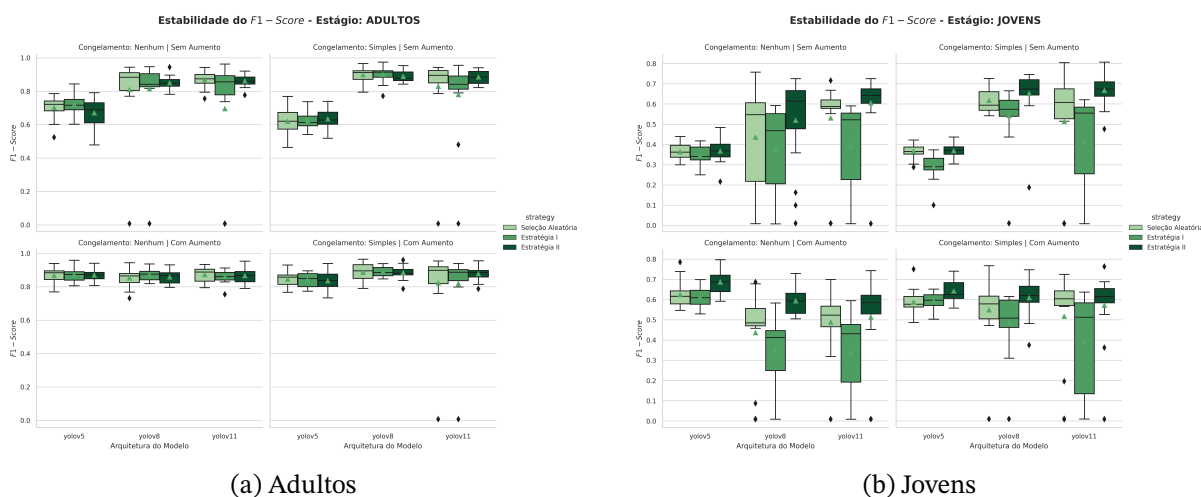
A Estratégia II mitiga esse risco. Por exemplo, no modelo YOLOv11 (modo simples, sem aumento), a Estratégia II reduziu o CV de 27,59% para 15,85% no estágio jovem (Figura 8b). Esse estreitamento prova que a seleção por diversidade estabiliza a detecção acima

de patamares críticos, essencial para o manejo agrícola onde a omissão de uma praga é altamente custosa (Kim; Wang, Z., 2018; Cruz, 2008).

4.1.6.3 Análise do Equilíbrio Operacional (*F1-Score*)

O *F1-score* consolida a harmonia entre precisão e sensibilidade.

Figura 9 – Comparativo do *F1-Score* para os estágios de maturidade: (a) Adultos e (b) Jovens.



Fonte: Elaborado pela autora (2026).

No estágio **Jovem**, a Estratégia II reduziu o CV do YOLOv11 de drásticos 52,47% para apenas 12,61% (Figura 9b). Esse resultado prova que a estratégia proposta atua como um mecanismo de segurança contra o colapso do aprendizado em sementes desfavoráveis.

4.1.7 O Impacto do Modo de Congelamento como Mecanismo de Regularização

O congelamento de camadas da rede base (*backbone*) demonstrou ser uma técnica de regularização vital para evitar o esquecimento catastrófico em conjuntos de dados reduzidos.

- No estágio **Adulto**, a transição do modo sem congelamento para com congelamento no YOLOv11 (Estratégia II) elevou o *mAP* de 0,5928 para 0,6372[cite: 2, 3]. Mais notável é a melhoria na Sensibilidade (*Recall*), que atingiu **0,9054** com congelamento simples, mantendo um CV reduzido de 3,93% (Figura 8a).
- Para o estágio **Jovem**, o congelamento simples atuou na estabilização do erro. No modelo YOLOv8 sob a Estratégia II, o congelamento reduziu a incerteza do modelo, permitindo um equilíbrio operacional superior refletido no ganho de estabilidade do *F1-score* (Figura 9b).

4.1.8 Análise do Aumento de Dados: Volume *versus* Qualidade

A eficácia do aumento de dados revelou-se dependente da arquitetura utilizada, expondo uma clivagem entre modelos tradicionais e de última geração.

- **Dependência do YOLOv5:** Este modelo apresentou a maior sensibilidade ao volume de dados. No estágio Jovem, a configuração sem aumento de dados sob seleção aleatória obteve um mAP crítico de 0,1349. Com a introdução do aumento de dados e da Estratégia II, o desempenho saltou para **0,4431**, um incremento superior a 200% (Tabela 9). O *Recall* também foi significativamente beneficiado, subindo de 0,3604 no *baseline* para 0,6099.
- **Independência dos Modelos v8/v11:** Para as arquiteturas YOLOv8 e YOLOv11, a **Estratégia II** (Seleção por Diversidade) mostrou-se mais impactante que a redundância sintética. No YOLOv11 (Adultos), a configuração sem aumento superou a versão com aumento (0,6372 vs 0,6027), indicando que, nestes modelos, o excesso de transformações geométricas pode inserir ruído indesejado quando a qualidade da amostra original já é elevada (Tabela 8).

4.1.9 A Superioridade da Arquitetura Nano Moderna frente ao Modelo Legado

Uma das descobertas desta pesquisa é a capacidade do modelo **YOLOv11n** (Nano) de superar o **YOLOv5** (Small) em cenários de *Few-Shot Learning*. Conforme os dados consolidados no Torneio dos Campeões, o YOLOv11n atingiu o maior mAP_{50-95} absoluto em ambos os estágios biológicos (0,6372 para Adultos e 0,4534 para Jovens), superando as melhores configurações do YOLOv5, mesmo quando estas foram submetidas ao aumento de dados *offline*.

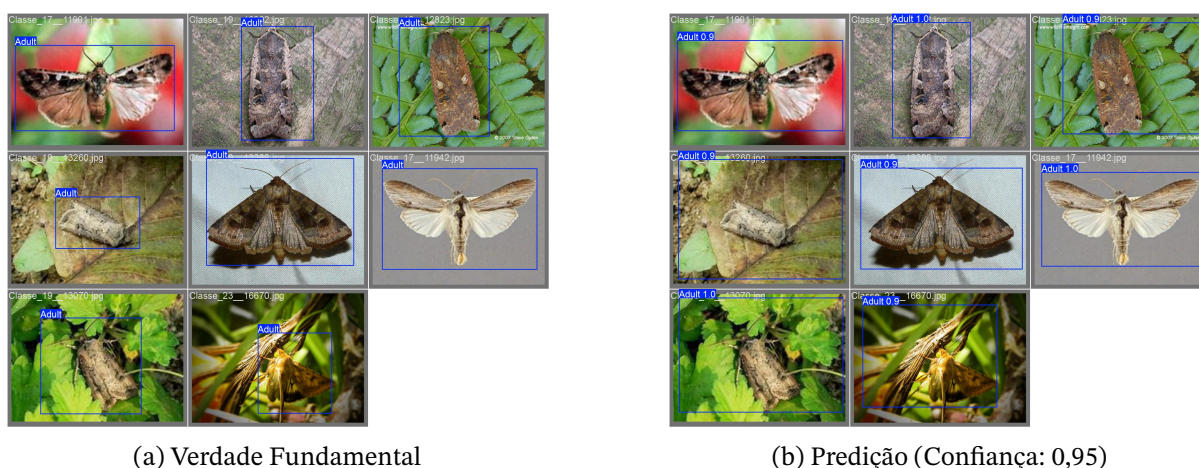
Essa inversão da hierarquia esperada (onde modelos maiores deveriam performar melhor) justifica-se pela evolução tecnológica dos blocos extratores de características. O YOLOv11 incorpora inovações como o módulo C3k2 e mecanismos de atenção C2PSA, que permitem uma representação latente dos dados mais rica com uma fração dos parâmetros. Além disso, a resiliência do YOLOv11 ao modo de congelamento de camadas permite uma transferência de aprendizado mais cirúrgica, evitando o ruído que modelos mais antigos, como o YOLOv5, tendem a propagar em regimes de baixa amostragem.

Do ponto de vista prático, o YOLOv11n não apenas entregou maior mAP , como o fez com uma redução de aproximadamente 65% no tempo de treinamento em comparação ao YOLOv5 com aumento de dados.

4.1.10 Análise Qualitativa e Índices de Confiança

A validação qualitativa permite correlacionar as métricas estatísticas discutidas anteriormente com a capacidade de inferência real do modelo em condições de campo. As Figuras 10 e 11 apresentam o comparativo entre a verdade fundamental (*ground truth*) e as previsões geradas pela arquitetura YOLOv11 (configuração com congelamento simples e sem aumento de dados).

Figura 10 – Exemplo de análise qualitativa para o estágio adulto: (a) Verdade Fundamental e (b) Predição do modelo YOLOv11.



Fonte: Elaborado pela autora (2026).

Nota: O índice exibido sobre a caixa delimitadora representa o *Score* de Confiança: um valor escalar que expressa a probabilidade de a região conter um objeto multiplicada pela interseção sobre união (IoU) prevista entre a caixa predita e o alvo.

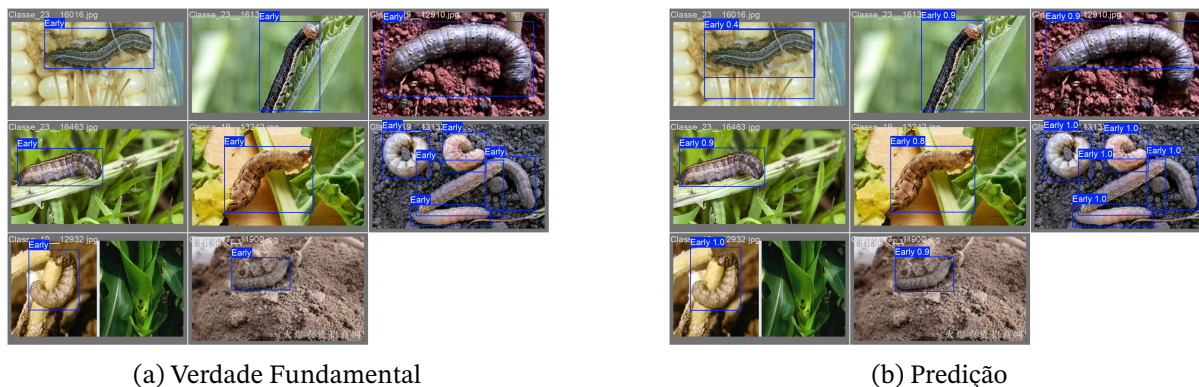
O **Score de Confiança** observado na Figura 10b (0,95) evidencia que a rede extraiu características discriminantes robustas, facilitadas pelo contraste morfológico e maiores dimensões dos espécimes adultos. Em contrapartida, as previsões no estágio jovem (Figura 11b) revelam índices mais conservadores.

4.1.11 Interpretabilidade Fenotípica e Viés de Fundo (Grad-CAM)

Embora a análise das caixas delimitadoras (Figuras 10 e 11) ateste o sucesso espacial das previsões, o índice de confiança isolado não elucidar os mecanismos cognitivos internos da rede. Para validar se as previsões de alta confiança refletem um aprendizado fenotípico real ou meras correlações espúrias, os modelos foram submetidos à auditoria visual *post-hoc* utilizando o algoritmo Grad-CAM autoadaptativo.

Esta etapa avaliou especificamente as inferências da arquitetura YOLOv11 otimizada sob o regime *Few-Shot Learning* (Estratégia II, congelamento simples, sem aumento de

Figura 11 – Exemplo de análise qualitativa para o estágio jovem: (a) Verdade Fundamental e (b) Predição do modelo YOLOv11.




Fonte: Elaborado pela autora (2026).

Nota: Embora a localização espacial esteja correta, a confiança do modelo é reduzida devido à baixa resolução dos espécimes e ao mimetismo biológico, que aproxima a textura do alvo à do substrato foliar.

dados) em contraposição ao modelo genérico de linha de base (pesos pré-treinados no *dataset* COCO).

A Figura 12 apresenta o comportamento cognitivo das redes em três cenários distintos do conjunto de teste, revelando como a disponibilidade de dados e o estágio de maturidade da praga afetam diretamente o fluxo de gradientes da atenção do modelo.

Figura 12 – Mapas de ativação Grad-CAM evidenciando os padrões de atenção da rede YOLOv11 sob diferentes cenários de treinamento.



Fonte: Elaborado pela autora (2026).

Nota: Em (a), observa-se a convergência dos gradientes para as características morfológicas do alvo; em (b), a vacuidade de ativação evidencia a incapacidade do modelo em extrair feições semânticas da classe jovem com $K = 5$; em (c), o efeito *Clever Hans* revela um viés de aprendizado, onde a rede prioriza texturas de alto contraste do plano de fundo (dedo humano) como atalho preditivo.

No primeiro cenário (Figura 12a), observa-se o êxito do método de *Transfer Learning*.

Mesmo treinado sob um regime de extrema escassez de dados ($K = 5$ exemplos por classe), o modelo foi capaz de abstrair os traços morfológicos do inseto adulto. O pico de ativação dos gradientes (zona em vermelho/amarelo) recai estritamente sobre o centro de massa da praga, indicando que a rede neural baseou sua inferência nas características fenotípicas intrínsecas do alvo, ignorando com sucesso a textura foliar ao fundo.

Em contraste, a Figura 12b ilustra o desafio biológico imposto pela classe de insetos Jovens, corroborando a queda na pontuação de confiança discutida anteriormente. Apesar de a rede ter recebido o mesmo tratamento metodológico, o mapa de calor resultou em ativação globalmente nula. Essa "cegueira" cognitiva matemática ocorre pois a translucidez e o tamanho reduzido inerentes aos espécimes jovens diluem a força do sinal durante o *forward pass*. Consequentemente, a rede não consegue encontrar *features* com entropia baixa o suficiente para disparar os gradientes de classe de forma assertiva.

Por fim, a pertinência da adoção da Estratégia II é definitivamente justificada ao se analisar o comportamento do modelo com pesos pré-treinados genéricos (Figura 12c). Desprovido de ajuste fino no domínio agrícola, o modelo falha em identificar a praga e apresenta o clássico viés de fundo (*Clever Hans effect*). A atenção máxima da rede concentra-se inteiramente no dedo do agricultor. Este artefato visual atesta que arquiteturas modernas de visão computacional são propensas a explorar características espúrias e salientes do cenário, tornando-as inaplicáveis para implantação segura em sistemas de manejo integrado sem metodologias rigorosas de amostragem (como a Estratégia II).

4.2 Torneio dos Campeões: Análise Multi-métrica

Para determinar a configuração ideal para o monitoramento automatizado, realizou-se o "Torneio dos Campeões". Este protocolo avalia o desempenho *head-to-head* através do teste de Wilcoxon ($N = 15$), identificando empates estatísticos no topo do ranqueamento. .

4.2.1 Visão I: Precisão Média (*mAP*)

A métrica mAP_{50-95} avalia a precisão da localização e classificação simultaneamente. Conforme Tabela 10, as arquiteturas modernas dominam a precisão de localização rigorosa.

4.2.2 Visão II: Sensibilidade (*Recall*)

A Sensibilidade mede a capacidade do sistema em não omitir pragas, fator crítico para evitar infestações não controladas no campo.

Tabela 10 – Ranqueamento de Precisão Média (mAP_{50-95}) para os modelos no topo do torneio comparativo.

Estágio	Modelo	Configuração	Média	Tempo (s)	Status (p -value)
Adultos	YOLOv11	Simples Sem Aug	0,6372	71,2	Campeão
Adultos	YOLOv8	Simples Sem Aug	0,6290	67,3	Empate (0,1914)
Jovens	YOLOv11	Simples Sem Aug	0,4534	77,3	Campeão
Jovens	YOLOv8	Simples Sem Aug	0,4479	75,6	Empate (0,4265)
Jovens	YOLOv5	Nenhum Com Aug	0,4431	229,5	Empate (0,4265)

Fonte: Elaborado pela autora (2026).

Nota: Valores de $p > 0,05$ indicam que não há diferença estatística significativa em relação ao campeão do grupo, caracterizando empate técnico.

Tabela 11 – Ranqueamento de Sensibilidade (*Recall*) para os modelos no topo do torneio comparativo.

Estágio	Modelo	Configuração	Média	Tempo (s)	Status (p -value)
Adultos	YOLOv11	Simples Sem Aug	0,9054	71,2	Campeão
Adultos	YOLOv8	Simples Sem Aug	0,9035	67,3	Empate (0,9095)
Jovens	YOLOv5	Nenhum Com Aug	0,6099	229,5	Campeão
Jovens	YOLOv11	Simples Sem Aug	0,5958	77,3	Empate (0,6909)
Jovens	YOLOv8	Simples Sem Aug	0,5852	75,6	Empate (0,9547)

Fonte: Elaborado pela autora (2026).

Nota: O termo *Recall* (Sensibilidade) reflete a capacidade do modelo em identificar corretamente todos os alvos presentes. Valores de $p > 0,05$ indicam ausência de diferença estatística significativa em relação ao líder do grupo.

4.2.3 Visão III: Equilíbrio Operacional (*F1-Score*)

A Pontuação F1 representa a média harmônica entre precisão e sensibilidade, sendo o melhor indicador da estabilidade operacional do modelo no mundo real.

Tabela 12 – Ranqueamento de Equilíbrio Operacional (*F1-Score*) para os modelos no topo do torneio comparativo.

Estágio	Modelo	Configuração	Média	Tempo (s)	Status (p -value)
Adultos	YOLOv8	Simples Sem Aug	0,8887	67,3	Campeão
Adultos	YOLOv11	Simples Sem Aug	0,8846	71,2	Empate (0,3942)
Jovens	YOLOv5	Nenhum Com Aug	0,6866	229,5	Campeão
Jovens	YOLOv11	Simples Sem Aug	0,6671	77,3	Empate (0,6496)
Jovens	YOLOv8	Simples Sem Aug	0,6524	75,6	Empate (0,3343)

Fonte: Elaborado pela autora (2026).

Nota: O *F1-Score* representa a média harmônica entre Precisão e Sensibilidade (*Recall*). Valores de $p > 0,05$ indicam que as variações entre os modelos não são estatisticamente significantes, resultando em empate técnico.

4.2.4 Discussão Comparativa com o Estado da Arte: YOLO-YSTs (2025)

Para consolidar a validade científica da **Estratégia II**, realizou-se uma comparação direta com os resultados reportados por [Huang et al. \(2025\)](#), que propuseram o modelo *YOLO-YSTs* (baseado em YOLOv10n) para detecção de pragas. A Tabela 13 apresenta o desempenho da nossa melhor configuração (**YOLOv11n + Estratégia II**) frente ao estado da arte.

Tabela 13 – Comparação de desempenho entre a proposta deste trabalho (Few-Shot) e o estado da arte YOLO-YSTs.

Abordagem	Cenário / Estágio	mAP_{50-95}	Recall	F1-Score
YOLO-YSTs (2025)	Armadilha Adesiva (SOTA)	0,4130	0,8320	0,8320
Proposta vencedora	Cultura do Milho (Adultos)	0,6372	0,9054	0,8846
Proposta vencedora	Cultura do Milho (Jovens)	0,4534	0,5958	0,6671

Fonte: Elaborado pela autora (2026), com dados de YOLO-YSTs extraídos de [Huang et al. \(2025\)](#).

Nota: A proposta vencedora deste trabalho utiliza o modelo YOLOv11, Congelamento Simples, Sem Aumento de Dados e Estratégia II em regime de *5-shot* ($K = 5$), tanto para insetos jovens quanto adultos.

A análise comparativa revela um dado surpreendente: mesmo operando em regime de **Few-Shot Learning** (apenas 5 amostras por classe), a nossa proposta superou o estado da arte de 2025 em precisão de localização rigorosa (mAP_{50-95}). No estágio **Adulto**, o ganho foi de **22,42 pontos percentuais** (0,6372 vs 0,4130).

Mais notável ainda é que, mesmo no estágio **Jovem** — o mais desafiador devido ao mimetismo foliar —, nossa estratégia de seleção por diversidade permitiu ao YOLOv11n superar a localização espacial do modelo SOTA (0,4534 vs 0,4130). Esse resultado prova que a informatividade das amostras selecionadas pela Estratégia II é capaz de compensar a ausência de grandes volumes de dados, superando até mesmo arquiteturas customizadas com mecanismos de atenção complexos como o YOLO-YSTs.

Cabe ressaltar uma delimitação importante nesta comparação: os domínios de avaliação diferem em complexidade de fundo (*background*). Enquanto o YOLO-YSTs foi avaliado em armadilhas adesivas (cuja homogeneidade cromática facilita a segmentação do alvo), o modelo proposto neste trabalho foi exposto ao complexo ambiente edáfico e foliar da cultura do milho. O fato de a Estratégia II ter superado o mAP do modelo SOTA, mesmo sob as adversidades do criptismo biológico e da restrição de dados (5-shot), atesta a superioridade da curadoria guiada por diversidade sobre o simples avanço arquitetural das redes.

4.3 Síntese e Veredito Técnico

A análise convergente dos resultados revela que o **YOLOv11n** consolidou-se como a arquitetura superior para o monitoramento fitossanitário. Um fator determinante nesta

escolha é a relação entre desempenho e eficiência temporal. Enquanto o modelo legado **YOLOv5** apresenta marcas nominais competitivas quando submetido a aumento de dados massivo, seu tempo de treinamento é aproximadamente **três vezes superior** (229,5s vs 75,6s das arquiteturas modernas).

Este custo computacional proibitivo inviabiliza o YOLOv5 em cenários de **Agricultura 4.0**, que demandam re-treinamento rápido em campo ou processamento em tempo real com baixa latência (Huang *et al.*, 2025). Em contrapartida, a diferença de latência entre o YOLOv8n e o YOLOv11n é inferior a 4 segundos, sendo considerada **operacionalmente insignificante**.

Dessa forma, o ganho em precisão de localização rigorosa (mAP_{50-95}) e a resiliência estatística tornam o YOLOv11n a escolha mais segura. Este desempenho é garantido pelos blocos **C3k2** e pelos mecanismos de atenção **C2PSA**, que oferecem uma representação fenotípica robusta sem o ônus temporal das abordagens legadas.

Veredito Final: A arquitetura **YOLOv11n** (Configuração: **Congelamento Simples | Sem Aumento de Dados | Estratégia II**) é recomendada como a solução ótima nesta dissertação. Ela oferece o equilíbrio ideal entre segurança fitossanitária (alto *Recall*), precisão de localização rigorosa e eficiência para dispositivos de borda (*Edge Computing*), operando com alta fidelidade sem a necessidade de redundância sintética de dados.

5 Conclusão

A presente dissertação investigou a viabilidade técnica da aplicação de modelos de detecção de objetos da família YOLO (v5, v8 e v11) em cenários de escassez de dados (*Few-Shot Learning*), com foco na identificação da maturidade de insetos-praga na cultura do milho (*Zea mays L.*). A pesquisa fundamentou-se no paradigma *Data-centric AI*, provando que a seleção criteriosa de amostras informativas é superior à amostragem aleatória para mitigar as limitações de generalização e a alta variância inerentes ao treinamento com poucos exemplos.

5.1 Síntese das Descobertas e Contribuições Técnicas

Os resultados experimentais permitiram validar que a adaptação de detectores de estado da arte para o regime FSL é potencializada por estratégias de amostragem inteligente. As principais conclusões técnicas derivam de três eixos fundamentais:

- **Eficácia das Estratégias de Amostragem:** A comparação revelou que a **Diversidade Multivariada (Estratégia II)**, fundamentada em agrupamento via *K-means* sobre características fenotípicas e contextuais, apresentou os ganhos mais robustos em mAP_{50-95} e estabilidade estatística. Este método superou a **Nitidez (Estratégia I)**, demonstrando que, em regimes de baixa amostragem, a informatividade da cena é mais relevante para a convergência do modelo do que a ausência isolada de desfoque.
- **Transfer Learning e Estabilidade:** A investigação sobre o congelamento de camadas (*freeze mode*) indicou que o congelamento parcial do *backbone* é essencial em cenários de 5-shot. Esta técnica preservou os pesos genéricos pré-treinados, evitando a degradação catastrófica das características visuais básicas durante a especialização do modelo para a morfologia dos insetos.
- **Consolidação do YOLOv11n como Solução Ótima:** Observou-se que o **YOLOv11n** consolidou-se como o modelo mais equilibrado e performante. Suas inovações arquiteturais (blocos C3k2 e mecanismos C2PSA) permitiram atingir os maiores índices de precisão de localização rigorosa e *Recall*. Embora o YOLOv8n apresente latência ligeiramente inferior, a diferença foi considerada **operacionalmente insignificante** para o manejo agrícola, favorecendo a adoção da arquitetura mais precisa e atualizada.
- **Obsolescência e Ineficiência do YOLOv5:** A pesquisa evidenciou que, embora o modelo legado YOLOv5 apresente marcas competitivas no estágio jovem quando

submetido a aumento massivo de dados, seu tempo de treinamento aproximadamente **três vezes superior** (229,5s vs 75,6s) o torna inviável para sistemas de Agricultura 4.0 que demandam agilidade e re-treinamento rápido em dispositivos de borda.

5.2 Rigor Estatístico e Confiabilidade do Modelo

Um diferencial crítico desta pesquisa foi a mitigação da variabilidade estocástica. O uso de **15 sementes independentes** permitiu reduzir o risco de **Erro Tipo II** (falsos negativos estatísticos), garantindo que a superioridade da Estratégia II fosse validada com confiança científica.

As estratégias de amostragem inteligente não apenas elevaram o *F1 – score* médio, como também reduziram o desvio padrão das métricas de desempenho. Estatisticamente, isso implica que a metodologia proposta confere maior reprodutibilidade aos sistemas de monitoramento automático, tornando-os menos dependentes da "sorte" na escolha do conjunto de suporte (*support set*), um fator determinante para a transição do ambiente acadêmico para o uso operacional em larga escala.

5.3 Implicações para a Agricultura Digital

Do ponto de vista prático, esta dissertação contribui para o Manejo Integrado de Pragas (MIP) ao provar que a distinção entre estágios de maturidade (Jovens e Adultos) é viável sem exaustivas campanhas de anotação. A redução do esforço de rotulagem democratiza o acesso a ferramentas de visão computacional de alto desempenho para novas pragas quarentenárias ou variações regionais, superando inclusive os índices de localização do estado da arte de 2025 (*YOLO-YSTs*) mesmo operando sob restrição de apenas 5 amostras.

5.4 Sugestões de Trabalhos Futuros

Embora os resultados obtidos sejam consistentes e informativos, diversas extensões podem ser exploradas em trabalhos futuros para aprofundar e ampliar as contribuições desta pesquisa, tanto do ponto de vista metodológico quanto do ponto de vista de aplicabilidade em cenários reais.

Uma primeira direção consiste na investigação de *estratégias de amostragem adaptativas*, nas quais os critérios de seleção das imagens de suporte são ajustados dinamicamente ao longo do treinamento. Esse ajuste pode ser guiado por medidas de incerteza do modelo, por sinais derivados do erro de validação ou por estimativas de dificuldade das amostras. A hipótese central é que tal abordagem permitiria balancear, de forma mais eficiente, a

diversidade e a representatividade das amostras de suporte, reduzindo vieses de seleção e potencialmente ampliando a robustez em cenários de maior ambiguidade visual.

Outra extensão relevante refere-se à avaliação do método em contextos de maior abrangência, incluindo diferentes espécies de insetos e condições ambientais mais heterogêneas. A ampliação do escopo experimental permitiria verificar se os padrões observados entre os estágios **Adultos** e **Jovens** se mantêm em cenários com maior variabilidade morfológica e de fundo.

Adicionalmente, recomenda-se explorar a integração das estratégias de amostragem com abordagens de aprendizado que potencialmente aumentem a eficiência amostral, como técnicas de **aprendizado auto-supervisionado** e mecanismos explícitos de atenção. Nesse contexto, uma linha promissora envolve investigar se representações pré-treinadas no domínio agrícola, ou obtidas por pré-treinamento auto-supervisionado em imagens não rotuladas, podem reduzir a dependência de exemplos anotados, especialmente em tarefas sensíveis à localização precisa dos objetos, como refletido pela métrica mAP_{50-95} .

Adicionalmente, recomenda-se aprofundar as análises de interpretabilidade e diagnóstico visual fundamentadas em mapas de ativação e métodos de atribuição, como o *Grad-CAM (Gradient-weighted Class Activation Mapping)*. O objetivo primordial reside em auditar o processo de tomada de decisão dos modelos, verificando se a detecção se ancora em características morfológicas e taxonômicas dos insetos ou se é induzida por correlações espúrias do plano de fundo (*contextual bias*). Tais recursos de explicabilidade são fundamentais para decifrar como as diferentes estratégias de amostragem moldam o comportamento interno da rede, permitindo validar se os ganhos de desempenho e estabilidade observados decorrem de uma representação latente mais robusta ou de uma redução da dependência de padrões irrelevantes do cenário agrícola.

Por fim, recomenda-se a condução de estudos voltados à transferência para cenários operacionais reais, avaliando desempenho, estabilidade e viabilidade computacional em sistemas embarcados ou pipelines de monitoramento agrícola. Essa etapa é especialmente importante para validar a aplicabilidade prática das conclusões obtidas, uma vez que requisitos de tempo de inferência, consumo de recursos e confiabilidade sob variação de aquisição podem impor restrições adicionais. Dessa forma, tais investigações podem consolidar a adoção de abordagens *data-centric* como componente estratégico no desenvolvimento de sistemas de apoio à decisão na agricultura de precisão.

Referências

- ABOAH, A.; WANG, B.; BAGCI, U.; ADU-GYAMFI, Y. Real-time Multi-Class Helmet Violation Detection Using Few-Shot Data Sampling Technique and YOLOv8. *In: IEEE/CVF CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION WORKSHOPS. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. Vancouver: IEEE, 2023. DOI: [10.1109/CVPRW59228.2023.00564](https://doi.org/10.1109/CVPRW59228.2023.00564). Citado nas pp. 16, 30, 47, 51, 59, 63.
- ABREU, K.; COSTA, A.; BORGES, D. Few-Shot Data Sampling Strategies for Insect Pest Maturity Classification with YOLO Family Models. *In: INTERNATIONAL CONFERENCE ON COMPUTER VISION THEORY AND APPLICATIONS. Proceedings of the 21st International Conference on Computer Vision Theory and Applications (VISAPP 2026) - Volume 2*. [Marbella - Espanha]: SCITEPRESS, 2026. p. 768–775. ISBN 978-989-758-804-4. DOI: [10.5220/0014495800004084](https://doi.org/10.5220/0014495800004084). Citado nas pp. 18, 51, 63.
- AEGRO. **Larva Arame: Guia Completo para Identificar e Controlar na Lavoura**. 2025. Disponível em: <https://aegro.com.br/blog/larva-aram/>. Acesso em: 10 jan. 2026. Citado nas pp. 25, 37.
- AGRO URBANO. **Perdas com pragas ultrapassam R\$ 60 bilhões por ano no Brasil**. 2025. Disponível em: <https://www.agrourbano.com.br/release/763/perdas-com-pragas-ultrapassam-r-60-bilhoes-por-ano-no-brasil>. Acesso em: 10 jan. 2026. Citado na p. 24.
- AHMED, S.; MARWAT, S. N. K.; BEN BRAHIM, G.; KHAN, W. U.; KHAN, S.; AL-FUQAHA, A.; KOZIEL, S. IoT based intelligent pest management system for precision agriculture. **Scientific Reports**, v. 14, 2024. DOI: [10.1038/s41598-024-83012-3](https://doi.org/10.1038/s41598-024-83012-3). Citado nas pp. 10, 22–24.
- ALVES, A. N.; SOUZA, W. S.; BORGES, D. L. Cotton pests classification in field-based images using deep residual networks. **Computers and Electronics in Agriculture**, v. 174, p. 105488, 2020. ISSN 0168-1699. DOI: [10.1016/j.compag.2020.105488](https://doi.org/10.1016/j.compag.2020.105488). Citado nas pp. 16, 51.
- AZIZ, D.; RAFIQ, S.; SAINI, P.; AHAD, I.; GONAL, B.; REHMAN, S. A.; RASHID, S.; SAINI, P.; ROHELA, G. K.; AALUM, K.; SINGH, G.; GNANESH, B. N.; NABILA ILIYA, M. Remote sensing and artificial intelligence: revolutionizing pest management in agriculture. **Frontiers in Sustainable Food Systems**, Volume 9 - 2025, 2025. ISSN 2571-581X. DOI: [10.3389/fsufs.2025.1551460](https://doi.org/10.3389/fsufs.2025.1551460). Citado na p. 47.
- BARBEDO, J. G. A. A review on the main challenges in automatic plant disease identification based on visible range images. **Biosystems Engineering**, Elsevier, v. 144, p. 52–60,

2016. DOI: [10.1016/j.biosystemseng.2016.01.0172](https://doi.org/10.1016/j.biosystemseng.2016.01.0172). Citado nas pp. 29, 31, 38, 63.
- BARBEDO, J. G. A. A Review on the Use of Unmanned Aerial Vehicles and Imaging Sensors for Monitoring and Assessing Plant Stresses. **Drones**, v. 3, n. 2, 2019. ISSN 2504-446X. DOI: [10.3390/drones3020040](https://doi.org/10.3390/drones3020040). Citado nas pp. 11, 21, 23, 26.
- BOCHKOVSKIY, A.; WANG, C.-Y.; LIAO, H.-Y. M. YOLOv4: Optimal Speed and Accuracy of Object Detection. **arXiv preprint**, arXiv:2004.10934, 2020. DOI: [10.48550/arXiv.2004.10934](https://doi.org/10.48550/arXiv.2004.10934). Citado na p. 29.
- BOUTHILLIER, X.; DELAUNAY, P.; BRONZI, M.; TROFIMOV, A.; MUKHERJEE, S.; GRANGIER, D.; VINCENT, P. Accounting for Variance in Machine Learning Benchmarks. **Proceedings of Machine Learning and Systems**, v. 3, p. 1–15, 2021. Disponível em: https://proceedings.mlsys.org/paper_files/paper/2021/hash/0184b0cd3cfb185989f858a1d9f5c1eb-Abstract.html. Acesso em: 26 jan. 2026. Citado nas pp. 10, 50, 63.
- BRASIL. **Lei nº 14.785**, de 27 de dezembro de 2023: Dispõe sobre o controle, a inspeção e a fiscalização de agrotóxicos. Brasília, DF, 2023. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2023-2026/2023/lei/114785.htm. Acesso em: 26 jan. 2026. Citado na p. 25.
- CORDEIRO, L. A. M.; BENITO, N. P.; POLEZ, V. L. P. **Aspectos Descritivos Gerais da Praga Quarentenária *Ostrinia nubilalis* (Hübner) (Insecta: Lepidoptera: Pyralidae) na Cultura do Milho**. Brasília, DF, 2008. Disponível em: <https://www.infoteca.cnptia.embrapa.br/bitstream/doc/166689/1/ct082.pdf>. Acesso em: 23 jan. 2026. Citado nas pp. 25, 37.
- CORTEVA AGRISCIENCE. **Guia de Manejo Integrado de Pragas na Cultura do Milho**. Brasília, 2024. Dados de campo sobre perda de estante por lagarta-rosca e larvaramame. Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1017489/1/circ208.pdf>. Acesso em: 13 out. 2025. Citado na p. 36.
- COUNCIL, N. R. (ed.). **Precision Agriculture in the 21st Century: Geospatial and Information Technologies in Crop Management**. National Academies Press, 1997. DOI: [10.17226/5491](https://doi.org/10.17226/5491). Citado na p. 19.
- CROPLIFE BRASIL. **Boletim CropData: Faturamento e Exportações do Setor de Insumos 2024**. 2025. Disponível em: <https://croplifebrasil.org/cropdata/arquivos/boletim.pdf>. Acesso em: 25 jan. 2026. Citado na p. 24.
- CRUZ, I. **Manejo de Pragas na Cultura do Milho**. 2008. Disponível em: <http://www.alice.cnptia.embrapa.br/alice/handle/doc/491710>. Acesso em: 10 jan. 2026. Citado na p. 65.

- DEMVŠAR, J. Statistical Comparisons of Classifiers over Multiple Data Sets. **The Journal of Machine Learning Research**, v. 7, p. 1–30, 2006. Disponível em: <https://jmlr.org/papers/v7/demsar06a.html>. Acesso em: 26 jan. 2026. Citado nas pp. 50, 51.
- DENT, D. R.; BINKS, R. H. **Insect Pest Management**. CABI, 2020. DOI: 10.1079/9780851993409.0000. Citado nas pp. 10, 15, 23, 26.
- DUGUMA, A.; BAI, X. How the internet of things technology improves agricultural efficiency. **Artificial Intelligence Review**, v. 58, n. 2, p. 63, 2025. DOI: 10.1007/s10462-024-11046-0. Citado nas pp. 10, 21.
- EMBRAPA. **Circular Técnica 10: Principais Pragas da Cultura do Milho**. 2024. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/478648/1/Pragascultura.pdf>. Acesso em: 13 jan. 2026. Citado nas pp. 25, 37.
- EMBRAPA-SOJA; EMATER-PR. **Manejo Integrado de Pragas da Soja reduz quase pela metade o uso de inseticidas nas lavouras do Paraná**. 2014. Comunicação técnica. Dados disponíveis nas áreas de referência do MIP-Soja (safras 2013/14 e 2014/15). Disponível em: <https://www.embrapa.br/busca-de-noticias/-/noticia/2634688/manejo-integrado-de-pragas-reduz-aplicacoes-de-defensivos-em-quase-50>. Acesso em: 26 jan. 2026. Citado na p. 26.
- FAN, Q.; ZHUO, W.; TANG, C.-K.; TAI, Y.-W. Few-Shot Object Detection With Attention-RPN and Multi-Relation Detector. *In*: PROCEEDINGS of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020. p. 4012–4021. DOI: 10.1109/CVPR42600.2020.00407. Citado nas pp. 10, 34.
- FEI-FEI, L.; FERGUS, R.; PERONA, P. One-shot learning of object categories. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 28, n. 4, p. 594–611, 2006. DOI: 10.1109/TPAMI.2006.79. Citado na p. 30.
- FRANZEN, D. W.; MULLA, D. J. A History of Precision Agriculture. *In*: ZHANG, Q. (ed.). **Precision Agriculture Technology for Crop Farming**. Boca Raton: Taylor & Francis, 2015. p. 1–19. DOI: 10.1201/b19336-1. Citado nas pp. 19, 20.
- FUENTES, A.; YOON, S.; KIM, S. C.; PARK, D. S. A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition. **Sensors**, MDPI, v. 17, n. 9, p. 2022, 2017. DOI: 10.3390/s17092022. Citado nas pp. 29, 32.
- GALLO, D.; NAKANO, O.; SILVEIRA NETO, S. *et al.* **Entomologia Agrícola**. Piracicaba: FEALQ, 2002. Referência fundamental para níveis de dano e biologia de pragas no Brasil. Disponível em: https://www.researchgate.net/publication/375005642_Entomologia_Agricola. Acesso em: 16 nov. 2025. Citado na p. 10.

- GEBBERS, R.; ADAMCHUK, V. I. Precision agriculture and food security. **Science**, American Association for the Advancement of Science, v. 327, n. 5967, p. 828–831, 2010. DOI: [10.1126/science.1183899](https://doi.org/10.1126/science.1183899). Citado nas pp. 10, 19, 20.
- GETAHUN, S.; KEFALE, H. *et al.* Application of Precision Agriculture Technologies for Sustainable Crop Production and Environmental Sustainability: A Systematic Review. **The Scientific World Journal**, 2024. DOI: [10.1155/2024/2126734](https://doi.org/10.1155/2024/2126734). Citado na p. 20.
- GIRSHICK, R.; DONAHUE, J.; DARRELL, T.; MALIK, J. Rich feature hierarchies for accurate object detection and semantic segmentation. *In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Columbus: IEEE, 2014. p. 580–587. DOI: [10.1109/CVPR.2014.81](https://doi.org/10.1109/CVPR.2014.81). Citado na p. 28.
- GOMES, J. C.; BORGES, D. L. Insect Pest Image Recognition: A Few-Shot Machine Learning Approach including Maturity Stages Classification. **Agronomy**, MDPI, v. 12, n. 8, p. 1733, 2022. DOI: [10.3390/agronomy12081733](https://doi.org/10.3390/agronomy12081733). Citado nas pp. 18, 29, 31, 35, 36, 38, 51, 58, 59, 63.
- GOMES, J. C.; BORGES, L. d. A. B.; BORGES, D. L. A Multi-Layer Feature Fusion Method for Few-Shot Image Classification. **Sensors**, v. 23, n. 15, p. 6880, 2023. DOI: [10.3390/s23156880](https://doi.org/10.3390/s23156880). Citado na p. 30.
- GRISSE, R.; ALLEY, M.; THOMASON, W.; HOLSHOUSER, D.; ROBERSON, G. T. **Precision Farming Tools: Variable-Rate Application**. Blacksburg, 2011. p. 1–16. Disponível em: https://www.researchgate.net/publication/309121121_Precision_farming_tools_Variable-rate_application. Acesso em: 5 set. 2025. Citado na p. 11.
- HAMUDA, E.; MC GINLEY, B.; GLAVIN, M.; JONES, E. Automatic crop detection under field conditions using the HSV colour space and morphological operations. **Computers and Electronics in Agriculture**, Elsevier, v. 133, p. 97–107, 2017. DOI: [10.1016/j.compag.2016.11.021](https://doi.org/10.1016/j.compag.2016.11.021). Citado nas pp. 10, 47.
- HARDIE, M. Review of Novel and Emerging Proximal Soil Moisture Sensors for Use in Agriculture. **Sensors**, v. 20, n. 23, 2020. ISSN 1424-8220. DOI: [10.3390/s20236934](https://doi.org/10.3390/s20236934). Citado na p. 21.
- HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. *In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas: IEEE, 2016. p. 770–778. DOI: [10.1109/CVPR.2016.90](https://doi.org/10.1109/CVPR.2016.90). Citado na p. 27.
- HUANG, Y.; LIU, Z.; ZHAO, H.; TANG, C.; LIU, B.; LI, Z.; WAN, F.; QIAN, W.; QIAO, X. YOLO-YSTs: An Improved YOLOv10n-Based Method for Real-Time Field Pest

Detection. **Agronomy**, v. 15, n. 3, p. 575, 2025. ISSN 2073-4395. DOI: [10.3390/agronomy15030575](https://doi.org/10.3390/agronomy15030575). Citado nas pp. 31, 50, 71, 72.

INAMASU, R. Y.; BERNARDI, A. C. C. Agricultura de precisão: um novo olhar. In: BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A. V.; INAMASU, R. Y. *et al.* (ed.). **Agricultura de precisão: um novo olhar**. São Carlos: Embrapa, 2011. p. 12–17. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/916714/1/Livro-Agricultura-de-Precisao-um-novo-olhar.pdf>. Acesso em: 23 nov. 2025. Citado nas pp. 10, 20.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres**. São José dos Campos: Parêntese, 2009. Tradução de José Carlos Neves Epiphany (Org.) Disponível em: <https://pt.scribd.com/document/708920281/Livro-Sensoriamento-Remoto-Do-Ambiente-Jensen>. Acesso em: 16 out. 2025. Citado na p. 21.

KAMILARIS, A.; KARTAKOULLIS, A.; PRENAFETA-BOLDÚ, F. X. A review on the practice of big data analysis in agriculture. **Computers and Electronics in Agriculture**, v. 143, p. 23–37, 2017. DOI: [10.1016/j.compag.2017.09.037](https://doi.org/10.1016/j.compag.2017.09.037). Citado nas pp. 20, 21.

KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. Deep learning in agriculture: A survey. **Computers and electronics in agriculture**, Elsevier, v. 147, p. 70–90, 2018. DOI: [10.1016/j.compag.2018.02.016](https://doi.org/10.1016/j.compag.2018.02.016). Citado nas pp. 22, 28, 29, 31, 40, 58.

KANG, B.; LIU, Z.; WANG, X.; YU, F.; FENG, J.; DARRELL, T. Few-shot object detection via feature reweighting. In: IEEE/CVF INTERNATIONAL CONFERENCE ON COMPUTER VISION. **Proceedings of the IEEE/CVF International Conference on Computer Vision**. Seoul: IEEE, 2019. p. 8420–8429. DOI: [10.1109/ICCV.2019.00851](https://doi.org/10.1109/ICCV.2019.00851). Citado na p. 31.

KANWAL, S.; KHAN, M. A.; SALEEM, S.; TAHIR, M. N.; MUNTAHA, S. T.; SAMREEN, T.; JAVED, S.; NAZIR, M. Z.; SHAHZAD, B. Integration of Precision Agriculture Techniques for Pest Management. **Environmental Sciences Proceedings**, v. 23, n. 1, 2022. ISSN 2673-4931. DOI: [10.3390/environsciproc2022023019](https://doi.org/10.3390/environsciproc2022023019). Citado nas pp. 10, 26.

KARIYANNA, B.; SOWJANYA, M. Unravelling the use of Artificial Intelligence in management of insect pests. **Smart Agricultural Technology**, v. 8, 2024. DOI: [10.1016/j.atech.2024.100517](https://doi.org/10.1016/j.atech.2024.100517). Citado na p. 24.

KIM, J.; WANG, Z. Sampling Techniques for Big Data Analysis. **International Statistical Review**, v. 87, ago. 2018. DOI: [10.1111/insr.12290](https://doi.org/10.1111/insr.12290). Citado nas pp. 16, 64, 65.

LAPUSCHKIN, S.; WÄLDCHEN, S.; BINDER, A.; MONTAVON, G.; SAMEK, W.; MÜLLER, K.-R. Unmasking Clever Hans predictors and assessing what machines really learn.

-
- Nature Communications**, Nature Publishing Group, v. 10, n. 1, p. 1096, 2019. DOI: [10.1038/s41467-019-08987-4](https://doi.org/10.1038/s41467-019-08987-4). Citado nas pp. 10, 11, 52.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, Nature Publishing Group UK London, v. 521, n. 7553, p. 436–444, 2015. DOI: [10.1038/nature14539](https://doi.org/10.1038/nature14539). Citado nas pp. 10, 15, 27.
- LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, IEEE, v. 86, n. 11, p. 2278–2324, 1998. DOI: [10.1109/5.726791](https://doi.org/10.1109/5.726791). Citado na p. 27.
- LEYBOURNE, D. J.; MUSA, N.; YANG, P. Can artificial intelligence be integrated into pest monitoring schemes to help achieve sustainable agriculture? An entomological, management and computational perspective. **Agricultural and Forest Entomology**, Wiley, v. 27, n. 1, p. 8–17, 2024. DOI: [10.1111/afe.12630](https://doi.org/10.1111/afe.12630). Citado na p. 24.
- LIMA, B. P. d. M.; BORGES, L. d. A. B.; HIROSE, E.; BORGES, D. L. A lightweight and enhanced model for detecting the Neotropical brown stink bug, *Euschistus heros* (Hemiptera: Pentatomidae) based on YOLOv8 for soybean fields. **Ecological Informatics**, v. 80, p. 102543, 2024. ISSN 1574-9541. DOI: [10.1016/j.ecoinf.2024.102543](https://doi.org/10.1016/j.ecoinf.2024.102543). Citado nas pp. 16, 31.
- LIN, T.-Y.; MAIRE, M.; BELONGIE, S.; BOURDEV, L.; GIRSHICK, R.; HAYS, J.; PERONA, P.; RAMANAN, D.; ZITNICK, C. L.; DOLLÁR, P. Microsoft COCO: Common objects in context. *In*: EUROPEAN CONFERENCE ON COMPUTER VISION. **Proceedings of the European Conference on Computer Vision**. Zurich: Springer, 2014. p. 740–755. DOI: [10.1007/978-3-319-10602-1_48](https://doi.org/10.1007/978-3-319-10602-1_48). Citado nas pp. 10, 31, 43, 45, 49, 58.
- LIU, L.; WANG, R.; XIE, C.; YANG, P.; WANG, F.; SUDIRMAN, S.; LIU, W. PestNet: An End-to-End Deep Learning Approach for Large-Scale Multi-Class Pest Detection and Classification. **IEEE Access**, v. 7, p. 45301–45312, 2019. DOI: [10.1109/ACCESS.2019.2909522](https://doi.org/10.1109/ACCESS.2019.2909522). Citado na p. 32.
- LIU, W.; ANGUELOV, D.; ERHAN, D.; SZEGEDY, C.; REED, S.; FU, C.-Y.; BERG, A. C. SSD: Single Shot MultiBox Detector. *In*: EUROPEAN CONFERENCE ON COMPUTER VISION. **Proceedings of the European Conference on Computer Vision**. Amsterdam: Springer, 2016. p. 21–37. DOI: [10.1007/978-3-319-46448-0_2](https://doi.org/10.1007/978-3-319-46448-0_2). Citado na p. 28.
- MAES, W. H.; STEPPE, K. Perspectives for remote sensing with unmanned aerial vehicles in precision agriculture. **Trends in Plant Science**, Elsevier, v. 24, n. 2, p. 152–164, 2019. ISSN 1360-1385. DOI: [10.1016/j.tplants.2018.11.007](https://doi.org/10.1016/j.tplants.2018.11.007). Citado na p. 11.
- MAHLEIN, A.; KUSKA, M.; THOMAS, S.; BOHNENKAMP, D.; ALISAAC, E.; BEHMANN, J.; WAHABZADA, M.; KERSTING, K. Plant disease detection by hyperspectral ima-

ging: from the lab to the field. **Advances in Animal Biosciences**, v. 8, n. 2, p. 238–243, 2017. ISSN 2040-4700. DOI: [10.1017/S2040470017001248](https://doi.org/10.1017/S2040470017001248). Citado na p. 32.

MOLIN, J. P.; AMARAL, L. R. d.; COLAÇO, A. F. **Agricultura de precisão**. Oficina de Textos, 2011. Disponível em: <https://www.bibliotecaagptea.org.br/agricultura/precisao/livros/AGRICULTURA%20DE%20PRECISAO%20-%20OFICINA%20DE%20TEXTOS.pdf>. Acesso em: 23 set. 2025. Citado nas pp. 10, 20.

NEUPANE, N.; GOSWAMI, R.; HARRISON, K.; OBERHAUSER, K.; RIES, L.; MCCORMICK, C. Artificial intelligence correctly classifies developmental stages of monarch caterpillars enabling better conservation through the use of community science photographs. **Scientific Reports**, v. 14, 2024. DOI: [10.1038/s41598-024-78509-w](https://doi.org/10.1038/s41598-024-78509-w). Citado nas pp. 29, 35, 39, 41, 51.

OERKE, E.-C. Crop losses to pests. **The Journal of Agricultural Science**, Cambridge University Press, v. 144, n. 1, p. 31–43, 2006. DOI: [10.1017/S0021859605005708](https://doi.org/10.1017/S0021859605005708). Citado nas pp. 15, 64.

OJALA, T.; PIETIKAINEN, M.; MAENPAA, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 24, n. 7, p. 971–987, 2002. DOI: [10.1109/TPAMI.2002.1017623](https://doi.org/10.1109/TPAMI.2002.1017623). Citado nas pp. 10, 47.

OLIVEIRA, C. M.; AUAD, A. M.; MENDES, S. M.; FRIZZAS, M. R. Economic impact of exotic insect pests in Brazilian agriculture. **Journal of Applied Entomology**, Wiley Online Library, v. 138, n. 1-2, p. 85–95, 2014. DOI: [10.1111/jen.12018](https://doi.org/10.1111/jen.12018). Citado nas pp. 15, 32.

PECH-PACHECO, V.; ALVAREZ-BORREGO, J.; CRISTOBAL, G.; BERRIEL-VALDOS, L. R. Diatom autofocusing in brightfield microscopy: a comparative study. *In: INTERNATIONAL CONFERENCE ON PATTERN RECOGNITION. Proceedings of the 15th International Conference on Pattern Recognition (ICPR-2000)*. Barcelona: IEEE, 2000. v. 3, p. 314–317. DOI: [10.1109/ICPR.2000.903548](https://doi.org/10.1109/ICPR.2000.903548). Citado nas pp. 33, 39, 41, 46.

PÉREZ-RUIZ, M.; UPADHYAYA, S. K. GNSS in Precision Agricultural Operations. *In: FUNDA, E. (ed.). New Approaches of Indoor and Outdoor Localization Systems*. Rijeka: InTech, 2012. p. 1–26. DOI: [10.5772/50448](https://doi.org/10.5772/50448). Citado nas pp. 10, 11, 19, 21.

PIERCE, F. J.; CLAY, D. **GIS Applications in Agriculture**. CRC Press, 2007. ISBN 978-0849375262. DOI: [10.1016/j.agsty.2008.08.002](https://doi.org/10.1016/j.agsty.2008.08.002). Citado nas pp. 11, 21.

PIERPAOLI, E.; CARLI, G.; PIGNATTI, E.; CANAVARI, M. Drivers of Precision Agriculture Technologies Adoption: A Literature Review. **Procedia Technology**, v. 8, p. 61–69, 2013. DOI: [10.1016/j.protcy.2013.11.010](https://doi.org/10.1016/j.protcy.2013.11.010). Citado na p. 15.

- PIMENTEL, D. Environmental and economic costs of the application of pesticides primarily in the United States. **Environment, Development and Sustainability**, Springer, v. 7, n. 2, p. 229–252, 2005. DOI: [10.1007/s10668-005-7314-2](https://doi.org/10.1007/s10668-005-7314-2). Citado na p. 23.
- POPP, J.; PETŐ, K.; NAGY, J. Pesticide productivity and food security. A review. **Agronomy for Sustainable Development**, Springer, v. 33, n. 1, p. 243–255, 2013. DOI: [10.1007/s13593-012-0105-x](https://doi.org/10.1007/s13593-012-0105-x). Citado na p. 15.
- REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You only look once: Unified, real-time object detection. *In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas: IEEE, 2016. p. 779–788. DOI: [10.1109/CVPR.2016.91](https://doi.org/10.1109/CVPR.2016.91). Citado nas pp. 11, 16, 28, 58.
- REN, S.; HE, K.; GIRSHICK, R.; SUN, J. Faster R-CNN: Towards real-time object detection with region proposal networks. *In: INTERNATIONAL CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS. Advances in Neural Information Processing Systems*. Montreal: Curran Associates, Inc., 2015. v. 28, p. 91–99. DOI: [10.48550/arXiv.1506.01497](https://doi.org/10.48550/arXiv.1506.01497). Citado na p. 28.
- ROBERT, P. C. Precision agriculture: a challenge for crop nutrition management. **Plant and Soil**, Springer, v. 247, n. 1, p. 143–149, 2002. DOI: [10.1023/A:1021171514148](https://doi.org/10.1023/A:1021171514148). Citado na p. 22.
- SENER, O.; SAVARESE, S. Active Learning for Convolutional Neural Networks: A Core-Set Approach. *In: INTERNATIONAL CONFERENCE ON LEARNING REPRESENTATIONS. Proceedings of the International Conference on Learning Representations*. Vancouver: ICLR, 2018. DOI: [10.48550/arXiv.1708.00489](https://doi.org/10.48550/arXiv.1708.00489). Citado na p. 34.
- SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on image data augmentation for deep learning. **Journal of Big Data**, Springer, v. 6, n. 1, p. 1–48, 2019. DOI: [10.1186/s40537-019-0197-0](https://doi.org/10.1186/s40537-019-0197-0). Citado nas pp. 30, 34, 41.
- SNELL, J.; SWERSKY, K.; ZEMEL, R. Prototypical networks for few-shot learning. *In: INTERNATIONAL CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS. Advances in Neural Information Processing Systems*. Long Beach: Curran Associates, Inc., 2017. v. 30, p. 4077–4087. DOI: [10.48550/arXiv.1703.05175](https://doi.org/10.48550/arXiv.1703.05175). Citado nas pp. 16, 39.
- SOUZA, W. S. R.; ALVES, A. N.; BORGES, D. L. A Deep Learning Model for Recognition of Pest Insects in Maize Plantations. *In: IEEE INTERNATIONAL CONFERENCE ON SYSTEMS, MAN AND CYBERNETICS. Proceedings of the IEEE International Conference on Systems, Man and Cybernetics (SMC)*. Bari: IEEE, 2019. p. 2285–2290. DOI: [10.1109/SMC.2019.8914428](https://doi.org/10.1109/SMC.2019.8914428). Citado na p. 16.

- TAN, M.; LE, Q. EfficientNet: Rethinking model scaling for convolutional neural networks. *In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING. **Proceedings of the International Conference on Machine Learning***. Long Beach: PMLR, 2019. p. 6105–6114. DOI: [10.48550/arXiv.1905.11946](https://doi.org/10.48550/arXiv.1905.11946). Citado na p. 27.
- ULTRALYTICS. **YOLOv11**. 2024. <https://github.com/ultralytics/ultralytics>. Acesso em: 10 set. 2025. Citado nas pp. 11, 28, 50, 58.
- ULTRALYTICS. **YOLOv5**. GitHub, 2020. <https://github.com/ultralytics/yolov5>. Acesso em: 10 set. 2025. Citado na p. 28.
- ULTRALYTICS. **YOLOv8**. GitHub, 2023. <https://github.com/ultralytics/ultralytics>. Acesso em: 10 set. 2025. Citado nas pp. 28, 31, 58.
- VINYALS, O.; BLUNDELL, C.; LILLICRAP, T.; WIERSTRA, D. *et al.* Matching networks for One Shot Learning. *In: INTERNATIONAL CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS. **Advances in Neural Information Processing Systems***. Barcelona: Curran Associates, Inc., 2016. v. 29, p. 3630–3638. DOI: [10.48550/arXiv.1606.04080](https://doi.org/10.48550/arXiv.1606.04080). Citado nas pp. 10, 31, 39.
- WANG, X.; HUANG, T. E.; DARRELL, T.; GONZALEZ, J. E.; YU, F. Frustratingly simple few-shot object detection. *In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING. **Proceedings of the International Conference on Machine Learning***. Virtual: PMLR, 2020. p. 9919–9928. DOI: [10.48550/arXiv.2003.06957](https://doi.org/10.48550/arXiv.2003.06957). Citado nas pp. 10, 31.
- WANG, Y.; YAO, Q.; KWOK, J. T.; NI, L. M. Generalizing from a few examples: A survey on few-shot learning. **ACM Computing Surveys (CSUR)**, v. 53, n. 3, p. 1–34, 2020. DOI: [10.1145/3386252](https://doi.org/10.1145/3386252). Citado nas pp. 10, 16, 29, 30, 32, 39, 58.
- WITZGALL, P.; KIRSCH, P.; CORK, A. Sex pheromones and their impact on pest management. **Journal of Chemical Ecology**, v. 36, n. 1, p. 80–100, 2010. DOI: [10.1007/s10886-009-9737-y](https://doi.org/10.1007/s10886-009-9737-y). Citado na p. 24.
- WOLFERT, S.; GE, L.; VERDOUW, C.; BOGAARDT, M.-J. Big Data in Smart Farming – A review. **Agricultural Systems**, v. 153, p. 69–80, 2017. ISSN 0308-521X. DOI: [10.1016/j.agsy.2017.01.023](https://doi.org/10.1016/j.agsy.2017.01.023). Citado nas pp. 20, 21.
- WU, J.; LIU, S.; HUANG, D.; WANG, Y. Multi-scale positive sample refinement for few-shot object detection. **European Conference on Computer Vision**, Springer, p. 456–472, 2020. DOI: [10.48550/arXiv.2007.09384](https://doi.org/10.48550/arXiv.2007.09384). Citado na p. 16.
- WU, X.; ZHAN, C.; LAI, Y.-S.; CHENG, M.-M.; YANG, J. IP102: A Large-Scale Benchmark Dataset for Insect Pest Recognition. *In: IEEE/CVF CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION. **Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)***. Long Beach:

IEEE, 2019. p. 8787–8796. DOI: [10.1109/CVPR.2019.00899](https://doi.org/10.1109/CVPR.2019.00899). Citado nas pp. 15, 25, 31, 35, 36, 50.

YOSINSKI, J.; CLUNE, J.; BENGIO, Y.; LIPSON, H. How transferable are features in deep neural networks? **Advances in Neural Information Processing Systems**, v. 27, 2014. DOI: [10.48550/arXiv.1411.1792](https://doi.org/10.48550/arXiv.1411.1792). Citado nas pp. 31, 59.

ZHANG, Q.; REID, J. F.; NOGUCHI, N. **Agricultural vehicle navigation using multiple guidance sensors**. 1999. Disponível em: https://www.researchgate.net/publication/245235458_Agricultural_Vehicle_Navigation_Using_Multiple_Guidance_Sensors. Acesso em: 20 out. 2025. Citado na p. 10.

ZHAO, Z.-Q.; ZHENG, P.; XU, S.-t.; WU, X. Object detection with deep learning: A review. **IEEE Transactions on Neural Networks and Learning Systems**, IEEE, v. 30, n. 11, p. 3212–3232, 2019. DOI: [10.48550/arXiv.1807.05511](https://doi.org/10.48550/arXiv.1807.05511). Citado nas pp. 10, 27, 49.

ZHENG, Z.; WANG, P.; LIU, W.; LI, J.; YE, R.; REN, D. Distance-IoU loss: Faster and better learning for bounding box regression. *In: AAAI CONFERENCE ON ARTIFICIAL INTELLIGENCE, 07. Proceedings of the AAI Conference on Artificial Intelligence*. New York: AAI Press, 2020. v. 34, p. 12993–13000. DOI: [10.1609/aaai.v34i07.6999](https://doi.org/10.1609/aaai.v34i07.6999). Citado nas pp. 10, 11, 29.

ZOU, Z.; SHI, Z.; GUO, Y.; YE, J. Object detection in 20 years: A survey. **Proceedings of the IEEE**, IEEE, v. 111, n. 3, p. 254–301, 2023. DOI: [/10.48550/arXiv.1905.05055](https://doi.org/10.48550/arXiv.1905.05055). Citado nas pp. 10, 28, 31, 49.