

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA
GOIANO - CAMPUS RIO VERDE, PROGRAMA DE PÓS-
GRADUAÇÃO EM CIÊNCIAS AGRÁRIAS – AGRONOMIA

**SISTEMAS INTELIGENTES EMBARCADOS EM
DISPOSITIVOS MOVEIS E BASEADOS EM *DEEP*
LEARNING PARA DETECÇÃO E MONITORAMENTO
ESPACIAL DE PRAGAS AGRÍCOLAS**

Autor: Me. Guilherme Pires Silva de Almeida
Orientador: Prof. Dr. Leonardo Nazário Silva dos Santos

RIO VERDE – GO

Novembro - 2025

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA
GOIANO - CAMPUS RIO VERDE, PROGRAMA DE PÓS-
GRADUAÇÃO EM CIÊNCIAS AGRÁRIAS – AGRONOMIA

**SISTEMAS INTELIGENTES EMBARCADOS EM
DISPOSITIVOS MOVEIS E BASEADOS EM *DEEP*
LEARNING PARA DETECÇÃO E MONITORAMENTO
ESPACIAL DE PRAGAS AGRÍCOLAS**

Autor: Me. Guilherme Pires Silva de Almeida
Orientador: Prof. Dr. Leonardo Nazário Silva dos Santos
Coorientador: Prof. Dr. Ruy de Oliveira

Tese apresentada, como parte das exigências para obtenção do título de DOUTOR EM CIÊNCIAS AGRÁRIAS - AGRONOMIA, no Programa de Pós-Graduação em Ciências Agrárias – Agronomia, do Instituto Federal de Educação, Ciência e Tecnologia Goiano – Campus Rio Verde.

RIO VERDE – GO

Novembro - 2025

**Ficha de identificação da obra elaborada pelo autor, através do
Programa de Geração Automática do Sistema Integrado de Bibliotecas do IF Goiano - SIBi**

A447 Almeida, Guilherme Pires Silva de
SISTEMAS INTELIGENTES EMBARCADOS EM
DISPOSITIVOS MOVEIS E BASEADOS EM DEEP
LEARNING PARA DETECÇÃO E MONITORAMENTO
ESPACIAL DE PRAGAS AGRÍCOLAS / Guilherme Pires Silva
de Almeida. Rio Verde 2025.

106f. il.

Orientador: Prof. Dr. Leonardo Nazário Silva dos Santos.
Coorientador: Prof. Dr. Ruy de Oliveira.
Tese (Doutor) - Instituto Federal Goiano, curso de 0232014 -
Doutorado em Ciências Agrárias - Agronomia - Rio Verde
(Campus Rio Verde).
1. Computer vision. 2. Deep learning. 3. YOLO. 4. Insect
detection. 5. Precision agriculture. I. Título.

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR PRODUÇÕES TÉCNICO-CIENTÍFICAS NO REPOSITÓRIO INSTITUCIONAL DO IF GOIANO

Com base no disposto na Lei Federal nº 9.610, de 19 de fevereiro de 1998, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia Goiano a disponibilizar gratuitamente o documento em formato digital no Repositório Institucional do IF Goiano (RIIF Goiano), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IF Goiano.

IDENTIFICAÇÃO DA PRODUÇÃO TÉCNICO-CIENTÍFICA

- | | |
|--|---|
| ☒ Tese (doutorado) | ☐ Artigo científico |
| ☐ Dissertação (mestrado) | ☐ Capítulo de livro |
| ☐ Monografia (especialização) | ☐ Livro |
| ☐ TCC (graduação) | ☐ Trabalho apresentado em evento |

☐ Produto técnico e educacional - Tipo:

Nome completo do autor:

Guilherme Pires Silva de Almeida

Matrícula:

2021102320140183

Título do trabalho:

SISTEMAS INTELIGENTES EMBARCADOS EM DISPOSITIVOS MOVEIS E BASEADOS EM DEEP LEARNING PARA DETECÇÃO E MONITORAMENTO ESPACIAL DE PRAGAS AGRÍCOLAS

RESTRIÇÕES DE ACESSO AO DOCUMENTO

Documento confidencial: ☒ Não ☐ Sim, justifique:

Informe a data que poderá ser disponibilizado no RIIF Goiano: 29 / 01 / 2026

O documento está sujeito a registro de patente? ☐ Sim ☒ Não

O documento pode vir a ser publicado como livro? ☒ Sim ☐ Não

DECLARAÇÃO DE DISTRIBUIÇÃO NÃO-EXCLUSIVA

O(a) referido(a) autor(a) declara:

- Que o documento é seu trabalho original, detém os direitos autorais da produção técnico-científica e não infringe os direitos de qualquer outra pessoa ou entidade;
- Que obteve autorização de quaisquer materiais incluídos no documento do qual não detém os direitos de autoria, para conceder ao Instituto Federal de Educação, Ciência e Tecnologia Goiano os direitos requeridos e que este material cujos direitos autorais são de terceiros, estão claramente identificados e reconhecidos no texto ou conteúdo do documento entregue;
- Que cumpriu quaisquer obrigações exigidas por contrato ou acordo, caso o documento entregue seja baseado em trabalho financiado ou apoiado por outra instituição que não o Instituto Federal de Educação, Ciência e Tecnologia Goiano.

Documento assinado digitalmente
gov.br
GUILHERME PIRES SILVA DE ALMEIDA
Data: 27/01/2026 22:25:02-0300
Verifique em <https://validar.ifg.gov.br>

Rio Verde - GO 28 / 01 / 2026
Local Data

Assinatura do autor e/ou detentor dos direitos autorais

Ciente e de acordo:

Assinatura do(a) orientador(a)

Documento assinado digitalmente
gov.br
LEONARDO NAZARIO SILVA DOS SANTOS
Data: 28/01/2026 15:03:18-0300
Verifique em <https://validar.ifg.gov.br>



SERVIÇO PÚBLICO FEDERAL
MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA GOIANO

Documentos 79/2025 - SREPG/CMPR/CPG-RV/DPGPI-RV/CMPRV/IFGOIANO

**SISTEMAS INTELIGENTES EMBARCADOS EM DISPOSITIVOS MÓVEIS E BASEADOS EM
DEEP LEARNING PARA DETECÇÃO E MONITORAMENTO ESPACIAL DE PRAGAS
AGRÍCOLAS**

Autor: Guilherme Pires Silva de Almeida

Orientador: Dr. Leonardo Nazário Silva dos Santos

TITULAÇÃO: Doutorado em Ciências Agrárias - Agronomia, Área de Concentração
em Produção Vegetal Sustentável no Cerrado

APROVADA em 28 de novembro de 2025.

Prof. Dr. Leonardo Nazário Silva dos Santos (Presidente)

Prof. Dr. Marconi Batista Teixeira (Avaliador interno)

Prof. Dr. Ruy de Oliveira (Avaliador externo)

Prof. Dr. Mario Anderson de Oliveira (Avaliador externo)

Prof. Dr. Wilker Alves Moraes (Avaliador interno)

Prof. Dr. Nelcilenio Virgilio De Souza Araujo (Avaliador externo)

Documento assinado eletronicamente por:

- **Marconi Batista Teixeira, COORDENADOR(A) DE CURSO - FUC0001 - CCMDAGRO-R**, em 01/12/2025 15:30:54.
- **Leonardo Nazário Silva dos Santos, Leonardo Nazário Silva dos Santos - Professor Avaliador de Banca - 10. 508. 381/0001-78 (1)**, em 01/12/2025 15:32:36.
- **Wilker Alves Moraes, PROFESSOR ENS BASICO TECN TECNOLOGICO**, em 01/12/2025 16:44:46.
- **Nelcileno Virgilio De Souza Araujo, 632.233.091-87 - Usuário Externo**, em 01/12/2025 20:39:20.
- **Ruy de Oliveira, 328.158.671-68 - Usuário Externo**, em 03/12/2025 16:58:53.
- **Mario Anderson de Oliveira, Mario Anderson de Oliveira - Professor Avaliador de Banca - Instituto Federal Goiano - Campus Rio Verde (10651417000500)**, em 04/12/2025 06:33:15.

Este documento foi emitido pelo SUAP em 26/11/2025. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifgoiano.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código Verificador: 766578

Código de Autenticação: 837b956007



INSTITUTO FEDERAL GOIANO

Campus Rio Verde

Rodovia Sul Goiana, Km 01, Zona Rural, 01, Zona Rural, RIO VERDE / GO, CEP 75901-970
(64) 3624-1000

AGRADECIMENTOS

A Deus, expresso minha profunda gratidão pela direção, proteção e força concedidas ao longo desta jornada acadêmica. Sua presença renovou minha confiança e sustentou-me nos momentos de maior desafio.

À minha esposa, Livia Almeida, agradeço pelo apoio incondicional, pela compreensão constante e pela paciência diante das inúmeras horas dedicadas ao estudo. Estendo meu carinho aos meus filhos, Pedro Henrique e Maria Júlia, cujo amor e compreensão tornaram mais leves os períodos de ausência. Esta conquista é também de vocês.

Agradeço ao meu orientador, professor Leonardo Nazário Silva dos Santos, pela orientação competente, pela confiança e pela disponibilidade sempre presente. Registro, igualmente, minha gratidão ao professor Marconi Batista Teixeira, Coordenador da Pós-Graduação do IF Goiano – Campus Rio Verde, pelo suporte institucional e incentivo contínuo.

Aos amigos Ruy de Oliveira e Mário Anderson de Oliveira, agradeço pelas contribuições acadêmicas, pelas conversas produtivas e pela parceria ao longo do desenvolvimento desta tese. Aos colegas Jéssica Lauanda Stirle e Sergio Souza Novak, agradeço pela colaboração direta, pelas trocas de conhecimento e pelo apoio técnico indispensável.

Agradeço, ainda, às instituições e órgãos de fomento que possibilitaram a realização desta pesquisa: Ministério da Ciência, Tecnologia e Inovação (MCTI); Financiadora de Estudos e Projetos (FINEP); Fundação de Amparo à Pesquisa do Estado de Goiás (FAPEG); Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq); Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES); Centro de Excelência em Agricultura Exponencial (CEAGRE); Instituto Federal Goiano (IF Goiano) — Campus Rio Verde; e Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso (IFMT).

Concluo, os agradecimentos, reconhecendo o apoio de tantos outros, que mesmo não mencionados individualmente contribuíram para esta conquista. A todos, deixo meu muito obrigado.

BIOGRAFIA DO AUTOR

GUILHERME PIRES SILVA DE ALMEIDA é professor e pesquisador na área de Computação, com atuação destacada em redes de computadores, segurança da informação e inteligência artificial.

Ingressou no Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso (IFMT) em 15 de julho de 2008, instituição na qual desenvolve atividades de ensino, pesquisa e extensão há mais de quinze anos. Graduiu-se em Sistemas de Informação pelo Centro Universitário de Várzea Grande (UNIVAG) em 2004.

Posteriormente, concluiu duas especializações: Redes de Computadores pelo CEFET-MT (atual IFMT) em 2007 e Criptografia e Segurança em Redes pela Universidade Federal Fluminense (UFF) em 2008.

Também cursou pós-graduação em Redes e Computação Distribuída. Obteve o título de Mestre em Engenharia Elétrica pela Universidade de Brasília (UnB) em 2012, com pesquisa voltada à estimativa de preços de energia elétrica utilizando redes neurais artificiais, área na qual atuou como bolsista CAPES.

Com experiência consolidada no IFMT e formação multidisciplinar, Guilherme desenvolve projetos nas áreas de tecnologias aplicadas, modelagem computacional, aprendizado de máquina e sistemas distribuídos, contribuindo para o avanço científico e tecnológico no âmbito institucional e regional.

Ingressou em 2021 no Doutorado pelo Programa de Pós-graduação em Ciências Agrárias - Agronomia do Instituto Federal Goiano - Campus Rio Verde, finalizando em junho de 2025.

ÍNDICE GERAL

ÍNDICE DE TABELAS	x
ÍNDICE DE FIGURAS.....	xi
LISTA DE SÍMBOLOS, SIGLAS E ABREVIACÕES	xiv
RESUMO GERAL.....	xvi
ABSTRACT.....	xvii
INTRODUÇÃO GERAL	18
OBJETIVOS	20
3 CAPÍTULO I. Performance Analysis of YOLO and Detectron2 Models for Detecting Corn and Soybean Pests Employing Customized Dataset	
Abstract	22
3.1. Introduction	22
3.2. Materials and Methods	26
3.2.1. <i>Dataset Acquisition</i>	26
3.2.2. Compilation of the AgroInsect Dataset	26
3.2.3 <i>Training Methods</i>	28
3.2.4. <i>Conversion Methods to ONNX and TFLite</i>	29
3.2.5 <i>Models' Parameters and Evaluation Metrics</i>	29
3.3 Results	31
3.3.1. <i>Evaluation of the Detectron2 Model in Insect Detection</i>	31
3.3.2. <i>Evaluation of the YOLO Model for Insect Detection</i>	34
3.4. Discussion	43
3.5. Conclusions	47
Acknowledgements	48
References	49
4 CAPÍTULO II. AGROINSECT: A Curated Image Dataset for Deep Learning-Based Detection and Identification of Agricultural Insect Pests	
Abstract	62
4.1. Data Value	63
4.2. Data Description	65
4.3. Experimental Design, Material, and Methods	66
4.4. Limitations	67
Acknowledgements	69
References	69
5 CAPÍTULO III. Monitoramento de Pragas Agrícolas via Smartphone com IA Embarcada e Mapeamento Geoestatístico.....	
Resumo	71
5.1. Introdução	71
5.2. Materiais e Métodos	75
5.2.2. Dataset	78
5.2.3. Modelo Yolo	79
5.2.4. Interpolação Espacial com Krigagem	81
5.3 Resultados	82
5.3.1. <i>Principais funcionalidades do AgroInsect</i>	82
5.3.2. Validação do Modelo de Krigagem em um Cenário Simulado	85
5.3.3. Avaliação das detecções automáticas realizadas em campo	89
5.3.4. Análise Espacial das Ocorrências de Pragas	91
5.3.5. Resultados do Painel Espacial Integrado do Sistema AgroInsect	92
5.4. Discussão	93

5. 5. Conclusão e trabalhos futuros	97
Agradecimentos	98
Referencias	98
Conclusão Geral	105

ÍNDICE DE TABELAS

CAPÍTULO 1. PERFORMANCE ANALYSIS OF YOLO AND DETECTRON2 MODELS FOR DETECTING CORN AND SOYBEAN PESTS EMPLOYING CUSTOMIZED DATASET

Table 1.	Division of datasets for each insect class and their annotations for training and evaluation of deep-learning models.....	27
Table 2.	Some important hyperparameters for configuring the Detectron2 and YOLO models.....	29
Table 3.	Metrics per class after inference of test images using the Reduced and AgroInsect datasets with the Detectron2 model.....	32
Table 4.	Different versions of YOLO and the size of each model after training with specific datasets.....	35
Table 5.	Comparison of model performance metrics based on different training datasets and YOLO versions.....	35
Table 6.	Comparison of performance parameters for models converted to ONNX and TFLite.....	42
Table 7.	Comparison of results obtained with the models proposed in this work and those available in the literature, including the number of classes, dataset and metrics.....	44

CAPÍTULO II. AGROINSECT: A CURATED DATASET TO IDENTIFY AGRICULTURAL INSECTS OF INTEREST IN CORN AND SOY.

Table 1.	Division of datasets for each insect class and their annotations for training and evaluation of deep-learning models	66
-----------------	--	----

CAPÍTULO III. MONITORAMENTO DE PRAGAS AGRÍCOLAS VIA SMARTPHONE COM IA EMBARCADA E MAPEAMENTO GEOESTATÍSTICO

Tabela 1.	Métricas de validação da interpolação por krigagem para a abundância simulada de insetos em diferentes resoluções de grade.....	86
Tabela 2.	Resumo das detecções e ajustes de classes.....	89
Tabela 3.	Desempenho do modelo de classificação para as espécies avaliadas....	91

ÍNDICE DE FIGURAS

CAPÍTULO I. PERFORMANCE ANALYSIS OF YOLO AND DETECTRON2 MODELS FOR DETECTING CORN AND SOYBEAN PESTS EMPLOYING CUSTOMIZED DATASET

Figure 1.	Insects selected for the dataset. (a) <i>Diabrotica speciosa</i> ; (b) <i>Dalbulus maidis</i> ; (c) <i>Diceraeus ssp.</i> ; (d) <i>Spodoptera frugiperda</i>	26
Figure 2.	Examples of confusion matrices. (a) Confusion matrix for binary classification problem. (b) Confusion matrix for multiclass classification problem	31
Figure 3.	Evolution of the loss function of Detectron2 over iterations with training executed on the Reduced dataset (a) and on the AgroInsect dataset (b)	32
Figure 4.	Prediction with Detectron2 and custom dataset. (a) contains the resulting images from the model trained with the Reduced dataset, and in (b) , the images are from the AgroInsect dataset	33
Figure 5.	Confusion matrix of the Detectron2 model trained with the Reduced dataset (a) and the AgroInsect dataset (b)	34
Figure 6.	Loss curves for YOLO models trained on two different datasets (Reduced dataset and AgroInsect dataset, respectively), where (a-1,b-1) represent the total loss, and (a-2,b-2) represent the class loss.	37
Figure 7.	Precision curve of YOLO model training: (a) Reduced dataset; (b) AgroInsect dataset	38
Figure 8.	Metric curve of YOLOv5s trained with the Reduced dataset.....	39
Figure 9.	Training metrics curve of YOLOv9-gelan: AgroInsect dataset with the best result among model/dataset combinations.....	39
Figure 10.	Confusion matrix of YOLO models with Reduced dataset.....	40
Figure 11.	Confusion matrix of YOLO models with AgroInsect dataset.....	41
Figure 12.	Insect detection with YOLOv9-gelan: (a) <i>Diabrotica speciosa</i> ; (b) <i>Dalbulus maidis</i> ; (c) <i>Diceraeus ssp.</i> ; (d) <i>Spodoptera frugiperda</i>	41
Figure 13.	Confusion matrix of YOLO models: (a) Detection result for YOLOv5s-TFLite with Reduced dataset; (b) Detection result for YOLOv9-gelan-ONNX with AgroInsect dataset.....	43

Figure 14. Inferences with ONNX and TFLite: (a) YOLOv5s–TFLite result; (b) YOLOv9-gelan–ONNX result.....	42
---	----

CAPÍTULO II. AGROINSECT: A CURATED DATASET TO IDENTIFY AGRICULTURAL INSECTS OF INTEREST IN CORN AND SOY.

Figure 1. Selected insects for the dataset. (a) <i>Diabrotica speciosa</i> . (b) <i>Dalbulus maidis</i> . (c) <i>Diceraeus</i> spp. (d) <i>Spodoptera frugiperda</i>	65
--	----

CAPÍTULO III. MONITORAMENTO DE PRAGAS AGRÍCOLAS VIA SMARTPHONE COM IA EMBARCADA E MAPEAMENTO GEOESTATÍSTICO

Figura 1. Os módulos fundamentais para detecção eficiente do modelo YOLOv11: SPPF, C2PSA e C3K2.....	76
Figura 2. Fluxograma do fluxo operacional do aplicativo AgroInsect, ilustrando as etapas de autenticação do usuário, seleção da área de interesse, definição do modo de operação, aquisição de imagens, detecção automática de insetos, anotação manual e armazenamento	77
Figura 3. Exemplos de quatro objetos marcados utilizando Caixas Delimitadoras.....	79
Figura 4. Módulos fundamentais para detecção eficiente do modelo YOLOv11, SPPF, C2PSA e C3K2.....	80
Figura 5. Interface do aplicativo AgroInsect, com detecção de objeto, mapa de calor e mapa de krigagem	83
Figura 6. Estrutura do banco de dados relacional (MySQL) do sistema AgroInsect.	84
Figura 7. Distribuição espacial dos resíduos de krigagem para as quatro espécies de insetos simuladas sob duas densidades de amostragem (grades de 20×20 e 200×200)	88
Figura 8. Matriz de confusão do modelo AgroInsect avaliado com imagens coletadas em campo.....	90
Figura 9. Painel de resultados gerados pelo sistema: (a) total de insetos detectados; (b) distribuição espacial das detecções; (c) interpolação espacial por krigagem.....	92

Figura 10. Mapas de incidência por krigagem: (a) distribuição agregada de todas as espécies; (b) *Diabrotica*; (c) *Dalbulus*; (d) *Diceraeus*; (e) Frugiperda..... 93

LISTA DE SÍMBOLOS, SIGLAS, ABREVIACÕES E UNIDADES

Símbolo / Sigla	Significado
°	graus (ângulo)
°C	graus Celsius
A	Accuracy - Acurácia
AI	Artificial Intelligence – Inteligência Artificial
AP	Average Precision
API	Application Programming Interface - Interface de programação de aplicativos
BCE	Binary Cross Entropy - Entropia Cruzada Binária
BIAS	Mean Bias Error
Bounding Box	Caixa delimitadora
CAM	Class Activation Map
CBAM	Convolutional Block Attention Module
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CEAGRE	Centro de Excelência em Agricultura Exponencial
CNN	Convolutional Neural Network - Rede Neural Convolucional
CNPq	Conselho Nacional de Desenvolvimento Científico e Tecnológico
COCO	Common Objects in Context
CRedit	Contributor Roles Taxonomy
CV	Computer Vision
Dataset	Conjunto de dados
DFL	Distillation-Augmented Feature Loss
DL	Deep Learning - Aprendizado profundo
DSC	Dice Similarity Coefficient
Edge Computing	Processamento em dispositivos de borda
EXIF	Exchangeable Image File Format
F1	F1-Score
FAPEG	Fundação de Amparo à Pesquisa do Estado de Goiás
FN	False Negative – Falso Negativo
FAO	Food and Agriculture Organization of the United Nations
FAPEG	Fundação de Amparo à Pesquisa do Estado de Goiás
FINEP	Financiadora de Estudos e Projetos
FP	False Positive – Falso Positivo
GBIF	Global Biodiversity Information Facility
GDP	Gross Domestic Product
GNSS	Global Navigation Satellite System - Sistema Global de Navegação por Satélite
GPS	Global Positioning System - Sistema de Posicionamento Global
GPU	Graphics Processing Unit - Unidade de Processamento Gráfico
Grad-CAM	Gradient-weighted Class Activation Mapping
h	Distância entre pontos
Heatmap	Mapa de calor
IDW	Inverse Distance Weighting
IF Goiano	Instituto Federal Goiano
IFMT	Instituto Federal de Mato Grosso
Inferência	Predição do modelo
IoT	Internet of Things
IoU	Intersection over Union
JSON	JavaScript Object Notation - Notação de objeto JavaScript
JWT	JSON Web Token

L2	L2 Regularization
km	quilômetro
km ²	quilômetro quadrado
Krigagem Ordinária	Método de interpolação geoestatística
m	metro
m ²	metro quadrado
mAP	Mean Average Precision - Média Precisão Média
MAE	Mean Absolute Error
MCTI	Ministério da Ciência, Tecnologia e Inovação
ML	Machine Learning
MPI	Monitoring Pest Interface
MRCNN	Mask Region-Based Convolutional Neural Network
MVVM	Model–View–ViewModel
ms	milissegundos
ONNX	Open Neural Network Exchange - Troca de Redes Neurais Abertas
P	Precision - Precisão
Pipeline	Fluxo de processamento
R	Recall - Revocação/Sensibilidade
R ²	Coeficiente de determinação
RAM	Random Access Memory
ReLU	Rectified Linear Unit - Unidade Linear Retificada
RGB	Red, Green, Blue
RMSE	Root Mean Square Error
ROI	Region of Interest - Região de interesse
s	segundos
SGD	Stochastic Gradient Descent - Descida de Gradiente Estocástica
SPD-Conv	Strip Pooling Dilated Convolution
SPPF	Spatial Pyramid Pooling – Fast
SQL	Structured Query Language - Linguagem de Consulta Estruturada
TF	TensorFlow
TFLite	TensorFlow Lite
TL	Transfer Learning
TN	True Negative – Verdadeiro Negativo
TP	True Positive – Verdadeiro Positivo
TPU	Tensor Processing Unit - Unidade de Processamento de Tensores
UAV	Unmanned Aerial Vehicle
w, h	Largura e altura da bounding box (YOLO)
x, y	Coordenadas do centro da bounding box (YOLO)
YAML	Yet Another Markup Language
$\gamma(h)$	Semivariância para distância h
λ_i	Pesos da krigagem
ρ	Correlação espacial
σ^2	Variância

RESUMO GERAL

ALMEIDA, G. P. S. de. **Sistemas inteligentes embarcados em dispositivos moveis e baseados em *deep learning* para detecção e monitoramento espacial de pragas agrícolas**. 2025. 114p. Tese (Doutorado em Ciências Agrárias – Agronomia). Instituto Federal Goiano – Campus Rio Verde – GO, Brasil.

A detecção precisa e o monitoramento oportuno de pragas agrícolas são desafios centrais para a agricultura moderna, especialmente em sistemas produtivos de soja e milho em larga escala. Práticas ineficientes de monitoramento frequentemente levam à aplicação tardia de medidas de controle e à consequente redução da produtividade. Os recentes avanços em *deep learning* e computação móvel criaram possibilidades para a identificação automática de insetos em campo por meio de modelos leves de visão computacional. Nesse contexto, esta tese apresenta um *framework* integrado para detecção inteligente e monitoramento espacial de pragas agrícolas, baseado em *deep learning*, métodos geoestatísticos e aplicações móveis. Inicialmente, foram construídos e avaliados dois conjuntos de dados: um *dataset* robusto de imagens de alta resolução, curado por meio de validação dupla por especialistas, e um *dataset* reduzido para fins comparativos. Arquiteturas de detecção de última geração (YOLO e Detectron2) foram treinadas em ambos os *datasets* e posteriormente convertidas para os formatos *TensorFlow Lite* (TFLite) e ONNX, possibilitando a execução em dispositivos com recursos computacionais limitados. Mesmo no cenário menos favorável e utilizando o *dataset* reduzido e o modelo ONNX mais leve — os resultados foram satisfatórios, com precisão de 87,3% e acurácia de 95,0%. Com base nestes resultados, foi desenvolvido o aplicativo móvel AgroInsect, capaz de realizar detecção em tempo real, diretamente no dispositivo, de quatro espécies-chave de pragas relevantes para a agricultura brasileira (*Diabrotica speciosa*, *Dalbulus maidis*, *Diceraeus spp.* e *Spodoptera frugiperda*). O sistema extrai automaticamente a geolocalização das imagens, valida a consistência espacial das detecções a partir dos limites da propriedade e sincroniza os dados com base em nuvem. A visualização espacial é realizada por meio de mapas de calor e interpolações via Krigagem Ordinária (PyKrig), permitindo mapear a incidência das pragas com alta resolução. Ensaio de campo confirmaram o alto desempenho do sistema, com acurácia global de 95,1%, F1-scores superiores a 0,94 para todas as espécies e apenas 1,1% de falsos positivos. O modelo geoestatístico apresentou elevado poder preditivo ($R^2 > 0,94$) sob amostragem densa, reproduzindo padrões espaciais consistentes com o comportamento ecológico das pragas. Além disso, esta tese apresenta o AgroLabIA, um ambiente digital criado para armazenamento, anotação e disponibilização de *datasets* agrícolas. A plataforma oferece imagens validadas, permite exportação em múltiplos formatos e está preparada para receber novas classes de insetos e plantas daninhas, contribuindo para o avanço da pesquisa em visão computacional aplicada ao manejo de pragas. O ecossistema integrado composto pela geração de *datasets*, detecção móvel, validação espacial e mapeamento geoestatístico demonstra solução escalável e operacionalmente robusta para o monitoramento de pragas em sistemas agrícolas. Os resultados evidenciam o AgroInsect como uma ferramenta prática e eficaz para apoiar a tomada de decisão no manejo integrado de pragas, especialmente em regiões com baixa conectividade, fortalecendo os pilares da Agricultura 4.0.

Palavras-chave: Visão computacional; *Deep learning*; YOLO; Detecção de insetos; Monitoramento de pragas; Agricultura de precisão; Krigagem ordinária; Geoestatística; Aplicativos móveis; TFLite; Agricultura 4.0.

ABSTRACT

REZENDA, A. G. **Soil physical quality in the diagnosis of compaction and in the assessment of regenerative agriculture**. 2025. 114p. Thesis (Doctorate in Agricultural Sciences – Agronomy. Instituto Federal Goiano – Campus Rio Verde – GO, Brazil.

Accurate and timely detection of insect pests remains one of the major challenges in modern agriculture, especially in large-scale soybean and maize production systems. Inefficient monitoring practices often result in delayed control interventions and significant yield losses. Recent advancements in deep learning and mobile computing have opened new opportunities for in-field pest identification using lightweight computer vision models. In this context, this thesis presents an integrated framework for intelligent pest detection and spatial monitoring based on deep learning, geostatistical analysis, and mobile applications. First, two datasets of insect pests were constructed and evaluated: a comprehensive high-resolution dataset curated through double-expert validation, and a smaller sample designed for comparative analysis. State-of-the-art detection architectures (YOLO and Detectron2) were trained on both datasets and subsequently converted into TensorFlow Lite (TFLite) and ONNX formats to enable deployment on resource-constrained devices. Even under the least favorable conditions using the reduced dataset and the lightest ONNX model the results reached a precision of 87.3% and accuracy 95.0%, demonstrating the robustness of the pipeline. Building upon these results, a mobile system named **AgroInsect** was developed. The application performs real-time, on-device detection of four key pest species relevant to Brazilian soybean and maize production (*Diabrotica speciosa*, *Dalbulus maidis*, *Diceraeus spp.*, and *Spodoptera frugiperda*), automatically extracts geolocation metadata, validates spatial consistency based on field boundaries, and synchronizes detections with a cloud database. Spatial visualization is generated through heatmaps and Ordinary Kriging (PyKriging), enabling high-resolution incidence maps. Field evaluations confirmed strong model performance, with overall accuracy of 95.1%, F1-scores above 0.94 for all species, and only 1.1% false detections. The kriging model achieved $R^2 > 0.94$ under dense sampling, accurately reproducing ecological spatial patterns. Additionally, this thesis introduces AgroLabIA, a digital platform designed for the storage, annotation, and dissemination of agricultural pest datasets. It provides curated, multi-format datasets suitable for training machine learning models and supports the continuous expansion of new insect and weed classes. The integrated environment that encompasses dataset generation, mobile detection, spatial verification, and geostatistical mapping demonstrate a scalable and operationally robust solution for precision pest monitoring. The results position the AgroInsect database as an effective tool for accelerating decision-making in integrated pest management, particularly in regions with limited connectivity, thus contributing to the consolidation of Agriculture 4.0.

Keywords: Computer vision; Deep learning; YOLO; Insect detection; Pest monitoring; Precision agriculture; Ordinary Kriging; Geostatistics; Mobile applications; TFLite; Agriculture 4.0.

INTRODUÇÃO GERAL

A presente tese está estruturada no formato de artigos científicos, organizados de maneira sequencial, complementar e interdependente, com o objetivo de propor, avaliar e validar um sistema inteligente integrado para a detecção e o monitoramento espacial de pragas agrícolas em lavouras de soja e milho. O trabalho articula três eixos centrais: (i) o desenvolvimento e a avaliação de modelos de visão computacional baseados em *deep learning*; (ii) a construção e disponibilização de um *dataset* agrícola curado e validado por especialistas; e (iii) a implementação de uma aplicação móvel embarcada, capaz de realizar detecção em tempo real e apoiar análises espaciais das ocorrências.

O Capítulo I, intitulado “Performance Analysis of YOLO and Detectron2 Models for Detecting Corn and Soybean Pests Employing Customized Dataset”, apresenta uma análise comparativa do desempenho de diferentes arquiteturas de detecção de objetos amplamente consolidadas na literatura, com destaque para os modelos YOLO (v5, v7, v8 e v9) e o framework Detectron2. São avaliados dois cenários de treinamento distintos — um *dataset* completo e um *dataset* reduzido — permitindo investigar de forma sistemática o impacto do tamanho da base de dados na acurácia, precisão, recall e capacidade de generalização dos modelos. Adicionalmente, os modelos com melhor desempenho são convertidos para os formatos ONNX e *TensorFlow Lite* (TFLite), possibilitando a análise do impacto dessas conversões na eficiência das inferências quando executadas em dispositivos com recursos computacionais limitados. Os resultados evidenciam que, mesmo em condições menos favoráveis, os modelos mantêm desempenho robusto, reforçando a viabilidade para aplicações embarcadas.

O Capítulo II, intitulado “AgroInsect: A Curated Dataset for the Identification of Agricultural Insects of Interest in Corn and Soy”, dedica-se à apresentação do *dataset* AgroInsect, desenvolvido especificamente para atender às demandas de aplicações de visão computacional no contexto da agricultura brasileira. O capítulo descreve detalhadamente o processo de aquisição das imagens, a curadoria realizada com validação dupla por especialistas em entomologia, a padronização das classes e a organização das anotações em formatos compatíveis com diferentes *frameworks* de *deep learning*. O *dataset* contempla quatro espécies de insetos-praga de elevada relevância econômica — *Diabrotica speciosa*, *Dalbulus maidis*, *Diceraeus spp.* e *Spodoptera frugiperda* — e é disponibilizado como um recurso aberto, com potencial de reutilização, reprodutibilidade científica e expansão futura. A principal contribuição deste capítulo reside na mitigação

da lacuna existente na literatura quanto à disponibilidade de bases de dados agrícolas robustas, representativas e devidamente anotadas.

O Capítulo III, intitulado “Monitoramento de Pragas Agrícolas via Smartphone com IA Embarcada e Mapeamento Geoestatístico”, integra os resultados metodológicos e experimentais apresentados nos capítulos anteriores em uma solução aplicada e operacional. Neste capítulo é descrito o desenvolvimento do aplicativo móvel AgroInsect, capaz de realizar a detecção automática de insetos diretamente no smartphone, sem dependência contínua de conectividade com a internet. O sistema contempla a captura de imagens em campo, a execução local das inferências por meio de modelos otimizados, a extração de metadados geoespaciais e a sincronização das informações com base de dados em nuvem quando disponível. Complementarmente, os dados coletados são utilizados para a geração de mapas de calor e mapas interpolados por Krigagem Ordinária, permitindo a análise da distribuição espacial das pragas. Avaliações conduzidas em cenários simulados e em condições reais de campo demonstram a robustez do sistema, bem como a aplicabilidade prática no suporte à tomada de decisão no manejo integrado de pragas.

De forma integrada, os três capítulos estabelecem um fluxo completo que abrange desde a geração e validação dos dados, passando pelo treinamento, otimização e conversão de modelos de *deep learning*, até a implementação de uma solução embarcada associada à análise geoestatística das ocorrências. Essa abordagem evidencia o potencial da inteligência artificial embarcada e das geotecnologias como ferramentas estratégicas para a consolidação da Agricultura 4.0, especialmente em contextos caracterizados por limitações de infraestrutura e conectividade. Ao final, a tese contribui simultaneamente com avanços metodológicos, científicos e tecnológicos, apresentando solução escalável, robusta e alinhada às demandas reais da agricultura brasileira.

OBJETIVOS

Geral

Desenvolver e validar um sistema inteligente para detecção e monitoramento espacial de insetos-praga em lavouras de soja e milho, integrando um modelo de *deep learning* otimizado para dispositivos móveis, um aplicativo embarcado em smartphone para coleta georreferenciada e uma infraestrutura computacional capaz de armazenar, sincronizar e analisar espacialmente a incidência das pragas por meio de técnicas de geoestatística.

Objetivos Específicos

- Construir, organizar e validar o conjunto de dados AgroInsect, incluindo a curadoria das imagens, a anotação individual dos insetos e a padronização das classes *Diabrotica speciosa*, *Dalbulus maidis*, *Diceraeus spp.* e *Spodoptera frugiperda*;
- Treinar e avaliar modelos de detecção de objetos baseados em YOLO, utilizando tanto o conjunto de dados completo (AgroInsect) quanto o conjunto reduzido, a fim de comparar o impacto do tamanho da base na acurácia e na capacidade de generalização;
- Converter os modelos treinados para os formatos TFLite e ONNX, otimizados para execução em dispositivos de baixo poder computacional, avaliando o desempenho, consumo de recursos e a eficiência das inferências embarcadas em smartphone;
- Desenvolver o aplicativo móvel AgroInsect, responsável por capturar imagens em campo, realizar a detecção localmente no dispositivo, extrair metadados (coordenadas GNSS, horário, informações contextuais) e registrar automaticamente cada ocorrência;
- Implementar um mecanismo de sincronização com banco de dados na nuvem, garantindo armazenamento seguro, escalável e estruturado das imagens, detecções e metadados, permitindo análise temporal e espacial das ocorrências;
- Aplicar técnicas de geoestatística, especialmente a Krigagem Ordinária, para gerar mapas de calor e mapas interpolados da incidência dos insetos-praga, possibilitando identificar padrões de distribuição espacial e auxiliar na tomada de decisão no manejo integrado de pragas;
- Avaliar o sistema embarcado em condições reais de campo, analisando robustez, usabilidade, eficiência operacional, latência de inferência, estabilidade do aplicativo, impacto das condições ambientais e confiabilidade das detecções;

- Integrar todo o fluxo operacional em um pipeline automatizado, envolvendo captura, detecção, validação, sincronização, interpolação espacial e visualização, demonstrando a aplicabilidade do sistema para monitoramento em tempo real mesmo em áreas com conectividade limitada.

3 CAPÍTULO 1

PERFORMANCE ANALYSIS OF YOLO AND DETECTRON2 MODELS FOR DETECTING CORN AND SOYBEAN PESTS EMPLOYING CUSTOMIZED DATASET

(AGRONOMY – ISSN-2073-4395)

Abstract: One of the most challenging aspects of agricultural pest control is accurate detection of insects in crops. Inadequate control measures for insect pests can seriously impact the production of corn and soybean plantations. In recent years, artificial intelligence (AI) algorithms have been extensively used for detecting insect pests in the field. In this line of research, this paper introduces a method to detect four key insect species that are predominant in Brazilian agriculture. Our model relies on computer vision techniques, including You Only Look Once (YOLO) and Detectron2, and adapts them to lightweight formats—TensorFlow Lite (TFLite) and Open Neural Network Exchange (ONNX)—for resource-constrained devices. Our method leverages two datasets: a comprehensive one and a smaller sample for comparison purposes. With this setup, the authors aimed at using these two datasets to evaluate the performance of the computer vision models and subsequently convert the best-performing models into TFLite and ONNX formats, facilitating their deployment on edge devices. The results are promising. Even in the worst-case scenario, where the ONNX model with the reduced dataset was compared to the YOLOv9-gelan model with the full dataset, the precision reached 87.3%, and the accuracy achieved was 95.0%.

Keywords: *Spodoptera frugiperda*; *Diceraeus ssp.*; *Dalbulus maidis*; *Diabrotica speciosa*; deep learning; computer vision; pest control; agronomy; grain production; ONNX; TFLite

3.1. Introduction

Securing enough food to satisfy the growing needs of the global population will be one of the most critical challenges facing humanity in the future. The world population is expected to reach 9 billion by 2050 [1], imposing on global leaders the challenge of increasing agricultural production sustainably. However, there are several factors that have impacted food production to meet global demand, such as forest preservation, scarcity of productive areas, soil degradation in cultivated areas [2,3], decrease in water resources [4], resistance to agricultural pesticides [5] and attack by insect pests [6].

In Brazil, agriculture contributed 25% to the gross domestic product (GDP) [7], with a production in the 2022/2023 harvest season of 320 million tons of grains [8]. Notably, soybean and corn production plays a pivotal role, and they are cultivated across several regions [7]. Historically, soybean production in the 2000s was 41.9 million tons, but currently, these numbers have more than tripled, reaching 154.6 million tons. Meanwhile, corn production during the same period increased from 35.2 to 131.9 million tons [8].

For example, agribusiness in Mato Grosso state represents 56.6% of the state's GDP, and so, it is crucial to maintain or increase productivity. The 2022/2023 corn harvest yielded 50,731.2 tons [9], while during the same period, soybean production reached 45,316,887 tons [10]. The production of these grains is important for the state's economy and the entire production chain.

Given the above figures, it is evident that Brazil has established itself in the international market as one of the largest producers and exporters of agricultural products [11,12]. Therefore, it is necessary to invest in new technologies to maintain productivity and maximize profits. The major challenge is to achieve higher production per planted hectare and reduce the use of agricultural inputs for weed and pest control [13].

To maintain Brazil's status as one of the world's leading agricultural producers and enhance profitability for farmers, the integration of computing technology in agriculture is essential. Leveraging such technology can provide valuable information to support informed decision making and drive efficiency in farming practices [14,15,16]. Within the technological realm, computer vision is a highly promising technology [17] that has been applied in various areas of the production process to solve different problems, such as yield prediction [18,19,20,21,22], disease detection [23,24,25,26], weed detection [27,28,29], pest insect detection [30,31,32,33,34,35,36,37], species recognition [38,39,40], crop improvement [41,42], water resource utilization [43,44,45] and soil management [46,47].

In recent years, studies have advanced in the use of deep-learning techniques in conjunction with computer vision technologies applied to agriculture [48,49,50,51]. Among the available systems, You Only Look Once (YOLO) and Detectron2 stand out, with advanced capabilities for real-time target detection, efficiency, accuracy and speed [52,53,54]. These technologies have been utilized for pest control, which can result in decreased production and increased prices of the product and its derivatives [55,56,57]. Using such technologies to develop automated systems or platforms toward detecting and identifying insect species in crops in real time, before populations escalate, could offer significant advantages.

Deep learning (DL)-based solutions excel at object detection and identification with high precision and speed. These solutions leverage the knowledge gained from previously trained neural networks to expedite the training process for new applications [58,59,60,61]. To achieve this, however, a proper, structured dataset containing images

of the objects to be detected is essential, which demands a great deal of effort and knowledge to be accomplished [62].

Driven by the need for more shared and categorized datasets for agricultural research, Yuzhen Lu et al. [48] address a significant gap in the precision agriculture literature by compiling publicly available image datasets used in computer vision applications since 2015. A total of 34 public image datasets were identified and categorized into three groups based on their purposes: 15 datasets related to weed control, 10 dedicated to fruit detection and the remaining 9 for other applications.

Considering effective approaches that use computer vision to detect insects in crops, YOLO versions 3, 4 and 5 were used by S. Verma et al. [49] for the detection of five other insect species (distinct from the ones addressed here) that also attack soybeans. They concluded that YOLO v4 and YOLO v5 can be applied for the automatic identification of insects in different agricultural crops. Park et al. [30] developed a deep-learning prediction platform on unmanned ground vehicles with three different models for object detection: MRCNN, YOLO v3 and Detectron2. All models achieved satisfactory results in detecting *Riptortus pedestris* (*R. pedestris*). The three models showed a mean average precision (mAP) performance of 0.95797, 0.97541 and 0.94435, respectively.

A two-stage classification model, named MaizePestNet, was developed based on EfficientNet-B0 and the Grad-CAM algorithm to locate targets and minimize background interference, thus achieving improved classification performance [50]. A dataset was created that includes 36 common maize pests, such as *Spodoptera frugiperda*, covering both adult and larval stages. The models proposed by the authors achieved the lowest average accuracy of 83.18%, while the highest average accuracy was 94.22%. This performance surpassed that of the control models ResNet101 and DenseNet161, which had average accuracies of 88.2% and 84.81%, respectively.

Another key issue in this area is the deployment of the aforementioned computer vision models on resource-constrained (edge) devices. This is crucial because such devices offer advantages like lower costs, reduced energy consumption and portability. However, deploying insect detection systems on resource-constrained devices poses a significant challenge due to the limited computational capacity of the equipment and the complexity of the application scenarios. Rustia et al. [40] developed a remote system for continuous monitoring of insect pests in an outdoor mango orchard. The proposed deep-

learning algorithm succeeded in recognizing pest insects of various sizes, achieving an F1-Score of 0.96% and an average processing time of 10.93 s on a Raspberry Pi Zero W.

To enable the deployment of large computer vision models on edge devices, frameworks such as ONNX and TFLite [63] have been developed. These frameworks optimize the mathematical functions of the models to fit the constraints of limited hardware. For instance, Lim et al. [64] utilized ONNX to effectively convert models for compatibility with specific frameworks. An integrated framework was developed that allows for exploring and customizing the inference operations of various convolutional neural network (CNN) models on embedded edge devices.

Although the above studies show promising results, there is still a gap to be addressed regarding the size of the dataset required for training the models and the detection capabilities of models converted to ONNX and TFLite formats [63].

In this paper, we created a dataset called AgroInsect, which includes existing images of the following insect species: *Diabrotica speciosa*, *Dalbulus maidis*, *Diceraeus spp.* and *Spodoptera frugiperda*. From this image collection, we derived a Reduced dataset containing 100 images of each such species. To assess the detection capability of the models according to the dataset size, we utilized Detectron2 and YOLO models (versions v5, v7, v8 and v9 (c and gelan)). The best results from each model combined with the dataset were converted to ONNX and TFLite formats to evaluate detection performance. Effective detection with these converted models paves the way for their use in devices with limited computational resources, such as smartphones and microcontrollers, and facilitates the development of low-cost applications capable of autonomous operation. Compared to previous studies, our research delves into the challenges of testing models with reduced datasets, allowing for the incorporation of new insect species into detection models with a limited number of samples. This study is expected to advance the development of insect detection applications on resource-constrained devices.

The remainder of this paper is organized as follows. The Section 2 details the development process, including dataset creation, model selection, model conversion and evaluation metrics. Section 3 provides the evaluation results. In Section 4, we present and discuss the main findings. Finally, the Section 5 outlines the key insights and suggests directions for future research.

3.2. Materials and methods

3.2.1. Dataset Acquisition

Four economically significant pest insects found in corn and soybean crops in the State of Mato Grosso were selected for this study, as presented in Figure 1: *Diabrotica speciosa* [65,66,67], *Dalbulus maidis* [68,69], *Diceraeus spp.* [67,70,71,72,73], *Spodoptera frugiperda* [55,67,74,75,76].




Figure 1. Insects selected for the dataset. (a) *Diabrotica Speciosa*; (b) *Dalbulus Maidis*; (c) *Diceraeus spp.*; (d) *Spodoptera Frugiperda*.

To ensure the reliability of the data used and the four evaluated species, a total of 1510 images were gathered. One part of these images was sourced from the iNaturalist database (inaturalist.org) [77,78], and another part was captured in the field by the authors themselves and validated by entomology experts.

3.2.2 Compilation of the AgroInsect Dataset

The object detection methods used in the experiments conducted in this work require image annotations for supervised learning. These annotations include information about the region of interest (ROI), classification target and class information [79,80].

To test the efficiency of Detectron2 and the YOLO family, the AgroInsect dataset was created, encompassing 1510 images. From this dataset, a subset of images for training was extracted and is referred to in this work as the Reduced dataset. Many existing works use random selection of the images in the dataset for training, validation and test images [38,49,67]. However, one of the goals of this work was to measure the detection capability of different models. To ensure that all models were trained under the same conditions, the first one hundred images from each class were selected for use in all training sessions with the Reduced dataset. Training with the AgroInsect dataset was performed using all available images, except those selected for validation and testing. The same predetermined selection criterion was applied to the choice of the fifteen validation

images and the twenty-five test images. All models trained with both datasets were tested with the same images to avoid any results being influenced by image complexity or other factors. All the evaluated models were able to make successful inferences on images featuring multiple insects or different classes. However, to simplify the interpretation of test results for each class in the confusion matrix, we used only images containing a single insect. Table 1 presents the number of images and annotations for each class in the AgroInsect and Reduced datasets, respectively. The difference between the number of images and annotations is due to some images containing more than one insect of the same species (one annotation per insect); however, this situation did not occur with the images and annotations used for validation and testing, since we chose here only images with a single insect.

Annotations for the 1510 images were created using Label Studio version 0.9.1, an open-source software that stores annotations in JSON format within an SQLite or PostgreSQL database. The software allows exporting to different formats [81]. After annotating and labeling all images, they were exported to the YOLO format with the configuration [class_id x, y, w, h]. These parameters are used to represent an object in a computer vision system. The annotation files were saved with the same names as the images, and the configurations for the file paths that feed the model (training/validation/test) were saved in a YAML file.

Table 1. Division of datasets for each insect class and their annotations for training and evaluation of deep-learning models.

Dataset	Classes				
	<i>Diabrotica speciosa</i>	<i>Dalbulus maidis</i>	<i>Diceraeus ssp.</i>	<i>Spodoptera frugiperda</i>	Total
AgroInsect	591	177	248	334	1350
	599	280	257	358	1496
Reduced	100	100	100	100	400
	100	156	104	102	462
Validation	15	15	15	15	60
	15	15	15	15	60

	25	25	25	25	100
Test	25	25	25	25	100

3.2.2. Training Methods

The Detectron2 used in this research is an updated version of the original Detectron framework, developed and presented by Facebook AI Research on 9 October 2019. This new version focuses primarily on object detection and instance segmentation tasks. The deep-learning library used was PyTorch, enabling integration with other neural network architectures. Detectron2 utilizes pretrained models with large image datasets [82,83].

YOLO emerges as an innovative model for object detection, offering a unified and efficient solution for use in computer vision. Its simplicity in construction and direct training on complete images set it apart from traditional approaches, making it ideal for real-time applications. Unlike classifier-based methods, which operate in separate stages, YOLO stands out with its unique architecture. The model is trained on a single loss function directly related to detection performance, optimizing the process and ensuring accurate results. It is recognized as the fastest general-purpose object detector in the literature, paving the way for a range of innovative applications. Its ability to operate in real time and adapt to different scenarios makes it ideal for a wide range of applications in areas such as security, industry, medicine, agriculture and transportation [52].

The models were tested using the two datasets created (AgroInsect and Reduced) and included YOLO models (v5, v7, v8 and v9, both c and gelan versions). The models that demonstrated the best precision were then converted to ONNX and TFLite formats, which are optimized for deployment on devices with limited computational resources. As the algorithms to convert YOLO version 9 (c and gelan) to the TFLite and Detectron2 to ONNX and TFLite are not yet publicly available, they were not converted.

The training of the models was conducted using Google Colab [84,85], a cloud-based notebook service provided by Google, which allows writing and executing Python code directly in the browser and provides graphics processing units (GPUs) and tensor processing units (TPUs) to accelerate machine-learning and deep-learning tasks. Using Google Colab enables researchers to conduct evaluations without the need to purchase acceleration hardware. The configuration used for training and inference in this research

included a T4 GPU accelerator (Nvidia, Santa Clara, CA, USA), with data integration saved in Google Drive.

3.2.3. Conversion Methods to ONNX and TFLite

The conversion of YOLO models to ONNX or TFLite formats offers several advantages, including portability, efficiency and integration with a wide range of platforms and devices [64,86,87]. Given these benefits, the models were converted to ONNX and TFLite formats after the initial training with the selected datasets. It is noteworthy that version 7 required more effort during the conversion process, as it did not have a standard implementation in the file available on the GitHub repository. Additionally, versions 9 were converted only to ONNX, as TFLite was not available at the time of this research work.

3.2.4. Models' Parameters and Evaluation Metrics

The models used in this paper involve numerous hyperparameter settings. However, the aim of the research was not to evaluate the effectiveness of different configurations but to assess the model's ability to correctly detect pest insects. To this end, some adjustments were made to the default settings of the models, as detailed in Table 2, which also provides information on several important parameters for the networks. It is worth noting that Detectron2 works with a very small learning rate to converge efficiently.

Table 2. Some important hyperparameters for configuring the Detectron2 and YOLO models.

Model	Detectron2	YOLOv5n	YOLOv7	YOLOv8	YOLOv9-c	YOLO V9-gelan
Layers	50	168	106	25	70	42
Activation Function	ReLU ¹	ReLU	ReLU	Leaky R ⁴	Leaky R	ReLU
Loss Function	Cross-entropy	BCE ³	Cross-entropy	Combine d loss	DFL	DFL ⁵

Optimizer	SGD ²	Adam	SGD	Adam	Adam	SGD 2
Learning Rate	0.00005	0.01	0.01	0.001	0.01	0.01
Batch Size	2	16	16	16	16	16
Epochs	10.000	300	300	300	300	300
Regularization	L2	L2	L2	L2	L2	L2

¹ Rectified Linear Unit, ² Stochastic Gradient Descent, ³ Binary Cross-Entropy, ⁴ Leaky Rectified Linear Unit, ⁵ Distillation-Augmented Feature Loss.

In this research, precision (P), accuracy (A), recall (R), F1-Score (f1) and confusion matrix are useith additional Python scripts in Visual Studio Code. The metric results were saved in spreadsheets for discussion.

To understand the results, it is important to understand the variables: true positive (TP) represents what was correctly predicted; true negative (TN) indicates that the model correctly predicted that a class is not present; false positive (FP) occurs when the model makes an incorrect detection; false negative (FN) occurs when the model fails to predict an object in the image.

The model's precision is calculated by Equation (1), which is the ratio of the number of true positive examples predicted to the total of true positive and false positive predictions.

$$\text{Precision (P)} = \text{TP} / (\text{TP} + \text{FP}) \quad (1)$$

The model's accuracy is the product of all true predictions divided by the total number of predictions, as follows:

$$\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{TP} + \text{FN} + \text{TN} + \text{FP}) \quad (2)$$

Equation (3) presents the recall, which measures the proportion of true positives correctly identified.

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN}) \quad (3)$$

The F1-Score is a metric that combines precision and recall, expressed in Formula (4).

$$F1 = 2 \times (P \times R)/(P + R) \quad (4)$$

In addition to the metrics presented above, an important tool used in this work to visualize and analyze the performance of neural network models in object detection is the confusion matrix [91,92,93,94]. According to Markoulidakis et al. [95] and Farhadpour et al. [96], this is a powerful tool for analyzing the performance of classification algorithms. Figure 2a,b show the confusion matrix used for binary and multiclass classification problems. Figure 2a displays a confusion matrix for binary classification with dimensions of 2×2 , having the actual class labels ‘Positive’ and ‘Negative’, and the predicted elements (positive and negative) compared with the actual class labels, resulting in true positives (TPs), true negatives (TNs), false positives (FPs) and false negatives (FNs). On the other hand, the multiclass confusion matrix (Figure 2b) is a structure with dimensions $N \times N$, where N is the number of classes. The predicted values are compared with the actual values and summed at the position (actual class, predicted class). The higher the values of $X_n = Y_n$, the more efficient the model.

Actual Class		Predicted Class			
		Predicted Class			
		Positive	Negative		
Positive		TP	FN		
Negative		FP	TN		

(a)

Actual Class	Predicted Class			
		$C Y_1$	$C Y_2$	$C Y_n$
	$C X_1$	$\sum C X_1 - C Y_1$		
	$C X_2$	$\sum C X_2 - C Y_1$	$\sum C X_2 - C Y_2$	
	...			...
	$C X_n$		$\sum C X_n - C Y_2$	$\sum C X_n - C Y_n$

(b)

Figure 2. Examples of confusion matrices. (a) Confusion matrix for binary classification problem. (b) Confusion matrix for multiclass classification problem.

3.3 Results

3.3.1. Evaluation of the Detectron2 Model in Insect Detection

Figure 3 presents the loss function of Detectron2 trained with both datasets. The value of the loss function gradually decreased as the iterations progressed.




Figure 3. Evolution of the loss function of Detectron2 over iterations with training executed on the Reduced dataset (a) and on the AgroInsect dataset (b).

Despite different amounts of data, both models showed a sharp decline in error rate before 2000 epochs, with a less pronounced decline starting around epoch 4000. Figure 3a, which represents training on the Reduced dataset, exhibited a more continuous decline compared to the graph of the AgroInsect dataset.

The decrease in loss score with increasing iterations indicates that the model is learning and improving its object detection performance. The point where the decline slows down signals a decrease in the model's generalization ability.

The results of the inferences made with the Detectron2 model are presented in Table 3.

Table 3. Metrics per class after inference of test images using the Reduced and AgroInsect datasets with the Detectron2 model

Dataset	Classes	Precision	Recall	F1-Score	Accuracy
Agroinsect	<i>Diabrotica Speciosa</i>	92.31	96	94.12	97.12
	<i>Dalbulus</i>	96.15	100	98.04	99.04
	<i>Diceraeus</i>	100	96	97.96	99.04
	<i>Spodoptera Frugiperda</i>	96.15	100	98.04	99.04
	<i>General</i>	94.23	94.23	94.23	97.69
	<i>Diabrotica Speciosa</i>	92.31	96	94.117	97.0874

	<i>Dalbulus</i>	96.15	100	98.0392	99.0291
Reduced	<i>Diceraeus</i>	100	92	95.83	98.06
	<i>Spodoptera Frugiperda</i>	100	100	100	100
	<i>General</i>	94.17	94.17	94.17	97.67

The consistency in these values (94.23% for precision, recall and F1-Score) suggests that the model is well balanced in its ability to correctly identify positive and negative classes. The high accuracy of 97.69% indicates that, in addition to being good at correctly predicting the positive class, the model also classifies samples from the negative classes correctly. The decrease from 94.23% to 94.17% in precision, recall and F1-Score metrics was minimal, indicating that the model's performance remained almost unchanged even with the dataset reduction. Similarly, the accuracy variation was also very small, decreasing from 97.69% to 97.67%.

Figure 4 illustrates the performance of the inference conducted using the Detectron2 model applied to the four types of insects investigated in this study. The figure clearly demonstrates the model's ability to accurately identify and classify the insects in the images from the datasets used. It was observed that the model was able to accurately predict the presence of insects in both training datasets, highlighting its robustness and reliability. Additionally, the analysis revealed that the model performed consistently across all variations in these insect images. These observations suggest that Detectron2 is effective for insect detection tasks, underscoring its utility for practical applications in pest monitoring.



Figure 4. Prediction with Detectron2 and custom dataset. (a) contains the resulting images from the model trained with the Reduced dataset, and in (b), the images are from the AgrolInsect dataset.

The confusion matrix (Figure 5) for Detectron2 with the two datasets shows high performance. The model had no difficulty in locating the insects; however, the best results were obtained for the *Dalbulus* and *Spodoptera frugiperda* classes, with all samples being detected.

3.3.2. Evaluation of the YOLO Model for Insect Detection

Table 4 presents the versions of the YOLO model used in this study along with the sizes of the original model and the sizes after training with the datasets (AgroInsect/Reduced).



Figure 5. Confusion matrix of the Detectron2 model trained with the Reduced dataset (a) and the AgroInsect dataset (b). The background includes insects detected where none existed.

The reduction in model complexity, fewer parameters to adjust, more effective regularization and reduction in data diversity contribute to the model size reduction. After training with the Reduced dataset, the YOLOv5, YOLOv8 and YOLOv9-c versions showed a decrease in size compared to the original model. The increase in the size of the YOLOv7 and YOLOv9-gelan models following training may be due to a combination of factors, including modifications to the model architecture, more detailed storage of weights and parameters and the complexity of the training data. The models might have stored weights with higher precision or in different formats, leading to a larger file size. When models use higher precision for weight representation, this can significantly contribute to increasing the final model size.

Table 5 shows the performance metrics, including precision, recall, F1-Score and accuracy, for different versions of YOLO models evaluated on the two distinct datasets. The results show that the YOLOv5 model achieved precision, recall and F1-Score of 85.58% with the Reduced dataset. However, with the AgroInsect dataset, these metrics

significantly improved to 98.04%. Accuracy specifically increased from 94.23% to 99.22% when using the complete dataset. YOLOv7 showed similar performance, with precision, recall and F1-Score of 86.67% on the Reduced dataset and 96.12% on the AgroInsect dataset. Accuracy also increased from 94.67% to 98.45% on the AgroInsect dataset. YOLOv8 obtained values of 86.54% for precision, recall and F1-Score with the Reduced dataset and 96.08% with the AgroInsect dataset. The accuracy for this model increased from 94.62% to 98.43% between the two datasets.

Table 4. Different versions of YOLO and the size of each model after training with specific datasets.

YOLO version	Model	Dataset	Original Size (MB)	Training Size (MB)
YOLOv5	YOLOv5n	Reduced	3.9	3.7
		AgroInsect		13.8
YOLOv7	YOLOv7	Reduced	72.1	284.7
		AgroInsect		284.7
YOLOv8	YOLOv8n	Reduced	6.2	6
		AgroInsect		35
YOLOv9	YOLOv9-c	Reduced	98.4	98
		AgroInsect		98
	YOLOv9-gelan	Reduced	49.1	195.2
		AgroInsect		195.2

The YOLOv9-c model exhibited a slight variation in accuracy from 98.81% to 98.82%, with precision, recall and F1-Score of 97.03% on the Reduced dataset, improving slightly to 97.06% on the AgroInsect dataset.

Finally, YOLOv9-gelan achieved 96.08% in precision, recall and F1-Score with the Reduced dataset and 98.04% with the AgroInsect dataset, with accuracy increasing from 98.43% to 99.22%. Overall, the performance metrics for all YOLO models showed

a significant improvement when evaluated with the AgroInsect dataset compared to the Reduced dataset. However, it is important to note that the smaller dataset also yielded satisfactory results, paving the way to its use in resource-constrained devices.

Figure 6 shows the learning curves that outline the training processes of the models over epochs. The optimizer updated the model weights, reducing losses and improving their performances. It is possible to see the model's learning capacity and potential overfitting or underfitting. Figure 6(a-1) presents the learning curves (total loss) for all YOLO models trained with the Reduced dataset, while Figure 6(a-2) highlights the class loss. Similarly, Figure 6(b-1) illustrates the box loss, and Figure 6(b-2) shows the class loss for the models trained with the AgroInsect dataset. It can be observed that box, class and objectivity loss decreased over the training time (epoch) as the model learned to locate, identify and detect insects with greater confidence.

Table 5. Comparison of model performance metrics based on different training datasets and YOLO versions.

YOLO Version	Dataset	Precision %	Recall %	F1-Score %	Accuracy %
YOLOv5	Reduced	85.58	85.58	85.58	94.23
	AgroInsect	98.04	98.04	98.04	99.22
YOLOv7	Reduced	86.67	86.67	86.67	94.67
	AgroInsect	96.12	96.12	96.12	98.45
YOLOv8	Reduced	86.54	86.54	86.54	94.62
	AgroInsect	96.08	96.08	96.08	98.43
YOLOv9-c	Reduced	97.03	97.03	97.03	98.81
	AgroInsect	97.06	97.06	97.06	98.82
YOLOv9-gelan	Reduced	96.08	96.08	96.08	98.43
	AgroInsect	98.04	98.04	98.04	99.22

The YOLOv8, YOLOv9-c and YOLOv9-gelan versions experienced early stopping, halting training when the model showed no sign of improvement in the last epochs with the AgroInsect dataset, and with the Reduced dataset, only the YOLOv9 versions experienced this early stopping. This early stopping parameter can be configured, but in this research, the versions used the default setting, considering the last

100 epochs. With the AgroInsect dataset, the selected models performed well in training/learning with faster convergence, without reaching the 300 epochs used in training, except for the YOLOv5s and YOLOv7 models, which went up to the end of the 300 epochs for the insect datasets.




Figure 6. Loss curves for YOLO models trained on two different datasets (Reduced dataset and AgroInsect dataset, respectively), where (a-1,b-1) represent the total loss, and (a-2,b-2) represent the class loss.

Figure 7a, b present the precision curve during the training of the YOLO models used in this research. The YOLOv7 model, during training on both datasets, showed a later convergence; however, before 100 epochs, it managed to stabilize the precision result. The other models had a faster convergence around epoch number 40, with the result stabilizing until the end of the training, which is very similar to the results presented by Badgujar et al. [62] in a study on insect identification.

Figure 8 illustrates the training graph of the YOLOv5 model over 300 epochs with the Reduced dataset. Despite showing the lowest Precision value among all the values in Table 5, it is observed that the model converged without much fluctuation in box_loss and cls_loss. The Recall values, which measure the model's ability to find all objects present in the image, reached 80% before 100 epochs.




Figure 7. Precision curve of YOLO model training: (a) Reduced dataset; (b) Agrolnsect dataset.

The YOLOv9-gelan achieved the highest precision among all models and datasets. Figure 9 presents the training results of the model, with a significant drop in box_loss, reaching an mAP@[0.50] above 90% and a Recall metric above 80%. The mAP@[0.50] and Recall are important metrics for evaluating the performance of object detection models, as they measure precision and coverage of detection, respectively.

Figure 10 illustrates the confusion matrix for five YOLO models used in the experimental study, trained with a Reduced dataset to classify four insect classes. It is observed that even in YOLOv5, YOLOv7 and YOLOv8 versions, which did not achieve a precision higher than 90% (Table 5), the false negatives in the last column of each model and false positives in the last row were low.

The YOLOv5s model had the lowest overall precision; however, it correctly classified 22 out of 25 *Diabrotica speciosa* images used in the test, 1 image as *Dalbulus*, and it failed to detect 2 images. In the *Dalbulus* class, 24 images were correctly classified, with four false positives and one false negative, while the other two classes followed a similar pattern with good precision. The standout among the models using the Reduced dataset was the YOLOv9-gelan version, which, out of 100 images used for testing, failed to predict only 2 images and had two false positives for the *Dalbulus* and *Diceraeus* classes.




Figure 8. Metric curve of YOLOv5s trained with the Reduced dataset.




Figure 9. Training metrics curve of YOLOv9-gelan: Agrolnsect dataset with the best result among model/dataset combinations.

Figure 10 illustrates the confusion matrix for five YOLO models used in the experimental study, trained with a Reduced dataset to classify four insect classes. It is observed that even in YOLOv5, YOLOv7 and YOLOv8 versions, which did not achieve a precision higher than 90% (Table 5), the false negatives in the last column of each model and false positives in the last row were low.




Figure 10. Confusion matrix of YOLO models with Reduced dataset.

The YOLOv5s model had the lowest overall precision; however, it correctly classified 22 out of 25 *Diabrotica speciosa* images used in the test, 1 image as *Dalbulus*, and it failed to detect 2 images. In the *Dalbulus* class, 24 images were correctly classified, with four false positives and one false negative, while the other two classes followed a similar pattern with good precision. The standout among the models using the Reduced dataset was the YOLOv9-gelan version, which, out of 100 images used for testing, failed to predict only 2 images and had two false positives for the *Dalbulus* and *Diceræus* classes.

The confusion matrix presented in Figure 11 was used to demonstrate the excellent capability of the YOLO models trained with the AgroInsect dataset. During the evaluation of the YOLOv5s and YOLOv9-gelan models on a test set, a low error rate was observed, with only two false positives recorded. The *Dalbulus* class presented greater difficulty for all tested models, with two false positives in each case. In summary, the visualization of the confusion matrix provides a more comprehensive understanding of the performance of the object detection models, highlighting the areas of success and opportunities for improvement. Identifying specific error patterns, such as those observed in the *Dalbulus* class, is crucial for guiding future adjustments and refinements in detection algorithms.




Figure 11. Confusion matrix of YOLO models with AgroInsect dataset.

Figure 12 illustrates the performance of YOLOv9-gelan in insect detection, showcasing inference results on eight images from the AgroInsect dataset. Each insect class is represented by two images, highlighting YOLOv9-gelan's ability to accurately identify insects across various colors and textures.




Figure 12. Insect detection with YOLOv9-gelan: (a) *Diabrotica speciosa*; (b) *Dalbulus maidis*; (c) *Diceraeus ssp.*; (d) *Spodoptera frugiperda*.

Table 6 presents a detailed comparison of the performance parameters for five YOLO models after conversion to ONNX and TFLite formats. The models were trained on the two datasets used in this work. The table shows the comparison of precision, recall, F1-Score and accuracy for each model and format combination across both datasets. This comparison highlights variations in model performance based on the dataset and conversion format. Understanding these variations is essential for evaluating the effectiveness of each YOLO version.

Table 6: Comparison of performance parameters for models converted to ONNX and TFLite.

Model	Dataset	Conversion	Precision %	Recall %	F1-Score %	Accuracy %
YOLOv5	Reduced	ONNX	94.23	94.23	94.23	97.69
	Reduced	TFLite	94.23	94.23	94.23	97.69
	AgroInsect	ONNX	96.15	96.15	96.15	98.46
	AgroInsect	TFLite	96.15	96.15	96.15	98.46
YOLOv7	Reduced	ONNX	94.23	94.23	94.23	97.69
	Reduced	TFLite	94.23	94.23	94.23	97.69
	AgroInsect	ONNX	96.15	96.15	96.15	98.46
	AgroInsect	TFLite	96.15	96.15	96.15	98.46
YOLOv8	Reduced	ONNX	86.54	86.54	86.54	94.62
	Reduced	TFLite	86.54	86.54	86.54	94.62
	AgroInsect	ONNX	96.12	96.12	96.12	98.45
	AgroInsect	TFLite	96.12	96.12	96.12	98.45
YOLOv9-c	Reduced	ONNX	96.97	96.00	96.48	98.25
	AgroInsect	ONNX	97.09	97.09	97.09	98.84
YOLOv9-gelan	Reduced	ONNX	97.03	97.03	97.03	98.81
	AgroInsect	ONNX	98.04	98.04	98.04	99.22

The results presented in Table 6 demonstrate that for the Reduced dataset, both YOLOv5 and YOLOv7 achieve consistent performance, with precision, recall and F1-Score of 94.23% and accuracy of 97.69% across ONNX and TFLite formats. In contrast, YOLOv8 shows reduced metrics, with precision, recall and F1-Score of 86.54% and accuracy of 94.62% in the same formats. For the AgroInsect dataset, all models perform better, with YOLOv5 and YOLOv7 reaching 96.15% in precision, recall and F1-Score and accuracy of 98.46%. YOLOv8 also maintains high metrics at 96.12% for precision, recall and F1-Score, with an accuracy of 98.45%. Notably, YOLOv9-c and YOLOv9-gelan exhibit superior results, with YOLOv9-gelan achieving the highest metrics of 98.04% for precision, recall and F1-Score and accuracy of 99.22% on the AgroInsect dataset.

The results of the inferences made with the converted models applied to the test data are presented in Table 6. It is important to note that all metrics for the model/dataset combinations achieved results above 94%, except for the YOLOv8 model applied to the

Reduced dataset, which reached 86.54% precision, recall and F1-Score and 94.62% accuracy.

The results for the YOLOv5s model trained with the Reduced dataset and converted to TFLite, and the YOLOv9-gelan model with the AgroInsect dataset and converted to ONNX, can be observed in the confusion matrix (Figure 13).



Figure 13. Confusion matrix of YOLO models: (a) Detection result for YOLOv5s-TFLite with Reduced dataset; (b) Detection result for YOLOv9-gelan-ONNX with AgroInsect dataset.

Figure 14 displays a selection of detection results from the YOLOv5s-TFLite and YOLOv9-gelan-ONNX models, illustrating successful detection across all four challenging categories.




Figure 14. Inferences with ONNX and TFLite: (a) YOLOv5s-TFLite result; (b) YOLOv9-gelan-ONNX result.

3.4. Discussion

Data processing is a critical step in supervised deep learning, as feeding irrelevant or incorrect data can significantly affect model performance, as noted by Badgujar et al.

[62]. Y. Lu and S. Young [48] reported the scarcity of public image datasets, describing this situation as a crucial bottleneck for rapid prototyping and evaluation of computer vision and machine-learning algorithms applied to agriculture, thus justifying the need for evaluations with smaller datasets, which could facilitate the development of applications without requiring a large dataset. Good precision and accuracy using a dataset with few images pave the way for incorporating new insects into the model without the need for extensive efforts to collect many images and annotations.

During the development of this work, no other dataset with the same insect classes evaluated here was found in the literature. However, to get an idea of the performance of YOLO and Detectron2 algorithms, we compared our results with other papers that we found sufficiently close to our approach, and we summarized them in Table 7. The approach by S. Verma et al. [49] used YOLO versions 4 and 5 for detecting five insects and achieved precisions of 99% and 93.20%, respectively. Considering that our best results were achieved with YOLOv5s and YOLOv9-gelan versions with a precision of 98.04% in both cases, the 0.96% difference between the two evaluations may be associated with the number of images used in training. They used 3710 images, while we only used 1510 images.

Table 7: Comparison of results obtained with the models proposed in this work and those available in the literature, including the number of classes, dataset and metrics.

Model	Classes	Dataset	Precision	Recall	F1-Score	Accuracy
YOLOv5s	4	AgroInsect	98.04%	98.04%	98.04%	99.22%
YOLOv5s	4	Reduced	85.58%	85.58%	85.58%	94.23%
YOLOv7	4	Reduced	86.67%	86.67%	86.67%	94.67%
YOLOv8	4	Reduced	86.54%	86.54%	86.54%	94.62%
YOLOv9-gelan	4	AgroInsect	98.04%	98.04%	98.04%	99.22%
Detectron2	4	AgroInsect	94.23%	94.23%	94.23%	97.69%
YOLOv5s [49]	5	-	93.20%	99.60%	96%	-
YOLOv4s [49]	5	-	99%	93%	96%	-
YOLOv7-Adam [97]	3	-	99.95%	-	-	-
Maize-YOLO [98]	13	-	73.30%	77.30%	75.10%	-
New Version-5x [99]	7	-	86.80%	88.60%	87.80%	-

YOLOv3/5 [100]	6	-	92.70%	93.90%	93.20%	-
EfficientNet-Br [50]	36	-	93.51%	97.14%	94.68%	-
YOLOv3 [67]	12	-	95.15%	75.79%	84.35%	72.96%
YOLO-MPNET—OSW [101]	3	-	94.14%	91.99%	93.05%	-
YOLOv5-Modificado [102]	2	-	86.84%	84.58%	85.69%	-
CNN [51]	5	-	97.00%	-	-	-
InceptionV3 [51]	5	-	97.00%	-	-	-
YOLOv5 [51]	5	-	98.75%	-	-	-

The authors Zhang et al. [97], using the YOLOv7 model and the Adam optimizer, achieved a precision of 99.95% for the classification of *Diabrotica virgifera*, *Zea mays*, *Spodoptera frugiperda* and *Helicoverpa zea*, which is higher than the 98.04% precision obtained by the best models proposed in this study.

As mentioned, good efficiency using a reduced dataset paves the way for incorporating new insects into the model without the need for many samples. The results achieved with the models using the Reduced dataset were superior to those obtained by Yang et al. [98], who achieved a precision of 73.30%, recall of 77.30% and F1-Score of 75.10% in detecting 13 insects. YOLO models (v5, v7, v8) combined with the Reduced dataset achieved precision results close to the 86.8% obtained by Kumar et al. [99] and Slim et al. [102].

Among the training combinations with YOLO versions and the AgroInsect dataset, YOLOv8 provided the worst results, with 96.08% precision, recall and F1-Score and an accuracy of 98.43%. However, these values are higher than those achieved by Bjerger et al. [100], who, among ten models, achieved the best precision at 92.7%, recall at 93.9% and F1-Score at 93.2%.

The results generated with the models applied in this work are consistent with the values from a study on corn earworm (*Spodoptera frugiperda*) in Chinese cornfields for detection from larval to adult stages presented by Zhang et al. [50], who achieved a good balance between precision and cost, with a precision of 93.51%, recall of 97.14% and F1-Score of 94.68%.

This study is relevant compared to other studies on pest insects attacking soybean crops. In a recent work published by Tetila et al. [67], which aimed to identify 12 different classes, including 2 at two stages (nymph and adult) in the State of Mato Grosso do Sul in Brazil, the best precision achieved was 95.15%.

Another insect detection study with three classes achieved the best precision of 94.14%, recall of 91.99% and F1-Score of 93.05% for the *C. medinalis* class using YOLO-MPNET with OSW, as reported by Sun et al. [101]. Using the YOLOv5 model, they achieved the best precision of 71.26%, while our work achieved a precision of 85.58% using the same model with a reduced dataset.

With a precision of 94.23% for Detectron2 and 98.04% for YOLOv5s, the models evaluated here demonstrated more consistent results than those presented by Slim et al. [102], who achieved a precision of 86.84% in detecting the Mediterranean fruit fly *Ceratitis capitata* and the peach fruit fly *Bactrocera zonata*.

A study conducted for the detection of five classes of insects that attack soybeans in India yielded excellent results, with an accuracy of 97% using CNN and Inceptionv3 models and 98.75% using YOLOv5 in the work presented by Trikey et al. [51]. However, the results achieved in our studies were superior, with YOLOv5s and YOLOv9-gelan models achieving 98.04% accuracy.

The equal value observed in this paper regarding the precision, recall and F1-Score metrics can be explained by the presence of a balanced test set, coupled with the model's ability to generalize consistently across all classes. This pattern reflects a robust and balanced model performance, suggesting an absence of bias toward any specific class and the ability to make accurate predictions across all categories.

As presented in Figure 5, the confusion matrix demonstrates the models' ability to correctly detect classes with few false positives and negatives.

To run on edge devices with limited computational resources, the model size can be a determining factor. After analyzing the results of the research published by Ye et al. [103] with a 12 MB model and the data in Table 4, it is evident that there is room for improvement in reducing our model sizes, as our results showed that the YOLOv9-gelan model had a size of 195.2 MB.

As shown in Table 6, with the conversion of the models, YOLO v5, v7 and YOLO 9-gelan with a reduced dataset showed improved accuracies, while v8 maintained results for the smaller dataset and improved with the full dataset. The YOLO 9-c model did not show much variation. Once converted to standard formats, such as ONNX or TFLite, the

models can be run on a variety of platforms and devices, including mobile devices, embedded systems and servers. This provides greater flexibility for deploying YOLO models in different environments.

3.5. Conclusions

This paper presents an approach based on deep-learning models to detect four species of insects found in corn and soybean crops. Our technique evaluates various setups with YOLO and Detectron2 models. In order to render our method deployable in resource-constrained devices, we compared the two mentioned computer vision models on a full (AgroInsect) and a smaller subset (Reduced) dataset and finally converted the best-performing models into TFLite and ONNX formats.

The Detectron2 and YOLO models demonstrated strong performance in detecting and classifying insect species, even when trained with the Reduced dataset. As anticipated, the models performed better with the AgroInsect dataset, but the results with the Reduced dataset were still notable. YOLOv5 achieved an accuracy of 85.58%, YOLOv7 86.67%, YOLOv8 86.54%, YOLOv9-gelan 96.08% and YOLOv9-c 97.03%. For the YOLOv9-c and YOLOv9-gelan models, the accuracy difference between the AgroInsect and Reduced datasets was just 0.03% and 1.96%, respectively. A key finding of this study is that even with a limited number of images for a specific insect, a model can maintain high efficiency and accuracy.

Additionally, YOLOv5 models with a Reduced dataset performed better when converted to TFLite, with a 2.19% decrease in accuracy in comparison to the results with the AgroInsect dataset. For YOLOv7, there was an improvement with the Reduced dataset, while YOLOv8 showed no significant variations. Similarly, the YOLOv9-c and YOLOv9-gelan versions also exhibited minimal variations in results. These outcomes demonstrate that converting YOLO results into TFLite and employing a reduced dataset is a practical and effective approach for deploying insect pest detection on resource-constrained devices.

For future work, we plan to further investigate the effects of varying reduced dataset sizes on model performance and tailor our approach for effective deployment and evaluation on mobile devices. This will involve optimizing our method to perform efficiently on mobile platforms and evaluating its effectiveness in practical, real-world scenarios. We also intend to integrate images from yellow traps, light traps and

pheromone traps into our datasets toward evaluating the models' ability to detect and classify in visually noisier images with other insects.

Author Contributions

Conceptualization, L.N.S.d.S., G.P.S.d.A. and M.B.T.; methodology, L.N.S.d.S., M.B.T., L.R.d.S.S., R.d.O., M.D.O. and G.P.S.d.A.; formal analysis, G.P.S.d.A., P.d.C.G., H.F.d.C.F. and M.C.T.; investigation, G.P.S.d.A., M.C.T. and R.d.O.; resources, M.B.T. and L.N.S.d.S.; writing—preparation of the original draft, G.P.S.d.A.; writing—review and editing, L.N.S.d.S., R.d.O., P.d.C.G., H.F.d.C.F., L.R.d.S.S. and M.D.O.; visualization, L.N.S.d.S. and M.C.T.; supervision, L.N.S.d.S. and M.B.T.; project administration, L.N.S.d.S. All authors have read and agreed to the published version of the manuscript.

Funding

This research get financial support from the Ministry of Science, Technology, and Innovation (MCTI), the Funding Authority for Studies and Projects (FINEP), the Research Support Foundation of the State of Goiás (FAPEG), the National Council for Scientific and Technological Development (CNPq), the Coordination for the Improvement for Higher Level Personnel (CAPES), Center of Excellence in Exponential Agriculture (CEAGRE), the Federal Institute of Education, Science, and Technology Goiano (IF Goiano)—Campus Rio Verde, and Federal Institute of Education, Science, and Technology of Mato Grosso (IFMT).

Data Availability Statement

All the data relevant to this manuscript are available on request from the corresponding author.

Acknowledgments

The authors express gratitude to the institutions mentioned in Funding part.

Conflicts of Interest

The authors declare no conflicts of interest. The funders had no role in the design of the study; in the collection, analyses, or interpretation of data; in the writing of the manuscript; or in the decision to publish the results.

References

1. Barreca, F. Sustainability in Food Production: A High-Efficiency Offshore Greenhouse. *Agronomy* **2024**, *14*, 518. [[Google Scholar](#)] [[CrossRef](#)]
2. Suzuki, L.E.A.S.; Casalinho, H.D.; Milani, I.C.B. Strategies and Public Policies for Soil and Water Conservation and Food Production in Brazil. *Soil Syst.* **2024**, *8*, 45. [[Google Scholar](#)] [[CrossRef](#)]
3. Shao, W.; Zhang, Z.; Guan, Q.; Yan, Y.; Zhang, J. Comprehensive assessment of land degradation in the arid and semiarid area based on the optimal land degradation index model. *CATENA* **2024**, *234*, 107563. [[Google Scholar](#)] [[CrossRef](#)]
4. Rai, G.K.; Magotra, I.; Khanday, D.M.; Choudhary, S.M.; Bhatt, A.; Gupta, V.; Rai, P.K.; Kumar, P. Boosting Drought Tolerance in Tomatoes through Stimulatory Action of Salicylic Acid Imparted Antioxidant Defense Mechanisms. *Agronomy* **2024**, *14*, 1227. [[Google Scholar](#)] [[CrossRef](#)]
5. Qu, H.-R.; Su, W.-H. Deep Learning-Based Weed–Crop Recognition for Smart Agricultural Equipment: A Review. *Agronomy* **2024**, *14*, 363. [[Google Scholar](#)] [[CrossRef](#)]
6. Luo, K.; He, D.; Guo, J.; Li, G.; Li, B.; Chen, X. Molecular Advances in Breeding for Durable Resistance against Pests and Diseases in Wheat: Opportunities and Challenges. *Agronomy* **2023**, *13*, 628. [[Google Scholar](#)] [[CrossRef](#)]
7. Greschuk, L.T.; Demattê, J.A.M.; Silvero, N.E.Q.; Rosin, N.A. A soil productivity system reveals most Brazilian agricultural lands are below their maximum potential. *Sci. Rep.* **2023**, *13*, 14103. [[Google Scholar](#)] [[CrossRef](#)]

8. Lamas, F.M. Artigo—A Produção Brasileira de Grãos—Salto Quantitativo. Embrapa Notícias. Available online: <https://www.embrapa.br/busca-de-noticias/-/noticia/84709032/artigo---a-producao-brasileira-de-graos--salto-quantitativo#:~:text=Estima%2Dse%20para%20o%20ano,distribui%C3%A7%C3%A3o%20de%20chuvas%20em%20outras> (accessed on 10 December 2004).
9. Companhia Nacional de Abastecimento (CONAB). Informações Agropecuárias da Superintendência Regional de Mato Grosso por meio do Setor de Apoio à Logística e Gestão da Oferta (SEGEO). Available online: <https://www.conab.gov.br/info-agro/analises-do-mercado-agropecuario-e-extrativista/analise-regional-do-mercado-agropecuario/analise-regional-mt-milho/item/23339-milho-analise-marco-2024> (accessed on 8 May 2024).
10. Machado, L. IMEA: Estimativas das Safras de Soja e Milho em Mato Grosso São Mantidas. *Sociedade Nacional de Agricultura*. Available online: <https://sna.agr.br/> (accessed on 3 May 2024).
11. Reis, S.A.D.; Leal, J.E.; Thomé, A.M.T. A Two-Stage Stochastic Linear Programming Model for Tactical Planning in the Soybean Supply Chain. *Logistics* **2023**, *7*, 49. [Google Scholar] [CrossRef]
12. Bordini, J.G.; Ono, M.A.; Hirozawa, M.T.; Garcia, G.T.; Vizoni, E.; Ono, E.Y.S. Safety of Corn and Corn-Based Products Intended for Human Consumption Concerning Fumonisin from a Brazilian Processing Plant. *Toxins* **2019**, *11*, 33. [Google Scholar] [CrossRef]
13. Nath, C.P.; Singh, R.G.; Choudhary, V.K.; Datta, D.; Nandan, R.; Singh, S.S. Challenges and Alternatives of Herbicide-Based Weed Management. *Agronomy* **2024**, *14*, 126. [Google Scholar] [CrossRef]
14. Nawoya, S.; Ssemakula, F.; Akol, R.; Geissmann, Q.; Karstoft, H.; Bjerger, K.; Mwikirize, C.; Katumba, A.; Gebreyesus, G. Computer vision and deep learning in insects for food and feed production: A review. *Comput. Electron. Agric.* **2024**, *216*, 108503. [Google Scholar] [CrossRef]
15. Fracarolli, J.A.; Pavarin, F.F.A.; Castro, W.; Blasco, J. Computer vision applied to food and agricultural products. *Rev. Ciênc. Agronômica* **2020**, *51*, e20207749. [Google Scholar] [CrossRef]

16. Zhai, Z.; Martínez, J.F.; Beltran, V.; Martínez, N.L. Decision support systems for agriculture 4.0: Survey and challenges. *Comput. Electron. Agric.* **2020**, *170*, 105256. [[Google Scholar](#)] [[CrossRef](#)]
17. Rehman, T.U.; Mahmud, M.S.; Chang, Y.K.; Jin, J.; Shin, J. Current and future applications of statistical machine learning algorithms for agricultural machine vision systems. *Comput. Electron. Agric.* **2019**, *156*, 585–605. [[Google Scholar](#)] [[CrossRef](#)]
18. Khaki, S.; Pham, H.; Wang, L. Simultaneous corn and soybean yield prediction from remote sensing data using deep transfer learning. *Sci. Rep.* **2021**, *11*, 11132. [[Google Scholar](#)] [[CrossRef](#)] [[PubMed](#)]
19. Sun, J.; Di, L.; Sun, Z.; Shen, Y.; Lai, Z. County-Level Soybean Yield Prediction Using Deep CNN-LSTM Model. *Sensors* **2019**, *19*, 4363. [[Google Scholar](#)] [[CrossRef](#)]
20. Kim, N.; Ha, K.-J.; Park, N.-W.; Cho, J.; Hong, S.; Lee, Y.-W. A Comparison Between Major Artificial Intelligence Models for Crop Yield Prediction: Case Study of the Midwestern United States, 2006–2015. *ISPRS Int. J. Geo-Inf.* **2019**, *8*, 240. [[Google Scholar](#)] [[CrossRef](#)]
21. Lu, W.; Du, R.; Niu, P.; Xing, G.; Luo, H.; Deng, Y.; Shu, L. Soybean Yield Preharvest Prediction Based on Bean Pods and Leaves Image Recognition Using Deep Learning Neural Network Combined with GRNN. *Front. Plant Sci.* **2022**, *12*, 791256. [[Google Scholar](#)] [[CrossRef](#)]
22. Bai, Y.; Yu, J.; Yang, S.; Ning, J. An improved YOLO algorithm for detecting flowers and fruits on strawberry seedlings. *Biosyst. Eng.* **2024**, *237*, 1–12. [[Google Scholar](#)] [[CrossRef](#)]
23. Ouhami, M.; Hafiane, A.; Es-Saady, Y.; El Hajji, M.; Canals, R. Computer Vision, IoT and Data Fusion for Crop Disease Detection Using Machine Learning: A Survey and Ongoing Research. *Remote Sens.* **2021**, *13*, 2486. [[Google Scholar](#)] [[CrossRef](#)]
24. Seal, A.K.E.A. SoyNet: Soybean leaf diseases classification. *Comput. Electron. Agric.* **2020**, *172*, 105342. [[Google Scholar](#)] [[CrossRef](#)]

25. Abbasi, R.; Martinez, P.; Ahmad, R. Crop diagnostic system: A robust disease detection and management system for leafy green crops grown in an aquaponics facility. *Artif. Intell. Agric.* **2023**, *10*, 1–12. [[Google Scholar](#)] [[CrossRef](#)]
26. Amarasingam, N.; Gonzalez, F.; Salgadoe, A.S.A.; Sandino, J.; Powell, K. Detection of White Leaf Disease in Sugarcane Crops Using UAV-Derived RGB Imagery with Existing Deep Learning Models. *Remote Sens.* **2022**, *14*, 6137. [[Google Scholar](#)] [[CrossRef](#)]
27. García-Navarrete, O.L.; Correa-Guimaraes, A.; Navas-Gracia, L.M. Application of Convolutional Neural Networks in Weed Detection and Identification: A Systematic Review. *Agriculture* **2024**, *14*, 568. [[Google Scholar](#)] [[CrossRef](#)]
28. Hasan, A.S.M.M.; Diepeveen, D.; Laga, H.; Jones, M.G.K.; Sohel, F. Object-level benchmark for deep learning-based detection and classification of weed species. *Crop Prot.* **2024**, *177*, 106561. [[Google Scholar](#)] [[CrossRef](#)]
29. Ahmed, A.M.A.E.K.R. Deep Learning for Detecting and Classifying the Growth Stages of *Consolida regalis* Weeds on Fields. *Agronomy* **2023**, *13*, 934. [[Google Scholar](#)] [[CrossRef](#)]
30. Park, Y.-H.; Choi, S.H.; Kwon, Y.-J.; Kwon, S.-W.; Kang, Y.J.; Jun, T.-H. Detection of Soybean Insect Pest and a Forecasting Platform Using Deep Learning with Unmanned Ground Vehicles. *Agronomy* **2023**, *13*, 477. [[Google Scholar](#)] [[CrossRef](#)]
31. Amrani, A.; Sohel, F.; Diepeveen, D.; Murray, D.; Jones, M.G.K. Insect detection from imagery using YOLOv3-based adaptive feature fusion convolution network. *Crop Pasture Sci.* **2023**, *74*, 615–627. [[Google Scholar](#)] [[CrossRef](#)]
32. Li, M.; Cheng, S.; Cui, J.; Li, C.; Li, Z.; Zhou, C.; Lv, C. High-Performance Plant Pest and Disease Detection Based on Model Ensemble with Inception Module and Cluster Algorithm. *Plants* **2023**, *12*, 200. [[Google Scholar](#)] [[CrossRef](#)]
33. Yadav, P.K.; Thomasson, J.A.; Searcy, S.W.; Hardin, R.G.; Braga-Neto, U.; Popescu, S.C.; Martin, D.E.; Rodriguez, R.; Meza, K.; Enciso, J.; et al. Computer Vision for Volunteer Cotton Detection in a Corn Field with UAS

- Remote Sensing Imagery and Spot Spray Applications. *arXiv* **2022**, arXiv:2207.07334. [**Google Scholar**]
34. Chamara, N.; Bai, G.; Ge, Y. AICropCAM: Deploying classification, segmentation, detection, and counting deep-learning models for crop monitoring on the edge. *Comput. Electron. Agric.* **2023**, *215*, 108420. [**Google Scholar**] [**CrossRef**]
 35. Teixeira, A.C.; Ribeiro, J.; Morais, R.; Sousa, J.J.; Cunha, A. A Systematic Review on Automatic Insect Detection Using Deep Learning. *Agriculture* **2023**, *13*, 713. [**Google Scholar**] [**CrossRef**]
 36. Kuzuhara, H.; Takimoto, H.; Sato, Y.; Kanagawa, A. Insect Pest Detection and Identification Method Based on Deep Learning for Realizing a Pest Control System. In Proceedings of the 2020 59th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE), Chiang Mai, Thailand, 23–26 September 2020; pp. 709–714. [**Google Scholar**] [**CrossRef**]
 37. Hu, Y.; Li, Z.; Lu, Z.; Jia, X.; Wang, P.; Liu, X. Identification Method of Crop Aphids Based on Bionic Attention. *Agronomy* **2024**, *14*, 1093. [**Google Scholar**] [**CrossRef**]
 38. Xia, Y.; Wang, Z.; Cao, Z.; Chen, Y.; Li, L.; Chen, L.; Zhang, S.; Wang, C.; Li, H.; Wang, B. Recognition Model for Tea Grading and Counting Based on the Improved YOLOv8n. *Agronomy* **2024**, *14*, 1251. [**Google Scholar**] [**CrossRef**]
 39. Su, X.; Zhang, J.; Ma, Z.; Dong, Y.; Zi, J.; Xu, N.; Zhang, H.; Xu, F.; Chen, F. Identification of Rare Wildlife in the Field Environment Based on the Improved YOLOv5 Model. *Remote Sens.* **2024**, *16*, 1535. [**Google Scholar**] [**CrossRef**]
 40. Rustia, D.J.A.; Lee, W.-C.; Lu, C.-Y.; Wu, Y.-F.; Shih, P.-Y.; Chen, S.-K.; Chung, J.-Y.; Lin, T.-T. Edge-based wireless imaging system for continuous monitoring of insect pests in a remote outdoor mango orchard. *Comput. Electron. Agric.* **2023**, *211*, 108019. [**Google Scholar**] [**CrossRef**]
 41. Zhang, T.; Zhou, J.; Liu, W.; Yue, R.; Yao, M.; Shi, J.; Hu, J. Seedling-YOLO: High-Efficiency Target Detection Algorithm for Field Broccoli Seedling Transplanting Quality Based on YOLOv7-Tiny. *Agronomy* **2024**, *14*, 931. [**Google Scholar**] [**CrossRef**]

42. Sheikh, M.; Iqra, F.; Ambreen, H.; Pravin, K.A.; Ikra, M.; Chung, Y.S. Integrating artificial intelligence and high-throughput phenotyping for crop improvement. *J. Integr. Agric.* **2024**, *23*, 1787–1802. [[Google Scholar](#)] [[CrossRef](#)]
43. Pokhariyal, S.; Patel, N.R.; Govind, A. Machine Learning-Driven Remote Sensing Applications for Agriculture in India—A Systematic Review. *Agronomy* **2023**, *13*, 2302. [[Google Scholar](#)] [[CrossRef](#)]
44. Bellido-Jiménez, J.A.; Estévez, J.; Vanschoren, J.; García-Marín, A.P. AgroML: An Open-Source Repository to Forecast Reference Evapotranspiration in Different Geo-Climatic Conditions Using Machine Learning and Transformer-Based Models. *Agronomy* **2022**, *12*, 656. [[Google Scholar](#)] [[CrossRef](#)]
45. Wang, D.; Liu, G.; Xu, Y. Information asymmetry in the graph model of conflict resolution and its application to the sustainable water resource utilization conflict in Niangziguan Springs Basin. *Expert Syst. Appl.* **2024**, *237*, 121409. [[Google Scholar](#)] [[CrossRef](#)]
46. Cravero, A.; Pardo, S.; Sepúlveda, S.; Muñoz, L. Challenges to Use Machine Learning in Agricultural Big Data: A Systematic Literature Review. *Agronomy* **2022**, *12*, 748. [[Google Scholar](#)] [[CrossRef](#)]
47. Diaz-Gonzalez, F.A.; Vuelvas, J.; Correa, C.A.; Vallejo, V.E.; Patino, D. Machine learning and remote sensing techniques applied to estimate soil indicators—Review. *Ecol. Indic.* **2022**, *135*, 108517. [[Google Scholar](#)] [[CrossRef](#)]
48. Lu, Y.; Young, S. A survey of public datasets for computer vision tasks in precision agriculture. *Comput. Electron. Agric.* **2020**, *178*, 105760. [[Google Scholar](#)] [[CrossRef](#)]
49. Verma, S.; Tripathi, S.; Singh, A.; Ojha, M.; Saxena, R.R. Insect Detection and Identification using YOLO Algorithms on Soybean Crop. In Proceedings of the TENCON 2021—2021 IEEE Region 10 Conference (TENCON), Auckland, New Zealand, 7–10 December 2021; pp. 272–277. [[Google Scholar](#)] [[CrossRef](#)]
50. Zhang, H.; Zhao, S.; Song, Y.; Ge, S.; Liu, D.; Yang, X.; Wu, K. A deep learning and Grad-Cam-based approach for accurate identification of the fall

- armyworm (*Spodoptera frugiperda*) in maize fields. *Comput. Electron. Agric.* **2022**, *202*, 107440. [Google Scholar] [CrossRef]
51. Tirkey, D.; Singh, K.K.; Tripathi, S. Performance analysis of AI-based solutions for crop disease identification, detection, and classification. *Smart Agric. Technol.* **2023**, *5*, 100238. [Google Scholar] [CrossRef]
 52. Redmon, J.; Divvala, S.; Girshick, R.; Farhadi, A. You Only Look Once: Unified, Real-Time Object Detection. In Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 27–30 June 2016; pp. 779–788. [Google Scholar] [CrossRef]
 53. Badgujar, C.M.; Poullose, A.; Gan, H. Agricultural object detection with You Only Look Once (YOLO) Algorithm: A bibliometric and systematic literature review. *Comput. Electron. Agric.* **2024**, *223*, 109090. [Google Scholar] [CrossRef]
 54. Tang, Z.; Lu, J.; Chen, Z.; Qi, F.; Zhang, L. Improved Pest-YOLO: Real-time pest detection based on efficient channel attention mechanism and transformer encoder. *Ecol. Inform.* **2023**, *78*, 102340. [Google Scholar] [CrossRef]
 55. Costa, E.N.; Fernandes, M.G.; Reis, L.C.; Martins, L.O.; Foresti, A.C.; de Paula Quintão Scalon, S. Above- and belowground resistance in Brazilian maize varieties under attack of *Spodoptera frugiperda* and *Diabrotica speciosa*. *Entomol. Exp. Appl.* **2022**, *170*, 718–726. [Google Scholar] [CrossRef]
 56. de Camargo Barros, G.S.; de Miranda, S.H.G.; Osaki, M.; Alves, L.R.A.A.; de Oliveira Adami, A.; Nishikawa, M.E. Efeito do não Tratamento de Pragas e Doenças Sobre Preços ao Consumidor de Produtos da Cadeia Produtiva do Milho. CEPEA—Centro de Estudos Avançados em Economia Aplicada, Cepea|Avaliação do Impacto Econômico De Pragas E Doenças|Parte 2, June 2019. Available online: https://www.cepea.esalq.usp.br/upload/kceditor/files/Cepea_EstudoPragaseDoencas_Parte%202.pdf (accessed on 10 January 2024).
 57. de Camargo Barros, G.S.; de Miranda, S.H.G.; Osaki, M.; Alves, L.R.A.A.; de Oliveira Adami, A.; Nishikawa, M.E. Mensuração Econômica da Incidência de Pragas e Doenças no Brasil: Uma Aplicação Para as Culturas de Soja, Milho e Algodão. CEPEA—Centro de Estudos Avançados em Economia Aplicada,

CEPEA|Avaliação Do Impacto Econômico de Pragas e Doenças|Parte 1, June 2019. Available online:

https://www.cepea.esalq.usp.br/upload/kceditor/files/Cepea_EstudoPragaseDoencas_Parte%201.pdf (accessed on 10 January 2024).

58. Marengoni, R.R.E.M. A Survey of Transfer Learning for Convolutional Neural Networks. In Proceedings of the 2019 32nd SIBGRAPI Conference on Graphics, Patterns and Images Tutorials (SIBGRAPI-T), Rio de Janeiro, Brazil, 28–31 October 2019; pp. 47–57. [**Google Scholar**] [**CrossRef**]
59. Han, X.; Zhang, Z.; Ding, N.; Gu, Y.; Liu, X.; Huo, Y.; Qiu, J.; Yao, Y.; Zhang, A.; Zhang, L.; et al. Pre-trained models: Past, present and future. *AI Open* **2021**, *2*, 225–250. [**Google Scholar**] [**CrossRef**]
60. Iman, M.; Arabnia, H.R.; Rasheed, K. A Review of Deep Transfer Learning and Recent Advancements. *Technologies* **2023**, *11*, 40. [**Google Scholar**] [**CrossRef**]
61. Guo, Y.; Shi, H.; Kumar, A.; Grauman, K.; Rosing, T.; Feris, R. SpotTune: Transfer Learning through Adaptive Fine-tuning. *arXiv* **2018**, arXiv:1811.08737. [**Google Scholar**]
62. Badgujar, C.M.; Armstrong, P.R.; Gerken, A.R.; Pordesimo, L.O.; Campbell, J.F. Real-time stored product insect detection and identification using deep learning: System integration and extensibility to mobile platforms. *J. Stored Prod. Res.* **2023**, *104*, 102196. [**Google Scholar**] [**CrossRef**]
63. Kim, D.-J.S.E.J.-J. A Deep Learning Framework Performance Evaluation to Use YOLO in Nvidia Jetson Platform. *Appl. Sci.* **2022**, *12*, 3734. [**Google Scholar**] [**CrossRef**]
64. Lim, S.-H.; Kang, S.-H.; Ko, B.-H.; Roh, J.; Lim, C.; Cho, S.-Y. An Integrated Analysis Framework of Convolutional Neural Network for Embedded Edge Devices. *Electronics* **2022**, *11*, 1041. [**Google Scholar**] [**CrossRef**]
65. Mignoni, M.E.; Honorato, A.; Kunst, R.; Righi, R.; Massuquetti, A. Soybean images dataset for caterpillar and *Diabrotica speciosa* pest detection and classification. *Data Brief* **2022**, *40*, 107756. [**Google Scholar**] [**CrossRef**] [**PubMed**]

66. Marques, G.B.C.; Ávila, C.J.; Parra, J.R.P. Danos Causados Por Larvas E Adultos De *Diabrotica Speciosa* (Coleoptera: Chrysomelidae) Em Milho. *Pesqui. Agropecu. Bras.* **1999**, *34*, 1983–1986. [[Google Scholar](#)] [[CrossRef](#)][[Green Version](#)]
67. Tetila, E.C.; da Silveira, F.A.G.; da Costa, A.B.; Amorim, W.P.; Astolfi, G.; Pistori, H.; Barbedo, J.G.A. YOLO performance analysis for real-time detection of soybean pests. *Smart Agric. Technol.* **2024**, *7*, 100405. [[Google Scholar](#)] [[CrossRef](#)]
68. de Oliveira, C.M.; Frizzas, M.R. Eight Decades of *Dalbulus maidis* (DeLong & Wolcott) (Hemiptera, Cicadellidae) in Brazil: What We Know and What We Need to Know. *Neotrop. Entomol.* **2022**, *51*, 1–17. [[Google Scholar](#)] [[CrossRef](#)]
69. Oliveira, C.M.; Molina, R.M.S.; Albres, R.S.; Lopes, J.R.S. Disseminação De Molícutes Do Milho A Longas Distâncias Por *Dalbulus Maidis* (Hemiptera: Cicadellidae). *Fitopatol. Bras.* **2002**, *27*, 91–95. [[Google Scholar](#)] [[CrossRef](#)]
70. Perini, C.R.; do Nascimento Machado, D. Application periods against *diceraeus* (*dichelops*) *melacanthus* on maize and their significant response on damage and grain yield in the Brazilian Midwest. *Crop Prot.* **2023**, *172*, 106344. [[Google Scholar](#)] [[CrossRef](#)]
71. Fernandes, M.G.; Costa, E.N.; Mota, T.A.; Alegre, E.A.; de Sousa, M.F.; Lourenção, A.L.F. Spatial distribution and sequential sampling plan for *Diceraeus melacanthus* (Hemiptera: Pentatomidae) in maize at the vegetative stage. *Crop Prot.* **2022**, *157*, 105988. [[Google Scholar](#)] [[CrossRef](#)]
72. Bueno, A.d.F.; Sutil, W.P.; Jahnke, S.M.; Carvalho, G.A.; Cingolani, M.F.; Colmenarez, Y.C.; Corniani, N. Biological Control as Part of the Soybean Integrated Pest Management (IPM): Potential and Challenges. *Agronomy* **2023**, *13*, 2532. [[Google Scholar](#)] [[CrossRef](#)]
73. de Queiroz, A.P.; Gonçalves, J.; da Silva, D.M.; Panizzi, A.R.; de Freitas Bueno, A. *Diceraeus melacanthus* (Dallas) (Hemiptera: Pentatomidae) development, preference for feeding and oviposition related to different food sources. *Rev. Bras. Entomol.* **2022**, *66*, e20220038. [[Google Scholar](#)] [[CrossRef](#)]

74. Triboni, Y.B.; Del Bem Junior, L.; Raetano, C.G.; Negrisoli, M.M. Effect of seed treatment with insecticides on the control of *Spodoptera frugiperda* (J. E. Smith) (Lepidoptera: Noctuidae) in soybean. *Arq. Inst. Biol.* **2019**, *86*, e0332018. [[Google Scholar](#)] [[CrossRef](#)]
75. de Araújo, W.A.; Degrande, P.E.; Malaquias, J.B.; Silvie, P.J.; Scoton, A.M.N.; da Silva Pachú, J.K. Cut off Behavior of *Spodoptera frugiperda* (Smith, 1797) (Lepidoptera: Noctuidae) in Soybean (*Glycine max* (L.) Merrill) Seedlings. *Braz. Arch. Biol. Technol.* **2023**, *66*, e23220386. [[Google Scholar](#)] [[CrossRef](#)]
76. Jaramillo-Barrios, C.I.; Quijano, E.B.; Andrade, B.M. Populations of *Spodoptera frugiperda* (Lepidoptera: Noctuidae) cause significant damage to genetically modified corn crops. *Rev. Fac. Nac. Agron.-MedellÃ-N* **2019**, *72*, 8953–8962. [[Google Scholar](#)] [[CrossRef](#)]
77. iNaturalist Contributors, iNaturalist. iNaturalist Research-Grade Observations. iNaturalist.org. 2024. Available online: <https://www.inaturalist.org/observations> (accessed on 8 January 2024).
78. Wang, C.; Grijalva, I.; Caragea, D.; McCornack, B. Detecting common coccinellids found in sorghum using deep learning models. *Sci. Rep.* **2023**, *13*, 9748. [[Google Scholar](#)] [[CrossRef](#)]
79. Prasetyo, E.; Suciati, N.; Fatichah, C. A Comparison of YOLO and Mask R-CNN for Segmenting Head and Tail of Fish. In Proceedings of the 2020 4th International Conference on Informatics and Computational Sciences (ICICoS), Semarang, Indonesia, 10–11 November 2020; pp. 1–6. [[Google Scholar](#)] [[CrossRef](#)]
80. Tan, L.; Huangfu, T.; Wu, L.; Chen, W. Comparison of RetinaNet, SSD, and YOLO v3 for real-time pill identification. *BMC Med. Inform. Decis. Mak.* **2021**, *21*, 324. [[Google Scholar](#)] [[CrossRef](#)]
81. Tkachenko, M.; Malyuk, M.; Holmanyuk, A.; Liubimov, N. Label Studio: Data Labeling Software. 2020. Available online: <https://github.com/heartexlabs/label-studio> (accessed on 15 December 2023).
82. Butt, M.; Glas, N.; Monsuur, J.; Stoop, R.; de Keijzer, A. Application of YOLOv8 and Detectron2 for Bullet Hole Detection and Score Calculation from Shooting Cards. *AI* **2024**, *5*, 72–90. [[Google Scholar](#)] [[CrossRef](#)]

83. Pham, V.; Pham, C.; Dang, T. Road Damage Detection and Classification with Detectron2 and Faster R-CNN. In Proceedings of the 2020 IEEE International Conference on Big Data (Big Data), Atlanta, GA, USA, 10–13 December 2020. **[Google Scholar]**
84. Routis, G.; Michailidis, M.; Roussaki, I. Plant Disease Identification Using Machine Learning Algorithms on Single-Board Computers in IoT Environments. *Electronics* **2024**, *13*, 1010. **[Google Scholar]** **[CrossRef]**
85. Haq, S.I.U.; Raza, A.; Lan, Y.; Wang, S. Identification of Pest Attack on Corn Crops Using Machine Learning Techniques. *Eng. Proc.* **2023**, *56*, 183. **[Google Scholar]** **[CrossRef]**
86. Li, P.; Wang, X.; Huang, K.; Huang, Y.; Li, S.; Iqbal, M. Multi-Model Running Latency Optimization in an Edge Computing Paradigm. *Sensors* **2022**, *22*, 6097. **[Google Scholar]** **[CrossRef]** **[PubMed]**
87. Parra, D.; Sanabria, D.E.; Camargo, C. A Methodology and Open-Source Tools to Implement Convolutional Neural Networks Quantized with TensorFlow Lite on FPGAs. *Electronics* **2023**, *12*, 4367. **[Google Scholar]** **[CrossRef]**
88. Ahmad, I.; Yang, Y.; Yue, Y.; Ye, C.; Hassan, M.; Cheng, X.; Wu, Y.; Zhang, Y. Deep Learning Based Detector YOLOv5 for Identifying Insect Pests. *Appl. Sci.* **2022**, *12*, 10167. **[Google Scholar]** **[CrossRef]**
89. Kunduraci, D.O.E.M.S. Comparison of Deep Learning Techniques for Classification of the Insects in Order Level With Mobile Software Application. *IEEE Access* **2022**, *10*, 35675–35684. **[Google Scholar]** **[CrossRef]**
90. Zhang, L.; Ding, G.; Li, C.; Li, D. DCF-Yolov8: An Improved Algorithm for Aggregating Low-Level Features to Detect Agricultural Pests and Diseases. *Agronomy* **2023**, *13*, 2012. **[Google Scholar]** **[CrossRef]**
91. Seidaliyeva, U.; Ilipbayeva, L.; Taissariyeva, K.; Smailov, N.; Matson, E.T. Advances and Challenges in Drone Detection and Classification Techniques: A State-of-the-Art Review. *Sensors* **2024**, *24*, 125. **[Google Scholar]** **[CrossRef]**
92. Almalky, A.M.; Ahmed, K.R.; Guzel, M.; Turan, B. An Efficient Deep Learning Technique for Detecting and Classifying the Growth of Weeds on Fields. In Proceedings of the Future Technologies Conference (FTC) 2022; Springer

International Publishing: Cham, Switzerland, 2023; Volume 2, pp. 818–835.

[**Google Scholar**]

93. Wengert, M.; Piepho, H.-P.; Astor, T.; Graß, R.; Wijesingha, J.; Wachendorf, M. Assessing Spatial Variability of Barley Whole Crop Biomass Yield and Leaf Area Index in Silvoarable Agroforestry Systems Using UAV-Borne Remote Sensing. *Remote Sens.* **2021**, *13*, 2751. [**Google Scholar**] [**CrossRef**]
94. Choudhury, B.U.; Divyanth, L.G.; Chakraborty, S. Land use/land cover classification using hyperspectral soil reflectance features in the Eastern Himalayas, India. *CATENA* **2023**, *229*, 107200. [**Google Scholar**] [**CrossRef**]
95. Markoulidakis, I.; Rallis, I.; Georgoulas, I.; Kopsiaftis, G.; Doulamis, A.; Doulamis, N. Multiclass Confusion Matrix Reduction Method and Its Application on Net Promoter Score Classification Problem. *Technologies* **2021**, *9*, 81. [**Google Scholar**] [**CrossRef**]
96. Farhadpour, S.; Warner, T.A.; Maxwell, A.E. Selecting and Interpreting Multiclass Loss and Accuracy Assessment Metrics for Classifications with Class Imbalance: Guidance and Best Practices. *Remote Sens.* **2024**, *16*, 533. [**Google Scholar**] [**CrossRef**]
97. Zhang, C.; Hu, Z.; Xu, L.; Zhao, Y. A YOLOv7 incorporating the Adan optimizer based corn pests identification method. *Front. Plant Sci.* **2023**, *14*, 1174556. [**Google Scholar**] [**CrossRef**]
98. Yang, S.; Xing, Z.; Wang, H.; Dong, X.; Gao, X.; Liu, Z.; Zhang, X.; Li, S.; Zhao, Y. Maize-YOLO: A New High-Precision and Real-Time Method for Maize Pest Detection. *Insects* **2023**, *14*, 278. [**Google Scholar**] [**CrossRef**]
99. Kumar, N.; Nagarathna; Flammini, F. YOLO-Based Light-Weight Deep Learning Models for Insect Detection System with Field Adaption. *Agriculture* **2023**, *13*, 741. [**Google Scholar**] [**CrossRef**]
100. Bjerger, K.; Alison, J.; Dyrmann, M.; Frigaard, C.E.; Mann, H.M.R.; Høye, T.T. Accurate detection and identification of insects from camera trap images with deep learning. *PLoS Sustain. Transform.* **2023**, *2*, 1–18. [**Google Scholar**] [**CrossRef**]

101. Sun, G.; Liu, S.; Luo, H.; Feng, Z.; YanQuantidadeMigratory Pests Based on Searchlight Trap and Machine Vision. *Front. Plant Sci.* **2022**, *13*, 897739. [Google Scholar] [CrossRef]
102. Slim, S.O.; Abdelnaby, I.A.; Moustafa, M.S.; Zahran, M.B.; Dahi, H.F.; Yones, M.S. Smart insect monitoring based on YOLOV5 case study: Mediterranean fruit fly *Ceratitis capitata* and Peach fruit fly *Bactrocera zonata*. *Egypt. J. Remote Sens. Space Sci.* **2023**, *26*, 881–891. [Google Scholar] [CrossRef]
103. Ye, J.L.E.J. Edge-YOLO: Lightweight Infrared Object Detection Method Deployed on Edge Devices. *Appl. Sci.* **2023**, *13*, 4402. [Google Scholar] [CrossRef]

4 CAPÍTULO II

AGROINSECT: A Curated Image Dataset for Deep Learning–Based Detection and Identification of Agricultural Insect Pests

Authors

Guilherme Pires Silva de Almeida *
 Leonardo Nazário Silva dos Santos
 Marconi Batista Teixeira
 Jéssica Lauanda Stirle
 Heyde Francielle do Carmo França
 Mario de Oliveira
 Ruy de Oliveira
 Sergio Novak
 Adriano Soares de Oliveira Bailão
 Pablo da Costa Gontijo

Affiliations Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso (IFMT), Cuiabá 78005-200, Brazil

Instituto Federal de Educação, Ciência e Tecnologia do Espírito Santo (IFES), Santa Teresa 29660-000, Brazil

Instituto Federal Goiano (IFGoiano), Campus Rio Verde, Rio Verde 75901-970, Brazil

Department of Engineering, Birmingham City University, Birmingham B4 7XG, UK

Corresponding author's email address and Twitter handle

guilherme.almeida@ifmt.edu.br

Keywords

Dataset, digital agriculture, pest management, artificial intelligence, computer vision, data curation.

Abstract

Agriculture 4.0 relies on the integration of advanced digital technologies to increase the efficiency, speed, and reliability of agricultural processes. In this context, the AgroInsect dataset was developed to support research in machine learning and computer vision applied to pest management. The dataset consists of high-resolution images and their corresponding annotations, enabling the use of deep learning approaches, such as convolutional neural networks, for object detection tasks and classification of insect pests. Initially, the AgroInsect dataset includes four economically relevant species for soybean and maize crops (*Spodoptera Frugiperda*, *Diceraeus spp.*, *Dalbulus Maidis*, and *Diabrotica Speciosa*), with potential for expansion in future versions. The dataset is integrated into the AgroLabIA web application, which enables the creation and storage of annotations, as well as the export of images and their corresponding labels in multiple

formats, providing flexibility for training a wide range of artificial intelligence models and contributing to advances in applied agricultural pest management.

SPECIFICATIONS TABLE

Subject	Computer Sciences
Specific subject area	Computer Vision, Deep Learning, and Precision Agriculture for Insect Pest Detection
Type of data	The dataset is distributed as a .rar archive containing .jpg images and corresponding .txt annotation files in YOLO format
Data collection	The AGROINSECT dataset was collected from three sources: public images obtained from the iNaturalist [1,2] and GBIF databases, and field images captured by the authors using digital cameras under natural lighting conditions. Images were selected based on visual quality and confirmed species identification. Only insect species with economic relevance to maize and soybean crops were included. All images were manually annotated using Label Studio software, generating bounding-box labels in YOLO format. No data normalization was applied.
Data source location	Fazenda Serra Azul, Manzagão, Nobres, MT, Brazil, Global (iNaturalist and GBIF databases)
Data accessibility	Repository name: Mendeley Data Data identification number: 10.17632/4jyp4m9gxj.1 Direct URL to data: https://data.mendeley.com/datasets/4jyp4m9gxj/2 Direct URL to data: https://agrolabia.com.br
Related research article	de Almeida, G.P.S.; dos Santos, L.N.S.; da Silva Souza, L.R.; da Costa Gontijo, P.; de Oliveira, R.; Teixeira, M.C.; de Oliveira, M.; Teixeira, M.B.; do Carmo França, H.F. Performance Analysis of YOLO and Detectron2 Models for Detecting Corn and Soybean Pests Employing Customized Dataset. <i>Agronomy</i> 2024, 14(10), 2194. https://doi.org/10.3390/agronomy14102194

VALUE OF THE DATA

The availability of high-quality public datasets remains a major challenge in digital agriculture, limiting the development and validation of computer vision models for pest detection. The AGROINSECT dataset addresses this gap by providing curated images and corresponding annotations suitable for training deep learning models,

particularly those from the YOLO family, widely adopted in agricultural monitoring applications.

The dataset has already supported peer-reviewed scientific research, demonstrating its applicability in real-world agricultural scenarios. Its annotations were produced through a structured curation process, ensuring consistency and reliability for machine learning tasks. The dataset is distributed in formats compatible with multiple computer vision frameworks, enabling its reuse in studies focused on object detection, classification, and real-time monitoring systems.

By focusing on insect pests of high economic relevance to maize and soybean crops in Brazil, the dataset contributes to the development of practical and scalable solutions for pest management, with potential benefits for precision agriculture research at both local and global scales.

BACKGROUND

The dataset was compiled as a research on image-based detection of insect pests in agricultural environments, where the availability of annotated datasets remains limited, particularly for crops of high economic importance such as maize and soybean. Advances in deep learning and computer vision, especially object detection architectures including YOLO and Detectron2, increased the need for datasets that represent real field conditions and support method development and evaluation.

The images were collected to support methodological studies focused on training and benchmarking deep learning models for insect pest detection. Data acquisition combined images obtained from public biodiversity repositories with images captured in agricultural fields, aiming to represent variations in lighting conditions, backgrounds, insect poses, and image quality commonly observed in crop monitoring scenarios.

This data article is related to a previously published research article that investigated the performance of object detection models for identifying insect pests in maize and soybean crops. While the research article focused on model training, evaluation, and deployment aspects, the present data article provides a detailed and standalone description of the dataset, including data sources, organization, and annotation procedures, thereby supporting transparency, reproducibility, and reuse of the data in future studies [3].

DATA DESCRIPTION

The AGROINSECT dataset contains 1,510 RGB images of agricultural insect pests stored in .jpg format, along with 1,510 corresponding annotation files stored in .txt format following the YOLO bounding-box annotation scheme. Across the entire dataset, a total of 1,654 insect objects were annotated. Each annotation file may contain one or more object entries when multiple insect individuals are present in a single image.

All image and annotation files were stored within a single directory structure in the repository. Image files and annotation files share identical filenames to ensure a direct correspondence between images and their labels.

The dataset includes four insect species of agricultural relevance: *Diabrotica speciosa*, *Dalbulus maidis*, *Diceraeus* spp., and *Spodoptera frugiperda*. Figure 1 presents representative examples of the four species included in the dataset.




Figure 1. Representative insect species included in the AGROINSECT dataset: (a) *Diabrotica speciosa*, (b) *Dalbulus Maidis*, (c) *Diceraeus* spp., and (d) *Spodoptera Frugiperda*.

Annotations were manually created using the open-source software Label Studio [4], where each visible insect individual was treated as a separate object and delineated using a bounding box. The annotation files encode the class label and normalized bounding-box coordinates according to the YOLO format specification.

Table 1 summarizes the distribution of images, annotation files, and annotated insect objects across the four species. When more than one insect individual appears in a single image, each individual is represented as an independent object within the corresponding annotation file.

Tabela 1. Division of datasets for each insect class and their annotations for training and evaluation of deep-learning models.

Dataset	Classes					Total
		<i>Diabrotica speciosa</i>	<i>Dalbulus maidis</i>	<i>Diceraeus ssp.</i>	<i>Spodoptera frugiperda</i>	
Agroinsect	Image	591	177	248	334	1350
	Annotation	599	280	257	358	1494
Reduced	Image	100	100	100	100	400
	Annotation	100	156	104	102	462
Validation	Image	15	15	15	15	60
	Annotation	15	15	15	15	60
Test	Image	25	25	25	25	100
	Annotation	25	25	25	25	100

Source: Adapted from Almeida et al. (2024).

EXPERIMENTAL DESIGN, MATERIALS AND METHODS

The AGROINSECT dataset was compiled from a combination of field-collected images acquired in agricultural areas and publicly available images obtained from the iNaturalist and GBIF databases [2]. Field images were collected in commercial crop fields and experimental farms located in the state of Mato Grosso, Brazil. All images were captured under natural field conditions using RGB cameras, preserving variations in background, illumination, insect pose, and scale [5,6].

Following data acquisition, all images were manually annotated using the open-source software Label Studio. Each insect individual visible in an image was treated as a separate object and delineated using a bounding box, with annotations exported according

to the YOLO format specification [7]. Images containing multiple insect individuals were annotated with multiple object entries within a single annotation file.

After the annotation process, the labeled images and corresponding annotation files were imported into a dedicated dataset management platform named LabAgroIA, a robust software application developed to support image submission, curation, validation, and controlled access under a client–server architecture. The back end of LabAgroIA was implemented using Node.js [8], with authentication based on JSON Web Token (JWT) [9] to ensure secure access, data integrity, and traceability. The MVVM (Model–View–ViewModel) [10] architectural pattern was adopted to promote modularity and scalability.

The front end was developed using the React framework, with Redux [11] employed for state management to ensure consistent interaction with data throughout the curation workflow. Data storage is managed using a MySQL [12] relational database hosted on a Linux server, ensuring robustness and availability for large volumes of image data and metadata.

A structured curation and validation workflow was applied to ensure dataset quality. Each annotated image was independently reviewed by two specialists with expertise in the respective insect species. Only images and annotations approved by both evaluators were incorporated into the final dataset and released for research use. This dual-review strategy reduces labeling errors and improves annotation consistency for computer vision applications.

The AGROINSECT dataset has been employed in peer-reviewed studies investigating deep learning–based object detection approaches for agricultural pest monitoring. However, the present data article focuses exclusively on describing the data acquisition procedures, annotation methodology, curation workflow, and dataset organization, without reporting experimental results or model performance evaluations.

LIMITATIONS

Although the AGROINSECT dataset constitutes a relevant resource for research in digital agriculture, some limitations should be acknowledged. First, the dataset is currently restricted to four insect species of agricultural importance, which may limit its applicability for studies targeting a broader range of pests or different taxonomic groups.

Second, the images were collected from heterogeneous sources, including field acquisitions and public repositories, resulting in variability in the image characteristics such as illumination conditions, background complexity, insect scale, and camera perspective. While this variability reflects realistic field scenarios, it may introduce class imbalance and visual heterogeneity that can affect downstream use.

Additionally, the dataset is geographically concentrated in Brazilian agricultural regions, particularly in the state of Mato Grosso. As a result, environmental and crop-specific characteristics may not fully represent other agricultural contexts or climatic conditions.

Finally, although a dual-review curation process was adopted to ensure annotation quality, the dataset size remains limited when compared to large-scale benchmarks commonly used in computer vision research. Future extensions incorporating additional species, regions, and acquisition conditions could further enhance the generalizability and reuse potential of the dataset.

ETHICS STATEMENT

The authors confirm that they have read and complied with the ethical requirements for publication in *Data in Brief*. The present work does not involve human subjects, animal experiments, or data collected from social media platforms.

CRedit AUTHOR STATEMENT

Guilherme Pires Silva de Almeida: Conceptualization, Data curation, Methodology, Software, Writing – original draft, Project administration.

Leonardo Nazário Silva dos Santos: Methodology, Supervision, Data curation, Investigation, Validation.

Marconi Batista Teixeira: Methodology, Supervision, Writing – review & editing.

Jéssica Lauanda Stirle: Investigation, Data curation, Validation.

Heyde Francielle do Carmo França: Supervision, Funding acquisition, Writing – review & editing.

Mario de Oliveira: Resources, Field data collection.

Ruy de Oliveira: Resources, Field data collection.

Sergio Novak: Formal analysis, Writing – review & editing.

Adriano Soares de Oliveira Bailão: Formal analysis, Writing – review & editing.

Pablo da Costa Contijo: Software, Methodology, Writing – review & editing.

ACKNOWLEDGEMENTS

The authors gratefully acknowledge the Goiano Federal Institute of Education, Science and Technology (IF Goiano), the Mato Grosso Federal Institute of Education, Science and Technology (IFMT), and the Center of Excellence in Exponential Agriculture (CEAGRE) for providing institutional support and infrastructure that were essential for the development of this work.

FUNDING

This work was supported by the Ministry of Science, Technology and Innovation (MCTI), the Coordination for the Improvement of Higher Education Personnel (CAPES), the National Council for Scientific and Technological Development (CNPq), and the Foundation for Research Support of the State of Goiás (FAPEG).

DECLARATION OF COMPETING INTERESTS

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

REFERENCES

- [1] iNaturalist Contributors, iNaturalist Research-Grade Observations, iNaturalist.org, 2024. Available online: <https://www.inaturalist.org/observations> (accessed on 8 January 2024).
- [2] Wang, C.; Grijalva, I.; Caragea, D.; McCornack, B., Detecting common coccinellids found in sorghum using deep learning models, *Scientific Reports* 13 (2023) 9748.
- [3] Almeida, G.P.S. de; Santos, L.N.S. dos; Souza, L.R. da Silva; Gontijo, P. da Costa; Oliveira, R. de; Teixeira, M.C.; Oliveira, M. de; Teixeira, M.B.; França, H.F. do Carmo, Performance analysis of YOLO and Detectron2 models for detecting corn and soybean pests employing customized dataset, *Agronomy* 14 (10) (2024). <https://doi.org/10.3390/agronomy14102194>.
- [4] Heartex, Label Studio: The Open Source Data Labeling Tool, Version 1.12, 2025. Available online: <https://labelstud.io/> (accessed on 10 November 2025).
- [5] Lu, Y.; Young, S., A survey of publicly available datasets for computer vision tasks in precision agriculture, *Computers and Electronics in Agriculture* 178 (2020) 105760. <https://doi.org/10.1016/j.compag.2020.105760>.

- [6] Salehin, M.R.; Khan, U.; Habiba, N.H.; Badhon, N.N.; Moon, N., Bau-insectv2: An agricultural plant insect dataset for deep learning and biomedical image analysis, *Data in Brief* 53 (2024) 110083. <https://doi.org/10.1016/j.dib.2024.110083>.
- [7] Badgujar, C.M.; Poullose, A.; Gan, H., Agricultural object detection with the You Only Look Once (YOLO) algorithm: A bibliometric and systematic literature review, *Computers and Electronics in Agriculture* 223 (2024) 109090. <https://doi.org/10.1016/j.compag.2024.109090>.
- [8] OpenJS Foundation, Node.js: JavaScript Runtime Built on Chrome's V8 Engine, 2025. Available online: <https://nodejs.org/> (accessed on 10 November 2025).
- [9] Jones, M.B.; Bradley, J.; Panzer, N., JSON Web Token (JWT), RFC 7519, Internet Engineering Task Force (IETF), 2015. Available online: <https://datatracker.ietf.org/doc/html/rfc7519> (accessed on 10 November 2025).
- [10] Fowler, M., *Patterns of Enterprise Application Architecture*, Addison-Wesley, Boston, 2004.
- [11] Abramov, D.; Clark, A., *Redux: A Predictable State Container for JavaScript Apps*, 2025. Available online: <https://redux.js.org/> (accessed on 10 November 2025).
- [12] Oracle Corporation, *MySQL: The World's Most Popular Open Source Database*, 2025. Available online: <https://www.mysql.com/> (accessed on 10 November 2025).

5 CAPÍTULO III

MONITORAMENTO DE PRAGAS AGRÍCOLAS VIA SMARTPHONE COM IA EMBARCADA E MAPEAMENTO GEOESTATÍSTICO

Resumo: A rápida disseminação de pragas agrícolas e a falta de informações de campo em tempo oportuno continuam sendo grandes obstáculos para um manejo integrado de pragas eficiente. Este estudo apresenta o AgroInsect, um aplicativo para smartphone que integra um modelo de aprendizado profundo embarcado (YOLOv11n-TFLite) com mapeamento geoestatístico para apoiar o monitoramento em tempo real de pragas em lavouras de soja e milho. O sistema realiza a detecção diretamente no dispositivo para quatro espécies-chave de insetos-praga (*Diabrotica Speciosa*, *Dalbulus Maidis*, *Diceraeus* spp. e *Spodoptera Frugiperda*), extrai automaticamente metadados de geolocalização das imagens, valida a consistência espacial com base nos limites da propriedade agrícola e transmite as detecções para um banco de dados em nuvem. Mapas de calor e interpolações espaciais são gerados por meio da Krigagem Ordinária, implementada com a biblioteca PyKrig, permitindo visualizar a incidência das pragas ao longo da área monitorada. Os testes de campo demonstraram elevado desempenho de detecção, com acurácia global de 95,1%, F1-score superior a 0,94 para todas as espécies e apenas 1,1% de detecções falsas. O modelo de krigagem apresentou forte capacidade preditiva sob amostragem densa ($R^2 > 0,94$), reproduzindo padrões espaciais consistentes com o comportamento ecológico de cada espécie. O fluxo integrado, que combina detecção em tempo real, validação espacial e interpolação automatizada, mostrou-se robusto e operacionalmente viável em condições reais de campo. Os resultados destacam o AgroInsect como ferramenta prática e escalável para o monitoramento de pragas em agricultura de precisão, especialmente em áreas com conectividade limitada, contribuindo para tomada de decisão mais rápida e confiável no manejo integrado de pragas.

Palavras-chave: YOLOv11; TFLite; aprendizado profundo; detecção de pragas; krigagem; agricultura de precisão; mapa de calor; aplicação móvel.

5.1. Introdução

De acordo com a Organização das Nações Unidas para Alimentação e Agricultura (FAO), aproximadamente 40% das culturas alimentares mundiais são perdidas todos os anos devido a pragas e doenças, resultando em prejuízos estimados a cerca de US\$ 220 bilhões anuais para a economia global [1]. Estima-se que existam 70.000 espécies de pragas que podem causar danos às culturas agrícolas mundialmente, incluindo insetos, patógenos e ervas daninhas, com poder de gerar perdas que podem variar de 35% a 42% do potencial de produção [2]. Os valores investidos no controle das pragas por meio da utilização de defensivos agrícolas, a contaminação do meio ambiente e os problemas de saúde humana, ressaltam a necessidade de abordagens mais eficazes e sustentáveis no

controle das pragas [3, 4]. Apesar da quantidade de espécies de pragas existentes, esse estudo se concentra em 4 insetos pragas [5], *Diabrotica Speciosa*, *Dalbulus Maidis*, *Diceraeus ssp.* e *Spodoptera Frugiperda*. Os avanços em inteligência artificial têm impulsionado a utilização da computação no manejo integrado de pragas, uma vez que o controle manual é desafiador, podendo consumir muitos recursos e tempo [6].

Impulsionados pelo acesso a grandes conjuntos de dados rotulados e pelo fortalecimento da computação paralela via GPU (Unidade de Processamento Gráfico), o aprendizado profundo proporcionou avanços na área da visão computacional, permitindo um treinamento mais eficiente de redes neurais profundas. Além disso, aprimoramentos como a mitigação do gradiente de desaparecimento, novas técnicas de regularização e o desenvolvimento de *frameworks* como TensorFlow, Theano e MXNet facilitaram a prototipagem e otimização dos modelos. Esses fatores possibilitaram avanços notáveis em tarefas como detecção de objetos, rastreamento de movimento, reconhecimento de ações, estimativa de pose humana, segmentação semântica e previsões de rendimento de culturas [7, 8].

É um desafio fornecer aos agricultores informações precisas e em tempo hábil sobre a prevenção e o controle eficaz de pragas e doenças. A escassez de dados detalhados sobre os tipos de pragas e doenças, a extensão dos danos causados e os métodos apropriados de prevenção e controle apresentam desafios na implementação de estratégias baseadas na previsão e no monitoramento das condições das culturas [9]. Essa limitação compromete a capacidade de mitigar efetivamente os impactos negativos nas lavouras. Além disso, a discrepância entre a percepção das pessoas sobre pragas e doenças de culturas e a disponibilidade de avaliadores qualificados para realizar diagnósticos precisos tem se intensificado, evidenciando uma lacuna crítica no suporte técnico oferecido ao setor agrícola. Diante desse cenário, torna-se imprescindível o desenvolvimento de novos métodos para a identificação e o manejo de pragas e doenças, capazes de superar essas barreiras e promover uma gestão agrícola mais eficiente e sustentável [10].

A visão computacional, uma subárea da IA (Inteligência Artificial), traz avanços tecnológicos para a agricultura moderna [11, 12, 13]. A utilização dessas tecnologias permite trabalhar em alguns domínios de problemas proeminentes nas fases de manejo da produção agrícola, no manejo do solo, plantio, controle de insetos pragas e ervas daninhas, crescimento das plantas, irrigação e colheita [14, 15, 16, 17, 18].

Karar *et al.* (2021) desenvolveram um aplicativo móvel para detecção e classificação de pragas de colheitas com base no Faster R-CNN e no sistema de computação em nuvem, para classificar 5 pragas: *Aphids*, *Flea Beetles*, *Cicadellidae* e *Flax budworm*. O sistema criado conseguiu classificar com sucesso as pragas agrícolas [9], o processamento desse sistema ocorre remotamente, em um servidor na nuvem. Contudo, essa arquitetura de projeto pode gerar prejuízo na indisponibilidade das informações, quando a conexão com servidor falhar e não conseguir entregar para a aplicação o resultado processado. Essa problemática já foi relatada em outros sistemas de detecção [19]. Outro exemplo é o sistema de detecção de doenças em plantas, que buscou tratar essa indisponibilidade [20].

Wang *et al.*(2025) criaram o sistema chamado Insect-YOLO. Foi realizado uma pesquisa utilizando um modelo YOLOv8m de aprendizado profundo aprimorado com um módulo *Convolutional Block Attention Module* (CBAM), que permite refinar mapas de características para destacar regiões de interesse, melhorando a capacidade de detectar pragas pequenas ou oclusas em imagens de baixa resolução. Foi relatado limitações com relação às variações de tamanho, forma e cor de pragas da mesma espécie em imagens em tempo real, dificultando o processo de rotulagem. Apesar da vantagem de utilizar imagens de baixa resolução, fatores ambientais, como iluminação, condições climáticas e complexidade do fundo, impactam negativamente a acurácia do modelo [21]. Ainda utilizando o YOLOv8n, Kebei Qin *et al.* (2024) introduziram FasterNet e PConvGLU ao modelo alcançando melhoria eficaz ao reduzir a redundância computacional enquanto aprimorava a representação de recursos em cenários realistas. O cabeçalho de detecção empregado por meio das camadas *Group Normalization e Scale* ajudou o modelo a lidar com alvos de tamanhos diferentes com sobrecarga computacional reduzida [22]. Já Vilar-Andreu *et al.* (2024) realizaram uma nova proposta, buscando desenvolver um modelo para detectar a presença de insetos sem se preocupar em classificar qual classe ele pertence. Esse processo é uma perspectiva generalista que resolve o problema de saber se tem ou não inseto, mas não ajuda o produtor a identificar a incidência de determinada praga na lavoura [23].

Verma *et al.* (2021) propuseram o uso dos algoritmos YOLO (v3, v4 e v5) para detectar insetos em plantações de soja, treinados com imagens coletadas em campo. Foi alcançado alta precisão, com o modelo YOLOv5 obtendo o melhor desempenho (mAP de 99,5%). Os obstáculos incluíram a falta de *datasets* amplos e rotulados, além da complexidade de identificar insetos em ambientes naturais variados, reforçando a

necessidade de mais dados e ajustes para cenários reais [24]. Tetila EC *et al.* (2024) utilizaram o YOLOv5 para detecção em tempo real de plantas daninhas em plantações de soja usando imagens de UAV. O modelo apresentou precisão de detecção com 93,99% sendo melhor que as versões mais modernas do YOLO v6 e v7, demonstrando a necessidade de mais estudos para esclarecer as razões para as precisões mais baixas desses dois modelos [4].

Em um estudo realizado para detectar 6 insetos pragas que atacam as lavoura de milho, os autores utilizaram o Inception-V3 modificado juntamente com um modelo de aprendizado profundo e aprendizado por transferência. Com os pesos do ImageNet o modelo alcançou 97,0% de precisão de validação, superando o Inception-V3 original (94,8%) e o AlexNet (96,3%) [25]. A aprendizagem por transferência foi identificada como uma estratégia eficaz para otimizar o treinamento do modelo [21].

Nawoya *et al.* (2024) [26] fizeram uma revisão sobre o emprego da visão computacional e aprendizado profundo na criação de insetos, voltado a produção de alimentos e rações. Observaram que a integração de técnicas de visão computacional (CV) e Aprendizado Profundo (DL) são bastante promissoras, mesmo com os desafios tecnológicos, ambientais e a morfologia dos insetos com curto ciclo de vida metamórfico. Eles chamam a atenção para a necessidade de desenvolver técnicas baseadas em CV de baixo custo, não invasivas e não destrutivas, para medir características economicamente importantes, como tamanho, peso, níveis de proteína e gordura dos insetos.

No contexto de inserir novas tecnologias na agricultura, Sahin YS *et al.* (2025) integraram em uma solução de detecção em tempo real com YOLOv8 e suporte à decisão baseado em linguagem via ChatGPT-4. Conseguiram juntar precisão na detecção de pragas e recomendações específicas para os agricultores [27]. Não ficou claro se a API (Interface de Programação de Aplicativos) utilizada estava funcionando offline ou fazendo chamadas ao servidor na nuvem. Nesse última opção a falta de conexão impossibilita a entrega da informação gerada pelo Chatgpt4. O sistema poderia armazenar as imagens coletadas para serem utilizadas em novos treinamentos permitindo aumentar a base de dados para treinamento.

Embora várias abordagens tenham avançado no campo da visão computacional e aprendizado por transferência (TL) na detecção e reconhecimento de insetos pragas no campo, muitos desafios ainda permanecem na precisão da classificação dos insetos, na confiabilidade dos modelos, na capacidade de rodar em dispositivos de baixo poder computacional, na autonomia de energia e comunicação de dados em trabalhos em campo

e no enfrentamento da escassez de dados rotulados de diferentes tipos de insetos que atacam as mais variadas culturas. Vencer essas limitações é fundamental para o desenvolvimento de ferramentas mais robustas e confiáveis para serem aplicadas no manejo integrado de qualquer produção agrícola.

Este estudo tem como objetivo desenvolver um sistema embarcado em smartphone, suportado por um modelo de aprendizado de máquina (YOLOv11), para detectar automaticamente insetos-praga em plantações de soja e milho, armazenar os dados em nuvem e permitir análises espaciais da incidência desses insetos para apoiar o monitoramento agrícola. Os objetivos específicos são: (1) treinar e validar um modelo de detecção profundo (YOLOv11) para identificar de forma precisa os insetos *Diabrotica speciosa*, *Dalbulus maidis*, *Diceraeus spp.* e *Spodoptera frugiperda*, (2) desenvolver uma aplicação móvel para smartphones que capture imagens, execute o modelo YOLOv11 localmente e registre as detecções, associados a metadados, (3) implementar um mecanismo para sincronizar os dados coletados pelo aplicativo com um banco de dados na nuvem, garantindo armazenamento seguro e escalável das imagens e registros de detecção, (4) Utilizar os dados coletados para gerar mapas de calor e interpolação espacial que mostrem a distribuição e a incidência dos insetos nas lavouras ao longo do tempo [6].

5.2. Material e métodos

5.2.1. Arquitetura e principais tecnologias utilizadas

O aplicativo AgroInsect foi desenvolvido com foco na detecção de pragas agrícolas em tempo real, na anotação de imagens e na visualização geoespacial das ocorrências detectadas, integrando processamento embarcado, coleta de dados em campo e análise espacial. A aplicação foi construída utilizando o *framework Flutter*, no ambiente Android Studio, com suporte à biblioteca TensorFlow Lite (TFLite), que permite a execução eficiente do modelo YOLOv11n diretamente em dispositivos Android [28,29].

A Figura 1 apresenta a arquitetura geral do sistema AgroInsect, destacando a execução local do modelo de detecção no dispositivo móvel e o fluxo de comunicação com o servidor em nuvem. As imagens capturadas em campo são processadas diretamente pela rede neural YOLOv11n, enquanto o código da aplicação, desenvolvido em Dart, utiliza a biblioteca TFLite para realizar as inferências, identificar os insetos-praga e marcar automaticamente as caixas delimitadoras (bounding boxes) nas imagens. Essa

abordagem permite que todo o processo de detecção ocorra localmente no dispositivo, eliminando a dependência de processamento em nuvem e possibilitando a operação do sistema em ambientes com conectividade limitada.




Figura 1. Os módulos fundamentais para detecção eficiente do modelo YOLOv11, SPPF, C2PSA e C3K2.

A arquitetura do aplicativo segue o padrão MVVM (Model–View–ViewModel), promovendo separação clara entre a interface do usuário, a lógica de negócios e a manipulação dos dados [30], facilitando a manutenção, a escalabilidade e a evolução do sistema. Os resultados das detecções, bem como os dados do usuário, são organizados e preparados para armazenamento e sincronização com a infraestrutura em nuvem.

O fluxo operacional do aplicativo AgroInsect é apresentado na Figura 2, que descreve as etapas de interação do usuário e de processamento das informações. O fluxo inicia-se com a autenticação do usuário e a seleção da fazenda ou unidade de manejo de interesse, garantindo que todas as informações coletadas sejam corretamente associadas a uma área agrícola específica. Em seguida, o usuário define o modo de operação, podendo optar entre a detecção automática de insetos ou a anotação manual de insetos, modos que são complementares na lógica do sistema.

Independentemente do modo selecionado, o fluxo converge para a etapa de aquisição ou seleção de imagens, na qual as imagens podem ser capturadas diretamente pela câmera do dispositivo móvel ou selecionadas a partir do armazenamento local. No modo de detecção automática, as imagens adquiridas são processadas pelo modelo de visão computacional embarcado. Quando ocorre a detecção de insetos, os resultados são automaticamente registrados. Nos casos em que não há detecção ou quando o usuário identifica detecções incorretas ou incompletas, o fluxo permite a transição para a etapa de anotação manual, possibilitando o registro ou a correção das informações relacionadas aos insetos observados.




Figura 2. Fluxograma do fluxo operacional do aplicativo AgroInsect, ilustrando as etapas de autenticação do usuário, seleção da área de interesse, definição do modo de operação, aquisição de imagens, detecção automática de insetos, anotação manual e armazenamento.

Todas as informações provenientes tanto das detecções automáticas quanto das anotações manuais — incluindo as coordenadas das caixas delimitadoras, as imagens analisadas, as classes identificadas e a geolocalização do ponto de captura — são armazenadas de forma persistente em um banco de dados relacional MySQL [6]. Esses registros podem ser utilizados tanto para o monitoramento da dinâmica populacional de insetos na propriedade quanto para a construção, expansão e refinamento contínuo da base de dados AgroInsect, destinada ao treinamento e à melhoria dos modelos de *deep learning*.

Para a visualização espacial das ocorrências registradas no fluxo, foi integrada a API do Google Maps, permitindo ao usuário acompanhar a distribuição geográfica das pragas detectadas diretamente na interface do aplicativo. Adicionalmente, foram desenvolvidos scripts em Python para a geração de mapas de calor e interpolação espacial, utilizando a biblioteca SciPy para a implementação do método IDW (Inverse Distance Weighting) e a biblioteca GeoPandas para a manipulação dos dados geoespaciais. Essas representações espaciais fornecem suporte à tomada de decisão, com base na distribuição e intensidade das infestações ao longo da área monitorada.

O aplicativo AgroInsect foi avaliado em condições reais de campo na Fazenda Serra Azul, em uma área experimental de 100×100 m, subdividida em grade de amostragem de 20×20 m. As imagens foram capturadas utilizando um smartphone Motorola Edge 30 (8 GB de RAM, processador Snapdragon 778G+), selecionado por representar um dispositivo comercial de gama média. Essa configuração permitiu avaliar

o desempenho da detecção em tempo real e a capacidade de resposta do sistema em condições operacionais reais. Todas as detecções foram processadas localmente no dispositivo, georreferenciadas no momento da captura e, posteriormente, transmitidas para o banco de dados MySQL central.

5.2.2. Dataset

O conjunto de dados utilizado neste estudo foi o mesmo utilizado pelos autores que publicaram uma análise de desempenho dos modelos YOLO e Detectron2 para detecção de pragas [5]. O conjunto de dados inclui quatro tipos de pragas que atacam as culturas de milho e soja: 591 imagens de *Diabrotica Speciosa*, 177 imagens de *Dalbulus Maidis*, 248 imagens de *Diceraeus ssp.* e 334 imagens de *Spodoptera Frugiperda* [5]. Essas imagens constituem um *dataset* denominado AgroInsect. As anotações das imagens do conjunto de dados AgroInsect foram realizadas utilizando o software de código aberto Label Studio (versão 0.9.1) [31]. Cada imagem foi anotada com informações da região de interesse (ROI), classe do inseto e posição do objeto no formato YOLO. Na Figura 3 está ilustrado um exemplo para cada classe do dataset.


No total, foram anotadas 1510 imagens, considerando que algumas continham mais de um inseto da mesma espécie. As anotações foram exportadas e organizadas em arquivos com os mesmos nomes das imagens correspondentes, com os caminhos de treinamento, validação e teste definidos em arquivos YAML, um formato de arquivo utilizado nos algoritmos. Os resultados obtidos com o conjunto de dados AgroInsect demonstraram alto desempenho dos modelos da família YOLO. O modelo YOLOv5 atingiu precisão, recall e F1-Score de 98,04%, com precisão específica de 99,22%. Da mesma forma, o YOLOv7 apresentou F1-Score de 96,12% e precisão de 98,45%, enquanto o YOLOv8 obteve F1-Score de 96,08% e precisão de 98,43%. Modelos mais recentes, como o YOLOv9-c e o YOLOv9-gelan, apresentaram ainda melhores resultados, alcançando F1-Scores de 97,06% e 98,04%, respectivamente, com precisão superior a 99%. Esses resultados indicam que o conjunto de dados AgroInsect é adequado para o treinamento de modelos de detecção de pragas, fornecendo imagens com diversidade suficientes para a obtenção de métricas de desempenho elevadas [5].




(a) Objeto marcado como classe 0 no dataset, corresponde a Diabrotica Speciosa.



(b) Objeto marcado como classe 1 no dataset, corresponde a Spodoptera Frugiperda.



(c) Objeto marcado como classe 2 no dataset, corresponde a Diceracius Spp.



(d) Objeto marcado como classe 3 no dataset, corresponde a diabrotica speciosa.

Figura 3: Exemplos de quatro objetos marcados utilizando Caixas Delimitadoras.

5.2.3. Modelo Yolo

Dentre as várias versões, para o desenvolvimento do aplicativo para smartphone, foi escolhido o YOLOv11n, sendo essa a versão mais recente da família YOLO (You Only Look Once), reconhecida pela alta eficiência na detecção de objetos em tempo real [32]. A Figura 4 ilustra o processo de treinamento, de forma que três blocos principais atuam na rede YOLOv11 para produzir um modelo que resolva a tarefa de detecção de objetos. A versão 11 da YOLO incorpora inovações arquitetônicas significativas, como o bloco C3k2 (Cross Stage Partial com kernel de tamanho 2), o módulo SPPF (Spatial

Pyramid Pooling- Fast) e o bloco C2PSA (Convolutional block with Parallel Spatial Attention), que, em conjunto, aprimoram a extração de características e aumentam a precisão do modelo.

O bloco C3k2, por exemplo, melhora a extração de detalhes de objetos pequenos, como insetos, mesmo em imagens complexas. Já o módulo SPPF permite a detecção eficiente de alvos em múltiplas escalas, fundamental para monitorar insetos em diferentes estágios de vida ou tamanhos. O bloco C2PSA, por sua vez, potencializa a identificação de padrões por meio de atenção espacial paralela, tornando o modelo mais robusto em cenários com fundos complexos ou visualmente confusos, como campos abertos ou lavouras. Além disso, o YOLOv11 está disponível em diferentes tamanhos de modelo, desde versões compactas, como o YOLOv11n, até configurações maiores, permitindo a adaptação a ampla gama de aplicações — desde dispositivos móveis até sistemas de alto desempenho [33].




Figura 4: Módulos fundamentais para detecção eficiente do modelo YOLOv11, SPPF, C2PSA e C3K2.

Neste trabalho, o modelo YOLOv11n foi treinado especificamente para a detecção de pragas agrícolas, sendo posteriormente convertido para o formato TensorFlow Lite (TFLite) [34], permitindo a execução em dispositivos Android. Essa conversão garantiu inferência rápida, baixo consumo de recursos e viabilidade em campo, requisitos estes fundamentais para aplicações móveis. A entrada do modelo é composta por imagens RGB, e a arquitetura é capaz de realizar detecção em tempo real, gerando caixas delimitadoras para indicar a localização das pragas. O treinamento do modelo foi realizado na plataforma Google Colab, com suporte a GPU. A acurácia da detecção, baseada na arquitetura YOLOv11n convertida para TFLite, foi avaliada por meio da precisão média (AP) e da Média de Precisão Aritmética (mAP). Para a etapa de validação, foram selecionadas aleatoriamente 15 imagens por espécie, enquanto o teste utilizou 25 imagens por espécie. Mesmo quando implantado em dispositivos com restrições de

hardware, o modelo manteve alta acurácia e desempenho, evidenciando o potencial da arquitetura YOLOv11n para aplicações embarcadas de visão computacional [35].

5.2.4. Interpolação Espacial com Krigagem

A krigagem é um método geoestatístico de interpolação amplamente utilizado para estimar valores de uma variável espacialmente contínua a partir de um conjunto discreto de pontos amostrados [36]. Diferentemente de métodos determinísticos, como a ponderação pelo inverso da distância (IDW), a krigagem considera não apenas a distância entre os pontos, mas também a dependência espacial existente entre as amostras, modelada por meio de uma função variograma. Essa abordagem permite estimar valores desconhecidos com base em combinação linear ponderada das observações vizinhas, otimizando a estimativa em termos de erro mínimo e não tendencioso [37].

A estimativa krigada de uma variável $Z(x_0)$ em um ponto não amostrado (x_0) pode ser expressa pela Equação (1):

$$\hat{Z}(x_0) = \sum_{i=1}^n \lambda_i Z(x_i) \quad (1)$$

em que:

- $\hat{Z}(x_0)$ é o valor estimado no ponto de localização x_0 ;
- $Z(x_i)$ são os valores observados nos n pontos amostrados;
- λ_i são os pesos atribuídos a cada ponto amostrado, determinados de forma que a soma dos pesos seja igual a 1 ($\sum \lambda_i = 1$).

Os pesos λ_i são calculados com base no variograma experimental, que descreve a variabilidade espacial da variável estudada em função da distância entre amostras. O variograma é definido pela Equação (2):

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2 \quad (2)$$

em que:

- $\gamma(h)$ é o semivariograma para uma distância h ;
- $N(h)$ é o número de pares de pontos separados por h ;
- $Z(x_i)$ e $Z(x_i + h)$ são os valores observados em dois pontos separados por essa distância.

A partir do variograma ajustado (esférico, exponencial, gaussiano, etc.), o modelo de krigagem calcula a matriz de covariância espacial e resolve o sistema linear que fornece os pesos λ_i ideais para cada ponto estimado. Isso garante que as estimativas apresentem erro mínimo de predição e incorporem a estrutura espacial real dos dados [38]. No presente estudo, foi utilizada a krigagem ordinária (Ordinary Kriging), implementada via biblioteca PyKrige [39], integrando-a a um servidor web em Flask para geração automatizada de mapas de densidade em tempo real. O modelo, utilizando um variograma esférico e operando com coordenadas geográficas, interpola as contagens discretas de insetos obtidas em campo. O resultado é uma superfície contínua de densidade (mapa de calor), visualizada sobre a interface do Google Maps. Essa integração transforma os dados brutos de monitoramento em inteligência espacial acionável, permitindo que os resultados sejam visualizados dinamicamente em interface móvel. A ferramenta fornece, assim, um suporte geoestatístico para a identificação precisa no monitoramento espacial de pragas agrícolas para a tomada de decisão no manejo de precisão. Para avaliar o desempenho do modelo de krigagem implementado, foi conduzida uma simulação sintética controlada. Foram gerados 8.000 pontos de ocorrência simulados distribuídos entre as espécies *Diabrotica speciosa*, *Dalbulus maidis*, *Diceraeus spp.* e *Spodoptera Frugiperda*. Cada espécie apresentou um padrão espacial distinto, com área de maior densidade (hotspot) e distribuição dispersa pelo restante da região de estudo. A área experimental foi subdividida em grades de 20×20 , 50×50 , 100×100 e 200×200 células, representando diferentes níveis de densidade amostral. Com base nos pontos simulados de cada grade, foram gerados mapas de krigagem ordinária utilizando a biblioteca PyKrige. Esses mapas interpolados foram posteriormente comparados com os mapas de gradiente simulados, considerados como a superfície de referência (ground truth). Essa comparação permitiu quantificar o erro de predição e analisar a sensibilidade do método à escassez de dados amostrais.

5.3. Resultados

5.3.1. Principais funcionalidades do AgroInsect

O Agrosinsect é um aplicativo para smartphone que auxilia os produtores na tomada de decisão no controle de pragas. A Figura 5 mostra a interface do aplicativo. Ao fazer login no sistema, o usuário precisa selecionar uma fazenda que ele esteja associado. O sistema tem estrutura para detecção e anotações de imagens, gerenciar usuários, fazendas, funções, classes e visualizações de mapas. Os módulos de detecção e anotação de imagens trabalham juntos.




Figura 5: Interface do aplicativo Agrolnsect, com detecção de objeto, mapa de calor e mapa de krigagem.

No módulo de detecção o usuário pode escolher tirar uma foto ou carregar uma imagem da galeria. Após esse processo a imagem é processada pelo modelo YOLO11s treinado e convertido para TFLITE para detecção e contagem de cada objeto (classe). Após esse processo o usuário pode salvar a detecção ou fazer correções nas anotações ou até anotar objetos que não foram detectados pelo modelo.

Para a geração dos mapas são necessárias as coordenadas de geolocalização das imagens, o sistema é capaz de ler as informações dos metadados EXIF das imagens tanto daquelas que são capturadas pelo dispositivo como aquelas que são lidas da galeria do smartphone. Para garantir que as imagens sejam coletadas exclusivamente nos limites da propriedade agrícola associada e selecionada pelo usuário logado, foi implementada uma validação georreferenciada baseada no raio de abrangência da fazenda. Cada propriedade possui um ponto central definido por coordenadas geográficas (farm_latitude, farm_longitude) e um raio máximo de operação (radius), expresso em metros. A distância entre o ponto de captura da imagem (extraído dos metadados EXIF) e o centro da fazenda é calculada utilizando a fórmula de Haversine:

$$d = 2R \arcsin \left(\sqrt{\sin^2 \left(\frac{\phi_2 - \phi_1}{2} \right) + \cos(\phi_1) \cos(\phi_2) \sin^2 \left(\frac{\lambda_2 - \lambda_1}{2} \right)} \right), \quad (3)$$

em que $R = 6371$ km é o raio médio da Terra, ϕ_1 , ϕ_2 são as latitudes e λ_1 , λ_2 são as longitudes em radianos. A imagem é considerada válida se:

$$d \leq r_{mx} \quad (4)$$

em que r_{mx} é o raio da fazenda em quilômetros. Essa abordagem garante a integridade espacial dos dados, evitando contaminações por amostras externas à área monitorada. A Figura 6 apresenta o projeto do banco de dados relacional (MySQL) da aplicação.




Figura 6: Estrutura do banco de dados relacional (MySQL) do sistema AgroInsect. A arquitetura multitenant utiliza a tabela *user_farm* para garantir isolamento total de dados entre fazendas.

O esquema foi desenvolvido para oferecer isolamento lógico entre diferentes fazendas, garantindo que cada uma, possua seus próprios dados operacionais e de usuários associados.

As tabelas centrais desse modelo são *user*, *farm*, *user_farm* e *image*:

1. A tabela *user* armazena informações globais de autenticação e cadastro dos usuários.
2. A tabela *farm* contém os dados específicos de cada fazenda registrada no sistema.

3. A tabela de junção *user_farm* é o elemento que estabelece o vínculo entre usuários e fazendas, permitindo que um mesmo usuário possa estar associado a uma ou mais fazendas.

O isolamento dos dados é assegurado pela forma como as informações operacionais, como imagens e anotações são vinculadas à relação *user_farm*. Assim, o sistema garante que cada usuário só possa salvar, consultar ou visualizar imagens e dados pertencentes às fazendas com as quais possua uma associação ativa (registro válido na tabela *user_farm*). Usuários sem vínculo não têm acesso aos dados de outras fazendas, mantendo a integridade e confidencialidade das informações.

5.3.2. Validação do Modelo de Krigagem em um Cenário Simulado

A etapa de validação teve como objetivo avaliar a precisão e a consistência espacial das estimativas de abundância geradas pela krigagem. Foram utilizadas métricas amplamente adotadas em geoestatística para quantificar os erros de predição e a acurácia do modelo, incluindo o erro quadrático médio (RMSE), o erro médio absoluto (MAE), o viés médio (Bias) e o coeficiente de determinação (R^2).

O erro de predição foi quantificado pelo erro quadrático médio (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Z_i - \hat{Z}_i)^2} \quad (5)$$

A acurácia preditiva foi avaliada pelo coeficiente de determinação (R^2):

$$R^2 = 1 - \frac{\sum_{i=1}^n (Z_i - \hat{Z}_i)^2}{\sum_{i=1}^n (Z_i - \bar{Z})^2} \quad (6)$$

em que $\bar{Z}$ representa a média dos valores coletados (simulados).

Além disso, foi calculado o erro médio absoluto (MAE) e o erro médio (Bias), que permite avaliar a precisão e o erro desvio sistemático das estimativas:

$$MAE = \frac{1}{n} \sum_{i=1}^n |Z_i - \hat{Z}_i|, \quad Bias = \frac{1}{n} \sum_{i=1}^n (Z_i - \hat{Z}_i) \quad (7)$$

A Tabela 1 resume os resultados obtidos para cada espécie simulada e diferentes resoluções de nota.

Tabela 1. Métricas de validação da interpolação por krigagem para a abundância simulada de insetos em diferentes resoluções de grade.

Species	Grid Size	Samples (n_{train})	Validation (n_{valid})	RMSE	MAE	R ²
<i>Dalbulus</i>	20×20	1963	2455	1.2596	1.0152	0.9113
	50×50	761	2455	1.2971	0.9913	0.9060
	100×100	198	2455	2.6761	1.9419	0.5997
	200×200	46	2455	2.3932	1.6535	0.6799
<i>Diabrotica</i>	20×20	950	2501	0.8070	0.6189	0.9511
	50×50	321	2501	0.8830	0.7402	0.9414
	100×100	74	2501	1.0341	0.8588	0.9197
	200×200	16	2501	2.6374	1.9396	0.4774
<i>Diceraeus</i>	20×20	558	1515	0.8073	0.6323	0.9478
	50×50	272	1515	0.8748	0.7288	0.9388
	100×100	76	1515	1.1860	1.0217	0.8874

	200×200	13	1515	2.7187	2.2817	0.4085
<i>Frugiperda</i>	20×20	601	1529	0.7664	0.5860	0.9656
	50×50	287	1529	0.8300	0.6919	0.9597
	100×100	70	1529	1.4723	1.1575	0.8731
	200×200	19	1529	2.9628	1.9192	0.4859

Os resultados demonstram tendência clara de redução da acurácia à medida que diminui a densidade amostral (ou seja, com o aumento do tamanho da grade). Para todas as espécies, as grades mais densas (20×20 e 50×50) apresentaram os menores valores de RMSE e MAE e os maiores valores de R2, indicando alta capacidade do modelo em reconstruir os padrões espaciais simulados. Entre as espécies, *Diabrotica Speciosa* destacou-se com os melhores indicadores (R2 > 0,94 nas grades de 20×20 e 50×50), refletindo seu padrão espacial mais uniforme. Por outro lado, *Dalbulus Maidis* e *Spodoptera Frugiperda* apresentaram leve degradação de desempenho nas grades mais amplas, por causa da presença de áreas de alta agregação (hotspots) e maior variabilidade local, que aumentam o erro de predição em regiões de transição. Além das métricas quantitativas de validação, analisou-se a estrutura espacial dos erros de predição para identificar possíveis vieses ou desvios regionais nas estimativas obtidas pela krigagem. Os resíduos foram calculados conforme a Equação 8, que representa a diferença entre os valores estimados e os valores de referência do universo simulado:

$$e_i = \hat{Z}_i - Z_i \quad (8)$$

em que:

- $\hat{Z}_i$ representa o valor estimado pela krigagem no ponto i;
- Z_i é o valor observado (simulado) correspondente.

A Figura 7 ilustra a distribuição espacial desses resíduos para ambas as configurações de amostragem (20×20 e 200×200).




Figura 7: Distribuição espacial dos resíduos de krigagem para as quatro espécies de insetos simuladas sob duas densidades de amostragem (grades de 20×20 e 200×200).

Os mapas de resíduos demonstram que os erros de predição apresentam estrutura espacial coerente com os padrões artificiais utilizados nas simulações. No conjunto de dados sintético, cada espécie apresentou uma região de alta densidade (hotspot) e uma dispersão gradual pelo restante da área. Consequentemente, observou-se tendência de subestimação nas zonas de maior concentração e superestimação nas regiões periféricas. Esse efeito de suavização é especialmente evidente em *Dalbulus maidis* e *Spodoptera frugiperda* e reflete o comportamento inerente da krigagem, que produz estimativas locais suavizadas próximas aos dados concentrados.

Por outro lado, *Diabrotica speciosa* apresentou distribuição de resíduos mais homogênea, condizente com seu padrão de simulação mais uniforme. Esse comportamento está em concordância com as métricas quantitativas, nas quais *Diabrotica* obteve o maior valor de R² e o menor RMSE, indicando que o modelo de krigagem reconstruiu adequadamente variações espaciais moderadas sob condições de amostragem regular.

De forma geral, a análise espacial dos resíduos confirma a robustez do método de krigagem implementado na aplicação MPI. Mesmo com padrões simulados simplificados, o modelo foi capaz de reproduzir os principais gradientes espaciais sem apresentar viés direcional sistemático. Esses resultados demonstram que o procedimento de interpolação mantém desempenho consistente em diferentes densidades amostrais

(20×20 a 200×200), reforçando o potencial para aplicações reais em monitoramento de pragas agrícolas. Trabalhos futuros poderão incorporar covariáveis auxiliares, como índices de vegetação, atributos do solo ou variáveis climáticas, visando aprimorar o desempenho preditivo em cenários de baixa densidade amostral

5.3.3. Avaliação das detecções automáticas realizadas em campo

A etapa de avaliação teve como objetivo quantificar o desempenho do modelo de reconhecimento de insetos usando um aplicativo de smartfone. Cada objeto detectado foi revisado manualmente e classificado em três categorias: (i) Detecção correta (D), quando o inseto foi identificado corretamente; (ii) Ajuste de classe (A), quando a detecção foi válida, mas a classificação da espécie necessitou correção; e (iii) Exclusão (E), aplicada a falsos positivos ou objetos sem definição morfológica adequada.

A Tabela 2 apresenta o resumo das detecções realizadas pelo modelo nas 79 imagens avaliadas. Do total de 183 objetos identificados, 92,4% foram classificados corretamente, 6,6% exigiram ajuste de classe e 1,1% foram excluídos por erro de detecção. Esses resultados evidenciam desempenho consistente do modelo, com baixa ocorrência de falsos positivos e necessidade limitada de intervenção manual.

Tabela 2. Resumo das detecções e ajustes de classes.

Categoria	Quantidade	Descrição
Detecções corretas (D)	169	Detecções com classificação correta
Ajustes de classe (A)	12	Detecções que exigiram correção manual
Exclusões (E)	2	Objetos descartados por erro de detecção
Total válido	183	Total de objetos considerados após exclusões

Já a Figura 8 apresenta a matriz de confusão derivada da validação cruzada, sintetizando o desempenho do classificador na discriminação das quatro espécies de insetos-alvo e da classe de fundo (background). Observa-se elevada concordância entre

rótulos previstos e verdadeiros, refletida em altos valores de sensibilidade por classe. As poucas inconsistências identificadas concentram-se em pares específicos de classes e podem estar associadas a variações presentes nas imagens utilizadas no processo de validação.




Figura 8: Matriz de confusão do modelo AgroInsect avaliado com imagens coletadas em campo.

As métricas quantitativas de desempenho estão apresentadas na Tabela 3. O modelo alcançou acurácia geral de 95,1%, com valores de *precision*, *recall* e F1-score superiores a 90% para todas as classes de interesse agrônômico. A espécie *Dalbulus Maidis* apresentou F1-score de 98%, indicando excelente equilíbrio entre sensibilidade e precisão. Desempenho igualmente robusto foi observado para *Diabrotica Speciosa* (98%) e *Spodoptera Frugiperda* (96%). Erros pontuais, como falsos negativos ocasionais, por exemplo, indivíduos de *Diabrotica Speciosa* classificados como *background* explicam a ligeira redução no valor de revocação dessa classe (96%), sem comprometer o desempenho global do modelo.

Tabela 3. Desempenho do modelo de classificação para as espécies avaliadas.

Classe	Precisão	Revocação	F1-score	Amostras
<i>Diabrotica speciosa</i>	1.00	0.96	0.98	24
<i>Dalbulus maidis</i>	0.99	0.97	0.98	120
<i>Diceraeus ssp.</i>	0.92	0.96	0.94	23
<i>Spodoptera frugiperda</i>	1.00	0.93	0.96	14
Acurácia geral 95,1%				

Os resultados combinados da avaliação automática e da revisão manual reforçam o potencial do sistema AgroInsect como ferramenta de apoio ao monitoramento automatizado de pragas. A elevada acurácia e a baixa necessidade de correções indicam que o modelo pode reduzir significativamente o esforço humano na etapa de triagem, mantendo consistência e confiabilidade nos registros. Em trabalhos futuros, recomenda-se o uso de estratégias de aprendizado ativo e refinamento iterativo para ampliar a robustez frente à variabilidade de morfologia e iluminação nas imagens de campo.

5.3.4. Análise Espacial das Ocorrências de Pragas

A Figura 9 apresenta os resultados gerados pelo sistema, após a aplicação dos filtros por fazendas que o usuário esteja associado e por intervalo de datas e espécie de praga. A interface retorna três componentes complementares: (a) um painel quantitativo com o número total de insetos detectados na propriedade no período selecionado; (b) um mapa de distribuição espacial mostrando a localização geográfica de cada detecção; e (c) um mapa de krigagem representando a interpolação da densidade dos insetos no talhão.

Em conjunto, esses elementos permitem avaliar não apenas a intensidade das ocorrências, mas também a dinâmica espacial das pragas, fornecendo subsídios objetivos para a tomada de decisão no manejo localizado.




Figura 9. Painel de resultados gerados pelo sistema: (a) total de insetos detectados; (b) distribuição espacial das detecções; (c) interpolação espacial por krigagem.

5.3.5. Resultados do Painel Espacial Integrado do Sistema AgroInsect

A Figura 10 apresenta o conjunto de mapas derivados da análise espacial realizada pelo sistema AgroInsect. O painel integra todas as etapas do fluxo de processamento desde as detecções produzidas pelo modelo até a interpolação espacial por krigagem permitindo uma avaliação clara e quantitativa da distribuição das pragas ao longo do talhão monitorado. O mapa agregado (Figura 10a) sintetiza a ocorrência combinada de todas as espécies, fornecendo um panorama geral da pressão de insetos no período analisado e destacando regiões de maior concentração que motivaram a avaliação individual de cada praga. Para *Diabrotica Speciosa* (Figura 10b), a projeção espacial revela padrão de distribuição fortemente pontual. As áreas de maior intensidade concentram-se nas proximidades imediatas dos pontos amostrados, especialmente na região central do talhão. A ausência de gradientes de dispersão mais amplos sugere focos localizados de infestação, compatíveis com o comportamento menos móvel dessa espécie e com registros de agregação espacial restrita mencionados na literatura. A krigagem aplicada à espécie *Dalbulus* (Figura 10c) resultou no padrão espacial mais amplo e contínuo entre todas as espécies avaliadas. Observa-se a formação de gradientes suaves e regiões de maior intensidade distribuídas predominantemente nas porções leste e sudoeste do talhão. Esse comportamento é coerente com a maior capacidade de deslocamento associada à espécie, resultando em superfície interpolada mais homogênea e com transições mais progressivas entre zonas de baixa e alta probabilidade de ocorrência. A

espécie *Diceraeus* (Figura 10d) apresenta padrão intermediário. Embora a maior parte da área mantenha valores reduzidos, observa-se a formação de um núcleo de intensidade elevada na porção central do talhão. Esse foco pode estar associado a características microambientais específicas que favorecem sua presença. Ainda assim, a distribuição como um todo permanece fragmentada, sugerindo pressão populacional moderada no período avaliado. Por fim, *Frugiperda* (Figura 10e) exibiu o padrão espacial mais homogêneo e de menor magnitude absoluta. A superfície interpolada mostra variação mínima ao longo do talhão, com apenas pequenas áreas de leve aumento, sem formação de manchas robustas de infestação. Esse comportamento confirma as baixas contagens observadas na etapa de detecção e sugere que a espécie estava dispersa e em baixa densidade durante o intervalo monitorado.




Figura 10. Mapas de incidência por krigagem: (a) distribuição agregada de todas as espécies; (b) Diabrotica; (c) Dalbulus; (d) Diceraeus; (e) Frugiperda.

5.4. Discussão

Os resultados obtidos demonstram que o sistema integra de forma eficiente técnicas modernas de visão computacional, geoprocessamento e modelagem espacial, oferecendo um fluxo completo para monitoramento de pragas em campo. Esse tipo de arquitetura, que combina detecção automática, validação geográfica e interpolação via krigagem em um único ambiente computacional, ainda é pouco explorado na literatura, em que soluções costumam abranger apenas partes isoladas desse processo. Por exemplo, Zhou *et al.* [6] apresentam um sistema baseado em YOLO para pomares, mas cuja etapa

de mapeamento depende de serviços externos, como ArcGIS Server, aumentando a complexidade operacional do monitoramento e os custos de integração.

O desempenho do modelo de classificação, com acurácia geral de 95,1%, mostra consistência com avanços recentes em arquiteturas de redes leves para detecção em dispositivos móveis. O trabalho de Xu *et al.* [40] descreve o modelo GBiDC-PEST, otimizado para smartphones Android, alcançando elevada precisão com forte redução do custo computacional. Resultados similares foram obtidos no AgroInsect, reforçando que modelos comprimidos e adaptados para TFLite podem manter desempenho competitivo mesmo operando em hardware restrito, sendo um aspecto crucial para a adoção por produtores rurais em contextos de baixa infraestrutura.

Além disso, o trabalho de Verma *et al.* (2021) contribui com uma análise detalhada do desempenho de diferentes versões da família YOLO (v3, v4 e v5) na detecção de insetos em soja, alcançando mAP de até 99,5% e F1-score de 96% para o YOLOv5 [24]. Embora tais resultados reforcem o potencial dos modelos YOLO para detecção precisa em cenários agrícolas, a abordagem permanece dependente de processamento em GPU e foco exclusivo na etapa de detecção. Em contraste, o AgroInsect amplia significativamente esse escopo ao operar integralmente em smartphones comuns, eliminando a necessidade de hardware especializado e integrando módulos adicionais ausentes em estudos anteriores, como validação geoespacial automática, interpolação via krigagem e geração de mapas de infestação. Assim, o presente trabalho avança além da simples detecção, oferecendo um sistema funcional de monitoramento espacial que atende diretamente às demandas práticas da agricultura de precisão.

Uma comparação relevante também pode ser feita com soluções baseadas em computação em nuvem. Karar *et al.* (2021) propõem um pipeline no qual o smartphone atua apenas como interface, enquanto a inferência com Faster R-CNN ocorre integralmente em servidores remotos [9]. Embora apresente acurácia elevada, o sistema depende de conectividade contínua, retransmissão automática em caso de falhas de rede e infraestrutura de hospedagem escalável. No contexto agrícola, em que a conectividade é frequentemente limitada, essa dependência pode comprometer a adoção prática. O AgroInsect avança nesse aspecto ao eliminar completamente a necessidade de processamento remoto, garantindo operação estável, de baixa latência e sem custos adicionais de infraestrutura, mesmo em regiões rurais com cobertura instável.

Além disso, estudos recentes demonstram avanços importantes na detecção de insetos pequenos em ambientes agrícolas heterogêneos. Tang *et al.* (2025) apresentam o S-YOLOv5m, uma variante aprimorada do YOLOv5m projetada para tomates, que incorpora SPD-Conv, módulos Ghost, CBAM e o bloco AEM. Essas alterações resultam em aumento de 4,73% no mAP, redução de 31% no número de parâmetros e ganho de 1,3 ms por imagem na inferência [41]. Tais melhorias refletem a evolução das arquiteturas YOLO para lidar com alvos pequenos e condições de iluminação e oclusão complexas; contudo, 12 o modelo permanece voltado exclusivamente à etapa de detecção e depende de GPU durante a fase de treinamento, sem incorporar elementos adicionais necessários a um sistema completo de monitoramento espacial. Em contraste, o AgroInsect associa detecção, validação espacial e modelagem geoestatística em um único pipeline executado integralmente em smartphones, ampliando a aplicabilidade em cenários de baixa infraestrutura.

Um avanço complementar é observado no trabalho de Kargar *et al.* (2025), que apresentam um modelo ultraleve projetado para segmentação e contagem de insetos diretamente em microcontroladores com apenas 1 MB de RAM e 2 MB de memória flash [42]. Apesar da expressiva redução de complexidade, aproximadamente 0,75 M de parâmetros, o modelo alcança desempenho sólido (DSC de 85% e IoU de 73%), demonstrando a viabilidade de execução totalmente embarcada em dispositivos de baixíssimo custo energético. No entanto, assim como outros estudos focados em arquiteturas leves, a aplicação restringe-se à tarefa de segmentação e contagem, sem incorporar validação geográfica, integração com sistemas espaciais ou geração de mapas de distribuição. Nesse sentido, o aplicativo diferencia-se ao expandir esse paradigma de processamento local para um pipeline completo de monitoramento, integrando detecção, georreferenciamento, interpolação e geração automática de mapas diretamente em smartphones convencionais.

No campo dos modelos leves, Wang *et al.* (2025) introduzem o Insect-YOLO, que incorpora o módulo CBAM para aprimorar a extração de características em imagens de baixa resolução. O modelo atinge mAP50 de 93,8% com aproximadamente 3 milhões de parâmetros, demonstrando boa relação entre eficiência e desempenho. Ainda assim, a aplicação é descrita em cenários que requerem infraestrutura dedicada, tipicamente integrada a sistemas IoT com processamento remoto. Os autores também destacam limitações importantes, como sensibilidade às condições ambientais, desempenho desigual entre espécies, especialmente *planthoppers* e risco de sobreajuste devido ao uso

de base de dados regional [21]. O AgroInsect supera esses entraves ao operar diretamente sobre imagens capturadas em campo, mitigando vieses geográficos e dispensando câmeras dedicadas ou servidores externos.

Adicionalmente, soluções recentes baseadas em armadilhas inteligentes equipadas com visão computacional e IoT, como as descritas por Guo *et al.* (2023), possibilitam coleta automatizada de grandes volumes de dados, mas exigem sensores fixos, infraestrutura permanente e conectividade estável para transmissão e análise [22]. Em contraste, o AgroInsect democratiza o monitoramento ao utilizar o próprio smartphone do produtor como dispositivo de captura e processamento, ampliando significativamente o alcance do sistema em regiões em que sensores dedicados são economicamente inviáveis.

A análise geoestatística realizada neste estudo revelou padrões espaciais consistentes com investigações clássicas que aplicam krigagem ao monitoramento de pragas. Os efeitos de suavização observados com subestimação em áreas de maior densidade e superestimação nas bordas, também são relatados em trabalhos sobre *Helicoverpa armigera*, *Billbugs* e *grape root borer* [43]. Além disso, as diferenças espaciais entre as espécies analisadas, como o padrão pontual de *Diabrotica* e a distribuição mais difusa de *Dalbulus*, refletem comportamentos ecológicos amplamente documentados, relacionados à mobilidade, agregação e dispersão.

Outro aspecto relevante é o tratamento automático da informação espacial. A validação georreferenciada baseada em metadados EXIF e no raio operacional da propriedade reduz falhas de posicionamento, problema comum em sistemas que dependem de entrada manual de coordenadas ou do uso de GPS externo. Tal abordagem atende a uma lacuna frequentemente apontada em aplicações móveis agrícolas, tornando a base espacial do AgroInsect mais robusta que a de soluções existentes. Notadamente, nenhum dos estudos revisados, incluindo modelos IoT, arquiteturas leves recentes e métodos baseados em nuvem, integra análise geoespacial, interpolação ou geração automatizada de mapas. Assim, o aplicativo desenvolvido diferencia-se ao unificar detecção, validação espacial e modelagem geoestatística em um único ambiente computacional.

De modo geral, os resultados demonstram que este software avança o estado da arte ao integrar um pipeline completo, desde a captura e detecção e anotação até a geração de mapas derivados de interpolação espacial, proporcionando uma ferramenta prática, precisa e operacionalmente eficiente para suporte ao manejo integrado de pragas.

5. Conclusão e trabalhos futuros

O AgroInsect mostrou ser uma solução robusta para o monitoramento automatizado de pragas agrícolas, combinando detecção eficiente, validação geográfica rigorosa e modelagem espacial por krigagem. A elevada acurácia do modelo de classificação e a baixa necessidade de ajustes manuais reforçam o potencial da plataforma em reduzir o esforço humano na etapa de triagem, aumentando a confiabilidade dos registros e permitindo análises mais rápidas e objetivas.

Os mapas gerados pela krigagem revelaram padrões coerentes com a ecologia das espécies avaliadas, destacando diferenças importantes na intensidade e dispersão das ocorrências. A integração dessas informações em um único painel oferece aos produtores uma visão clara sobre a dinâmica espacial das pragas no talhão, auxiliando na tomada de decisão para intervenções pontuais e eficientes.

Comparado a soluções existentes, o aplicativo se destaca pela operação totalmente embarcada em smartphone, pela validação espacial automatizada e pela geração imediata de mapas de incidência, características que o tornam adequado para uso em campo, inclusive em propriedades com infraestrutura limitada.

Como trabalhos futuros, a incorporação de covariáveis ambientais, como índices de vegetação, umidade do solo e variáveis climáticas, poderá ampliar a precisão das estimativas em cenários com baixa densidade amostral. Estratégias de aprendizado ativo também poderão ser exploradas para o aprimoramento contínuo do modelo, especialmente em condições de grande variabilidade morfológica e luminosa. Em síntese, o AgroInsect se apresenta como ferramenta promissora para modernizar práticas de monitoramento e apoiar decisões no manejo integrado de pragas.

CRedit – Declaração de Contribuição dos Autores

Autores: Guilherme Almeida: Conceituação, Escrita – revisão e edição, Escrita – redação original, Visualização, Validação, Software, Metodologia, Investigação, Análise formal, Curadoria de dados. Leonardo dos Santos: Conceituação, Escrita – revisão e edição, Recursos, Metodologia, Investigação, Obtenção de financiamento, Supervisão. Pablo Gontijo: Escrita – revisão e edição, Metodologia, Supervisão. Ruy de Oliveira: Escrita – revisão e edição, Escrita – redação original, Visualização, Validação, Software, Metodologia, Investigação, Análise formal, Curadoria de dados, Conceituação. Mario de Oliveira: Escrita – revisão e edição, Escrita – redação original, Visualização, Validação, Software, Metodologia, Investigação, Análise formal, Curadoria de dados, Conceituação.

Marconi Teixeira: Escrita – revisão e edição, Recursos, Obtenção de financiamento, Conceituação. Sergio Souza Novak: Escrita – revisão e edição, Software, Metodologia, Supervisão. Adriano Soares de Oliveira Bailão – revisão e edição, Software, Metodologia, Supervisão.

Declaração de Conflito de Interesses

Os autores declaram que não possuem interesses financeiros ou pessoais que possam ter influenciado de forma indevida o trabalho relatado neste artigo.

Disponibilidade de Dados

Os dados utilizados nesta pesquisa são confidenciais.

Agradecimentos

Esta pesquisa recebeu apoio financeiro do Ministério da Ciência, Tecnologia e Inovação (MCTI), da Financiadora de Estudos e Projetos (FINEP), da Fundação de Amparo à Pesquisa do Estado de Goiás (FAPEG), do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), do Centro de Excelência em Agricultura Exponencial (CEAGRE), do Instituto Federal de Educação, Ciência e Tecnologia Goiano (IF Goiano) — Campus Rio Verde e do Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso (IFMT).

Referências

- [1] S. Savary, A. Ficke, J.-N. Aubertot, C. Hollier, The global burden of pathogens and pests on major food crops, *Nature Ecology Evolution* 3 (3) (2019) 430–439, dados da FAO: cerca de 40 doi:10.1038/s41559-018-0793-y.
- [2] D. Pimentel (Ed.), *Techniques for Reducing Pesticide Use: Economic and Environmental Benefits*, John Wiley Sons, Chichester, 1997. doi:10.1002/9780470510505. URL <https://doi.org/10.1002/9780470510505>
- [3] D. Pimentel, Pesticides and pest control, in: R. Peshin, A. K. Dhawan (Eds.), *Integrated Pest Management: Innovation-Development Process: Volume 1*, Springer Netherlands, Dordrecht, 2009, pp. 83–87. doi:10.1007/978-1-4020-8992-3_3. URL https://doi.org/10.1007/978-1-4020-8992-3_3

[4] E. C. Tetila, B. L. Moro, G. Astolfi, A. B. da Costa, W. P. Amorim, N. A. de Souza Belete, H. Pistori, J. G. A. Barbedo, Real-time detection of weeds by species in soybean using uav images, *Crop Protection* 184 (2024) 106846. doi:<https://doi.org/10.1016/j.cropro.2024.106846>.

URL <https://www.sciencedirect.com/science/article/pii/S0261219424002746>

[5] G. P. S. de Almeida, L. N. S. dos Santos, L. R. da Silva Souza, P. da Costa Gontijo, R. de Oliveira, M. C. Teixeira, M. De Oliveira, M. B. Teixeira, H. F. do Carmo França, Performance analysis of yolo and detectron2 models for detecting corn and soybean pests employing customized dataset, *Agronomy* 14 (10) (2024). doi:10.3390/agronomy14102194.

URL <https://www.mdpi.com/2073-4395/14/10/2194>

[6] C. Zhou, W. S. Lee, S. Zhang, O. E. Liburd, A. Pourreza, J. K. Schueller, Y. Ampatzidis, A smartphone application for site-specific pest management based on deep learning and spatial interpolation, *Computers and Electronics in Agriculture* 218 (2024) 108726. URL <https://www.sciencedirect.com/science/article/pii/S0168169924001170>

[7] A. Voulodimos, N. Doulamis, A. Doulamis, E. Protopapadakis, Deep learning for computer vision: A brief review, *Computational Intelligence and Neuroscience* 2018 (1) (2018) 7068349. URL <https://onlinelibrary.wiley.com/doi/abs/10.1155/2018/7068349>

[8] A. Upadhyay, N. S. Chandel, K. P. Singh, S. K. Chakraborty, B. M. Nandede, M. Kumar, A. Subeesh, K. Upendar, A. Salem, A. Elbeltagi, Deep learning and computer vision in plant disease detection: a comprehensive review, *Artificial Intelligence Review* 58 (3) (2025) 92. URL <https://doi.org/10.1007/s10462-024-11100-x>

[9] M. E. Karar, F. Alsunaydi, S. Albusaymi, S. Alotaibi, A new mobile application of agricultural pests recognition using deep learning in cloud computing system, *Alexandria Engineering Journal* 60 (5) (2021) 4423–4432. doi:<https://doi.org/10.1016/j.aej.2021.03.009>.

URL <https://www.sciencedirect.com/science/article/pii/S1110016821001642>

[10] F. Han, X. Guan, M. Xu, Method of intelligent agricultural pest image recognition based on machine vision algorithm, *Discover Applied Sciences* 6 (10) (2024) 536. URL <https://doi.org/10.1007/s42452-024-06224-2>

- [11] J. Luo, B. Li, C. Leung, A survey of computer vision technologies in urban and controlled-environment agriculture, *ACM Computing Surveys* 56 (5) (2023). doi:10.1145/3626186. URL <https://doi.org/10.1145/3626186>
- [12] L. Ahmad, F. Nabi, *Agriculture 5.0: artificial intelligence, IoT and machine learning*, CRC Press, 2021.
- [13] S. Ghazal, A. Munir, W. S. Qureshi, Computer vision in smart agriculture and precision farming: Techniques and applications, *Artificial Intelligence in Agriculture* 13 (2024) 64–83. doi:<https://doi.org/10.1016/j.aiia.2024.06.004>. URL <https://www.sciencedirect.com/science/article/pii/S2589721724000266>
- [14] . Guo, Y. Geng, C. Wang, Y. Xue, D. Sun, Z. Lou, T. Chen, T. Geng, L. Quan, Instacropnet: An efficient unet-based architecture for precise crop row detection in agricultural applications, *Artificial Intelligence in Agriculture* 12 (2024) 85–96. doi:<https://doi.org/10.1016/j.aiia.2024.05.002>. URL <https://www.sciencedirect.com/science/article/pii/S2589721724000175>
- [15] H. Tian, T. Wang, Y. Liu, X. Qiao, Y. Li, Computer vision technology in agricultural automation —a review, *Information Processing in Agriculture* 7 (1) (2020) 1–19. doi:<https://doi.org/10.1016/j.inpa.2019.09.006>. URL <https://www.sciencedirect.com/science/article/pii/S2214317319301751>
- [16] G. Hou, H. Chen, M. Jiang, R. Niu, An overview of the application of machine vision in recognition and localization of fruit and vegetable harvesting robots, *Agriculture* 13 (9) (2023). doi:10.3390/agriculture13091814. URL <https://www.mdpi.com/2077-0472/13/9/1814>
- [17] Aplicações de visão computacional e aprendizado de máquina na agricultura: um vislumbre do estado da arte,in: Conferência Internacional de 2022 sobre Tendências Inovadoras em Tecnologia da Informação (ICITIIT). doi:10.1109/ICITIIT54346.2022.9744150.
- [18] A. Paul, R. Machavaram, Ambuj, D. Kumar, H. Nagar, Smart solutions for capsicum harvesting: Unleashing the power of yolo for detection, segmentation, growth stage classification, counting, and real-time mobile identification, *Computers and Electronics*

in Agriculture 219 (2024) 108832. doi:<https://doi.org/10.1016/j.compag.2024.108832>.
URL <https://www.sciencedirect.com/science/article/pii/S0168169924002230>

[19] Z. Zhang, Y. Yang, X. Xu, L. Liu, J. Yue, R. Ding, Y. Lu, J. Liu, H. Qiao, Gvc-yolo: A lightweight real-time detection method for cotton aphid-damaged leaves based on edge computing, Remote Sensing 16 (16) (2024). doi:10.3390/rs16163046.
URL <https://www.mdpi.com/2072-4292/16/16/3046>

[20] A. Nkonjoh, J. Kaze, R. Nwokam, B. Njotsa, A. Kuate, A. Tchouta, S. Babagniack, Yolo-agrinet: A deep learning-based model for real-time plant disease detection in precision agriculture, Journal of Computer and Communications 13 (2025).181–204. doi:10.4236/jcc.2025.138009.

[21] N. Wang, S. Fu, Q. Rao, G. Zhang, M. Ding, Insect-yolo: A new method of crop insect detection, Computers and Electronics in Agriculture 232 (2025) 110085. doi:<https://doi.org/10.1016/j.compag.2025.110085>.
URL <https://www.sciencedirect.com/science/article/pii/S0168169925001917>

[22] K. Qin, J. Zhang, Y. Hu, Identification of insect pests on soybean leaves based on sp-yolo, Agronomy 14 (7) (2024). doi:10.3390/agronomy14071586.
URL <https://www.mdpi.com/2073-4395/14/7/1586>

[23] M. Vilar-Andreu, L. García, A.-J. Garcia-Sanchez, R. Asorey Cacheda, J. Garcia-Haro, Enhancing precision agriculture pest control: A generalized deep learning approach with yolov8-based insect detection, IEEE Access PP (2024) 1–1. doi:10.1109/ACCESS.2024.3413979.

[24] S. Verma, S. Tripathi, A. Singh, M. Ojha, R. R. Saxena, Insect detection and identification using yolo algorithms on soybean crop, in: TENCON 2021 - 2021 IEEE Region 10 Conference (TENCON), 2021, pp. 272–277. doi:10.1109/TENCON54134.2021.9707354.

[25] W. S. R. Souza, A. N. Alves, D. L. Borges, A deep learning model for recognition of pest insects in maize plantations, in: 2019 IEEE International Conference on Systems, Man and Cybernetics (SMC), 2019, pp. 2285–2290. doi:10.1109/SMC.2019.8914428.

- [26] S. Nawoya, F. Ssemakula, R. Akol, Q. Geissmann, H. Karstoft, K. Bjerger, C. Mwikirize, A. Katumba, G. Gebreyesus, Computer vision and deep learning in insects for food and feed production: A review, *Computers and Electronics in Agriculture* 216 (2024) 108503. doi:<https://doi.org/10.1016/j.compag.2023.108503>. URL <https://www.sciencedirect.com/science/article/pii/S0168169923008918>
- [27] Y. S. Sahin, N. S. Gençer, H. Sahin, Integrating ai detection and language models for real-time pest management in tomato cultivation, *Frontiers in Plant Science* 15 (2025). doi:10.3389/fpls.2024.1468676. URL <https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2024.1468676>
- [28] X. Xu, J. Shi, Y. Chen, Q. He, L. Liu, T. Sun, R. Ding, Y. Lu, C. Xue, H. Qiao, Research on machine vision and deep learning based recognition of cotton seedling aphid infestation level, *Frontiers in Plant Science* Volume 14 - 2023 (2023). doi:10.3389/fpls.2023.1200901. URL <https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2023.1200901>
- [29] C. Yu, J. Feng, Z. Zheng, J. Guo, Y. Hu, A lightweight sod-yolov5n model-based winter jujube detection and counting method deployed on android, *Computers and Electronics in Agriculture* 218 (2024) 108701. doi:<https://doi.org/10.1016/j.compag.2024.108701>. URL <https://www.sciencedirect.com/science/article/pii/S0168169924000929>
- [30] C. Alcaide Zaragoza, R. González Perea, I. Fernández García, E. Camacho Poyato, J. A. Rodríguez Díaz, Open source application for optimum irrigation and fertilization using reclaimed water in olive orchards, *Computers and Electronics in Agriculture* 173 (2020) 105407. doi:<https://doi.org/10.1016/j.compag.2020.105407>. URL <https://www.sciencedirect.com/science/article/pii/S0168169920301022>
- [31] M. Tkachenko, M. Malyuk, A. Holmanyuk, N. Liubimov, Label studio:open source data labeling platform, <https://github.com/heartexlabs/label-studio>, acessado em 20 de Janeiro de 2025 (2020).
- [32] G. Jocher, J. Qiu, Ultralytics yolo11 (2024). URL <https://github.com/ultralytics/ultralytics>

- [33] R. Khanam, M. Hussain, Yolov11: An overview of the key architectural enhancements (2024). arXiv:2410.17725. URL <https://arxiv.org/abs/2410.17725>
- [34] A. Evan, M. Sarosa, R. A. Asmara, M. Kusumawardani, D. F. Al Riza, Y. M. Azis, Detection and counting of grape leaves using yolov8 via tflite on mobile applications, in: 2024 International Conference on Electrical and Information Technology (IEIT), 2024, pp. 246–251. doi:10.1109/IEIT64341.2024.10763328.
- [35] S. Oumaima, L. Mohamed, B. Abderrahmane, M. Iyass, Enviscan+: Ai-driven plant identification and eco-system management for sustainable agriculture, *SoftwareX* 30 (2025) 102182. doi:<https://doi.org/10.1016/j.softx.2025.102182>. URL <https://www.sciencedirect.com/science/article/pii/S2352711025001499>
- [36] M. Seethalam, K. G. Bapatla, M. Kumar, S. Nisa, P. Chandra, P. Mathyam, V. Sengottaiyan, Characterization of helicoverpa armigera spatial distribution in pigeonpea crop using geostatistical methods, *Pest Management Science* 77 (11) (2021) 4942–4950. arXiv:<https://scijournals.onlinelibrary.wiley.com/doi/pdf/10.1002/ps.6536>, doi:<https://doi.org/10.1002/ps.6536>. URL <https://scijournals.onlinelibrary.wiley.com/doi/abs/10.1002/ps.6536>
- [37] J. Heusler, J. Funk, A. Wagner, Spatial interpolation in applied insect ecology: A review, including guidelines and datasets for practical use, *Journal of Applied Entomology* n/a (n/a). arXiv:<https://onlinelibrary.wiley.com/doi/pdf/10.1111/jen.13455>, doi:<https://doi.org/10.1111/jen.13455>. URL <https://onlinelibrary.wiley.com/doi/abs/10.1111/jen.13455>
- [38] K. H. Cho, J.-S. Park, J. H. Kim, Y. S. Kwon, D.-H. Lee, Modeling the distribution of invasive species (ambrosia spp.) using regression kriging and maxent, *Frontiers in Ecology and Evolution* Volume 10 - 2022 (2022). doi:10.3389/fevo.2022.1036816. URL <https://www.frontiersin.org/journals/ecology-and-evolution/articles/10.3389/fevo.2022.1036816>
- [39] R. L. Wheeler, J. S. Miller, G. N. Smith, J. H. Lambert, C. A. Pennetti, G. E. Louis, D. A. Johnson, Geospatial analysis of extreme temperature impacts in agricultural systems using machine learning, in: 2024 IEEE International Symposium on Systems Engineering (ISSE), 2024, pp. 1–8. doi:10.1109/ISSE63315.2024.10741115.

[40] W. Xu, R. Yang, R. Karthikeyan, Y. Shi, Q. Su, Gbidc-pest: A novel lightweight model for real-time multiclass tiny pest detection and mobile platform deployment, *Journal of Integrative Agriculture* 24 (7) (2025) 2749–2769. doi:<https://doi.org/10.1016/j.jia.2024.12.017>.

URL <https://www.sciencedirect.com/science/article/pii/S209531192400426X>

[41] Y. Tang, F. Luo, P. Wu, J. Tan, L. Wang, Q. Niu, H. Li, P. Wang, An improved yolo network for small target insects detection in tomato fields, *Computers and Electronics in Agriculture* 239 (2025) 110915. doi:<https://doi.org/10.1016/j.compag.2025.110915>.

URL <https://www.sciencedirect.com/science/article/pii/S016816992501021X>

[42] A. Kargar, D. Zorbas, M. Gaffney, B. O’Flynn, S. Tedesco, Tiny deep learning model for insect segmentation and counting on resource-constrained devices, *Computers and Electronics in Agriculture* 236 (2025) 110378. doi:<https://doi.org/10.1016/j.compag.2025.110378>.

URL <https://www.sciencedirect.com/science/article/pii/S0168169925004843>

[43] F. Moral García, Analysis of the spatio-temporal distribution of *helicoverpa armigera* hb. In a tomato field using a stochastic approach, *Biosystems Engineering* 93 (3) (2006) 253–259. doi:<https://doi.org/10.1016/j.biosystemseng.2005.12.011>.

URL <https://www.sciencedirect.com/science/article/pii/S1537511005003016>

CONCLUSÃO GERAL

Esta tese apresentou o desenvolvimento integrado de um sistema inteligente para detecção e monitoramento espacial de insetos-praga em lavouras de soja e milho, combinando modelos avançados de visão computacional, bases de dados especializadas e técnicas de geoestatística. A abordagem proposta contemplou desde a construção e curadoria do conjunto de dados AgroInsect, passando pelo treinamento e avaliação de modelos de *deep learning*, até a implementação de um aplicativo móvel capaz de realizar inferências embarcadas e gerar mapas de incidência em tempo quase real.

A experimentação conduzida com diferentes versões dos modelos YOLO (v5, v7, v8, v9-gelan e v9-c) e com o Detectron2 demonstrou que é possível alcançar elevado desempenho mesmo em cenários de recursos limitados. Os resultados obtidos com o conjunto de dados completo (AgroInsect) confirmaram a robustez dos modelos, mas um achado relevante foi que o uso de um conjunto reduzido (Reduced), composto por apenas 100 imagens por espécie, não comprometeu significativamente a acurácia. Modelos como o YOLOv9-c e o YOLOv9-gelan apresentaram diferenças de apenas 0,03% e 1,96% entre os conjuntos completo e reduzido, reforçando que, com curadoria adequada, é possível treinar redes de alta performance mesmo com bases menores. Esse resultado representa um avanço importante, pois facilita a inclusão de novas espécies de insetos em futuras versões do sistema, permitindo escalabilidade com baixo custo de anotação.

A conversão dos melhores modelos para os formatos TFLite e ONNX confirmou a viabilidade de execução eficiente em dispositivos de borda, como smartphones. Em particular, o YOLOv5 mostrou redução mínima de desempenho após a conversão, e o YOLOv7 chegou a apresentar melhoria com o conjunto de dados reduzido. Esses achados ressaltam que o emprego de modelos leves em campo não é apenas factível, mas desejável para soluções que exigem operação offline, baixa latência e baixo consumo energético.

A implementação do aplicativo AgroInsect consolidou o sistema como uma plataforma operacional completa. A detecção embarcada, a extração automática de metadados e a sincronização com a nuvem permitiram o registro padronizado das ocorrências, reduzindo erros humanos e possibilitando análises integradas. A validação geográfica das detecções garantiu coerência espacial, evitando registros inconsistentes e aumentando a confiabilidade das informações coletadas.

As análises espaciais realizadas por meio da krigagem ordinária revelaram padrões consistentes com a ecologia das espécies avaliadas, indicando áreas de maior incidência e possíveis rotas de dispersão. A geração imediata de mapas de calor e superfícies interpoladas demonstrou o potencial do sistema para apoiar o manejo integrado de pragas, fornecendo aos produtores informações claras, objetivas e espacialmente explícitas para intervenções mais eficientes e sustentáveis.

Em comparação com soluções disponíveis na literatura e no mercado, o AgroInsect diferencia-se por operar completamente embarcado em *smartphone*, dispensando conexão contínua com a internet e permitindo uso em propriedades rurais com infraestrutura limitada. A integração entre detecção, validação espacial, armazenamento estruturado e análise geoestatística torna a plataforma uma ferramenta completa, moderna e aplicável em situações reais de campo.

Como desdobramentos futuros, recomenda-se a incorporação de covariáveis ambientais, como índices de vegetação, umidade do solo e variáveis climáticas, com o objetivo de aprimorar a precisão das estimativas em contextos de baixa densidade amostral. Sugere-se também a adoção de estratégias de aprendizado ativo, permitindo que o próprio sistema selecione novas imagens relevantes para rotulagem, acelerando o processo de adaptação a diferentes condições morfológicas, luminosas e ambientais. Além disso, a inclusão de imagens provenientes de armadilhas amarelas, luminosa e feromônios ampliará a capacidade do modelo de lidar com cenários visuais mais desafiadores, contribuindo para uma solução ainda mais robusta.

Em síntese, o sistema proposto — composto pelo *dataset* AgroInsect, pelos modelos YOLO otimizados e pelo aplicativo móvel AgroInsect — representa uma contribuição significativa para o avanço da Agricultura 4.0. Ao integrar detecção embarcada, validação espacial e análise geoestatística em um único ecossistema operacional, a tese demonstra que é possível viabilizar soluções inteligentes, escaláveis e de alto desempenho para o monitoramento automatizado de pragas agrícolas. Essa abordagem abre caminho para novas investigações e aplicações capazes de transformar estratégias de manejo integrado, promovendo maior eficiência, sustentabilidade e precisão na produção agrícola.