

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E
TECNOLOGIAGOIANO - CAMPUS CERES
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM IRRIGAÇÃO NO
CERRADO

MODELOS DE APRENDIZAGEM PROFUNDA PARA
DETECÇÃO E SEGMENTAÇÃO DE PLANTAS DANINHAS
COM IMAGENS OBTIDAS POR UAV

Autor: Josef Augusto Oberdan Souza Silva

Orientador: Prof. Dr. Henrique Fonseca Elias de Oliveira

Coorientador: Prof. Dr. Luís Sérgio Rodrigues Vale

Ceres - GO

Março – 2024

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E
TECNOLOGIAGOIANO - CAMPUS CERES
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM IRRIGAÇÃO NO
CERRADO

MODELOS DE APRENDIZAGEM PROFUNDA PARA
DETECÇÃO E SEGMENTAÇÃO DE PLANTAS DANINHAS
COM IMAGENS OBTIDAS POR UAV

Autor: Josef Augusto Oberdan Souza Silva

Orientador: Prof. Dr. Henrique Fonseca Elias de Oliveira

Coorientador: Prof. Dr. Luís Sérgio Rodrigues Vale

Dissertação apresentada, como parte das exigências para obtenção do título de MESTRE EM IRRIGAÇÃO NO CERRADO, ao Programa de Pós-Graduação em Irrigação no Cerrado, do Instituto Federal de Educação, Ciência e Tecnologia Goiano – Campus Ceres. Área de concentração: Tecnologias de Irrigação.

Ceres - GO

Março – 2024

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E
TECNOLOGIAGOIANO - CAMPUS CERES
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM IRRIGAÇÃO NO
CERRADO

MODELOS DE APRENDIZAGEM PROFUNDA PARA
DETECÇÃO E SEGMENTAÇÃO DE PLANTAS DANINHAS
COM IMAGENS OBTIDAS POR UAV

Autor: Josef Augusto Oberdan Souza Silva

Orientador: Prof. Dr. Henrique Fonseca Elias de Oliveira

Coorientador: Prof. Dr. Luís Sérgio Rodrigues Vale

TITULAÇÃO: Mestre em Irrigação no Cerrado – Área de concentração:
Tecnologias de Irrigação

Aprovada em 27 de março de 2024

Lorena Nunes Lacerda
University of Georgia
Formosa

Leomar Rufino Alves Júnior
Instituto Federal de Goiás – Campus

Marcio Mesquita
Universidade Federal de Goiás

Henrique F. E. de Oliveira – IF Goiano
(Orientador – IF Goiano)

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema Integrado de Bibliotecas (SIBI) – Instituto Federal Goiano

S586m

Silva, Josef Augusto Oberdan Souza.

Modelos de Aprendizagem Profunda para Detecção e Segmentação de Plantas Daninhas com Imagens Obtidas por UAV [manuscrito] / Josef Augusto Oberdan Souza Silva. -- Ceres, GO: IF Goiano, 2024.

113 fls. : tabs.

Orientador: Prof. Dr. Henrique Fonseca Elias de Oliveira.

Co-orientador: Prof. Dr. Luís Sérgio Rodrigues Vale.

Dissertação (Mestrado em Irrigação no Cerrado) – Instituto Federal Goiano, Campus Ceres, 2024.

1. Agricultura de precisão. 2. Algoritmos de segmentação. 3. Inteligência artificial. 4. Modelos de aprendizagem. 5. Veículo aéreo não tripulado. I. Oliveira, Henrique Fonseca Elias de. II. Vale, Luís Sérgio Rodrigues. I. Título.

CDU 631::004.5

À minha mãe, Dolores, por todo amor e carinho
e por me mostrar que sempre é possível
realizar os sonhos quando há
esforço e dedicação,

DEDICO

AGRADECIMENTOS

Agradeço a Deus, por minha saúde, família e amigos e por sempre me guiar durante os momentos difíceis da vida.

Em especial, à minha mãe, Dolores Durci de Souza, que sempre esteve do meu lado, me incentivando em todos os momentos da vida.

Ao meu orientador, Prof. Dr. Henrique Fonseca Elias de Oliveira, por acreditar em mim, pelo tempo, paciência e por transmitir seus conhecimentos.

A meu coorientador, Prof. Dr. Luís Sérgio Rodrigues Vale, que me incentivou no início do mestrado e me auxiliou em momentos importantes durante o processo.

Aos professores, Prof. Dr. Jhon Lennon Bezerra da Silva e Prof. MSc Vilson Soares de Siqueira, pelo auxílio durante todo o projeto.

Ao Instituto Federal Goiano – Campus Ceres, por me proporcionar os meios para realizar o curso de Mestrado em Irrigação no Cerrado.

A todos os professores do Curso de Pós-Graduação em Irrigação no Cerrado, em especial ao Dr. Roriz Luciano Machado, Dr. Cleiton Mateus Sousa, Dr. Antonio Evami Cavalcante Sousa e Dra. Eliane Vieira Rosa.

Aos amigos conquistados durante o curso de Mestrado, por toda a paciência que tiveram comigo e pelos bons momentos.

Aos bolsistas Thiago Nascimento e João Paulo e à servidora Ana Paula Santos Oliveira, pelas horas dedicadas na execução do projeto em campo, pois eu não conseguiria sem a ajuda de vocês.

A todos aqueles que de alguma forma contribuíram para a realização deste trabalho, muito obrigado.

BIOGRAFIA DO AUTOR

JOSEF AUGUSTO OBERDAN SOUZA SILVA, filho de Dolores Durci de Souza Silva e Paulo Oberda da Silva, nasceu em 05 de setembro de 1994 em Goiânia-GO. Em 2014, ingressou no curso de Engenharia da Computação na Pontifícia Universidade Católica de Goiás (PUC - GO), tendo recebido no ano de 2019 o título de Bacharel em Engenharia da Computação. Em 2021, iniciou os estudos no curso de Especialização em Informática Forense pelo Instituto de Pós-Graduação e Graduação (IPOG), concluindo no ano de 2022. Ainda em 2022, iniciou o curso de Mestrado em Irrigação no Cerrado, no Instituto Federal Goiano - Campus Ceres, Área de Concentração: Tecnologias de Irrigação.

ÍNDICE

	Página
RESUMO GERAL.....	xviii
GENERAL ABSTRACT	xix
1. INTRODUÇÃO GERAL.....	1
2. OBJETIVOS.....	3
2.1. Geral.....	3
2.2. Específicos	3
3. REFERÊNCIAS BIBLIOGRÁFICAS GERAIS.....	88
CAPÍTULO I – INTELIGÊNCIA ARTIFICIAL APLICADA À DECISÕES AGRONÔMICAS NA ANÁLISE AÉREA AUTOMÁTICA DE IMAGENS CAPTURADAS POR UAV: UMA REVISÃO SISTEMÁTICA.....	
	4
RESUMO.....	4
ABSTRACT.....	5
1. INTRODUÇÃO.....	6
2. MATERIAL E MÉTODOS.....	7
2.1. Planejamento da pesquisa.....	7
2.2. Seleção dos artigos	8
3. REVISÃO DA LITERATURA	11
3.1. Planta daninha.	12
3.2. Deficiência nutricional.....	17
3.3. Estresse hídrico.....	18
3.4. Doença em planta.....	20
3.5. Praga agrícola.....	24
3.6. Estimativa de produtividade.....	25
4. RESULTADOS E DISCUSSÃO.....	31
4.1. Percentual de pesquisas da RSL conforme as técnicas que automatizam processos agrícolas.....	31

4.2. Respostas para as questões de pesquisa.....	31
5. CONCLUSÃO	42
6. REFERÊNCIAS BIBLIOGRÁFICAS.....	43
CAPÍTULO II: APRENDIZADO DE MÁQUINA PROFUNDO PARA DETECÇÃO E SEGMENTAÇÃO DE PLANTAS DANINHAS EM CULTURAS AGRÍCOLAS USANDO IMAGENS CAPTURADAS POR UAV (UNMANNED AERIAL VEHICLE)	54
RESUMO.....	54
ABSTRACT.....	55
1. INTRODUÇÃO.....	56
2. MATERIAL E MÉTODOS.....	58
2.1. Experimento de campo	58
2.2. Etapas de processamento e segmentação de plantas daninhas	59
2.3. Aquisição das imagens RGB	60
2.3.1. Anotação do conjunto de dados.....	61
2.3.2. Redimensionamento das imagens	62
2.3.3. Aplicação da técnica <i>Data Augmentation</i>	63
2.3.4. Geração de máscaras do conjunto de dados.....	65
2.4. Modelos	66
2.4.1. You Only Look Once (YOLO).....	66
2.4.2. Detectron2.....	67
2.4.3. U-Net	68
2.5. Parâmetros dos modelos e configurações.....	69
2.6. Métricas de validação	71
2.6.1. Cálculos de desempenho dos modelos.....	71
3. RESULTADOS	73
3.1. Desempenho de diferentes backbones e variantes de modelos	73
3.2. Desempenho de diferentes épocas de treinamento	75
4. DISCUSSÃO	79
4.1. Desempenho de diferentes backbones e variantes de modelos	80
4.2. Desempenho de diferentes épocas de treinamento.....	80

5. CONCLUSÃO	82
6. REFERÊNCIAS BIBLIOGRÁFICAS.....	83
4. CONCLUSÃO GERAL	88

ÍNDICE DE TABELAS

Página

CAPÍTULO I

Tabela 1. Artigos selecionados por ano de publicação e principais bases bibliográficas utilizadas	11
Tabela 2. Artigos incluídos na RSL – Planta daninha.	32
Tabela 3. Artigos incluídos na RSL – Deficiência nutricional	34
Tabela 4. Artigos incluídos na RSL – Estresse hídrico.	34
Tabela 5. Artigos incluídos na RSL – Doença em planta	35
Tabela 6. Artigos incluídos na RSL – Praga agrícola.	37
Tabela 7. Artigos incluídos na RSL – Estimativa de produtividade.....	37

CAPÍTULO II

Tabela 1. Conjunto de dados Bean Soy Dataset.	80
Tabela 2. Conjunto de dados após divisão, redimensionamento e aumento das imagens.....	84
Tabela 3. Parâmetros de ambiente de software e hardware..	89
Tabela 4. Parâmetros de treinamento de modelos de segmentação de instâncias, YOLOv8, YOLOv7 e YOLOv5.	89
Tabela 5. Hiperparâmetros de treinamento de modelo de segmentação de instância Mask R-CNN com detectron2.	90
Tabela 6. Hiperparâmetros de treinamento de modelo de segmentação de instâncias U-Net.	90
Tabela 7. Pontuações de precisão, recall e mAP das variantes YOLOv8, treinadas por 500 épocas. Os maiores resultados estão em negrito....	93
Tabela 8. Pontuações de precisão, recall e mAP dos modelos YOLOv8s, YOLOv7 e YOLOv5s em 500 épocas. Os maiores resultados estão em negrito	94
Tabela 9. Pontuações de acurácia, mAP e F1-Score dos modelos YOLOv8s,	

YOLOv7 e YOLOv5s em 500 épocas. Os maiores resultados estão em negrito	94
Tabela 10. Pontuações de acurácia, mAP e F1-Score dos modelos YOLOv8s, YOLOv7 e YOLOv5s, treinados em diferentes épocas. Os maiores resultados estão em negrito.	95
Tabela 11. Pontuações de acurácia e precisão dos modelos YOLOv8s, YOLOv7 e YOLOv5s em diferentes épocas. Os maiores resultados estão em negrito..	95
Tabela 12. Pontuações Acc e AP do modelo Mask R-CNN com detectron2 em diferentes backbones. Os maiores resultados estão em negrito	96
Tabela 13. Pontuações de AP do modelo Mask R-CNN com detectron2 em diferentes backbones. Os maiores resultados estão em negrito.	96
Tabela 14. Pontuações de acurácia, perda de treinamento e validação do modelo U-Net em diferentes épocas. Os maiores resultados estão em negrito.	97
Tabela 15. Pontuações de acurácia, AP e recall de todos os modelos e suas variantes. Os maiores resultados estão em negrito	99

ÍNDICE DE FIGURAS

	Página
CAPÍTULO I	
Figura 1. Etapas de seleção da RSL, adaptado de Siqueira <i>et al</i> (2021)	09
Figura 2. Fluxograma da extração de dados e destaques de sequência da RSL, adaptado de Siqueira <i>et al.</i> (2021)	11
Figura 3. Exemplo de saída de dados após o treinamento do modelo YOLOv7 para segmentação de plantas daninhas em culturas agrícolas comerciais.....	14
Figura 4. Número de artigos e cronologia de publicações por tipo de problema agrônomo..	41
Figura 5. Número de artigos publicados e plataformas científicas por tipo de problema agrônomo.	42
CAPÍTULO II	
Figura 1. Área experimental, cultivada com soja e feijoeiro no Instituto Federal Goiano – <i>Campus Ceres</i> , Goiás, Brasil.....	59
Figura 2. Fluxo do processo de treinamento para segmentação de plantas daninhas. Etapas: (1) imagens rotuladas e redimensionadas usando a ferramenta Roboflow; (2) imagens aumentadas e treinadas nos modelos U-Net, YOLO e Detectron2; (3) métricas de validação usadas nos modelos treinados; e (4) teste de campo do modelo com maior eficiência.....	60
Figura 3. Isolamento de objetos do conjunto de imagens.....	61
Figura 4. Redimensionamento das imagens.....	63
Figura 5. Aumento do conjunto de dados de imagens.....	64
Figura 6. Imagens RGB (512x512) rotuladas para o <i>Ground Truth</i> . Criação de máscaras: a) imagem RGB anotada e redimensionada; b) máscara criada: cor branca, plantas daninhas; e cor preta, ausência das plantas daninhas na imagem.....	66

Figura 7. Arquitetura YOLOv8.....	67
Figura 8. Arquitetura do <i>framework</i> Detectron2.....	68
Figura 9. Arquitetura U-Net.....	69
Figura 10. Comparação de máscaras de segmentação previstas e reais entre algoritmos de segmentação de instâncias e suas variantes: (a) YOLOv8s, YOLOv7 e YOLOv5s; (b) Mask R-CNN (Detectron2) e seus diferentes backbones.....	78
Figura 11. Resultados de treinamento para os modelos de segmentação de instâncias: (a) precisão dos modelos YOLOv8s, YOLOv7 e YOLOv5s em 500 épocas; (b) acurácia do modelo Mask R-CNN (Detectron2) e suas variantes, em 20.000 iterações.....	78

LISTA DE SÍMBOLOS, SIGLAS, ABREVIACÕES E UNIDADES

Símbolo /Sigla	Significado	Unidade de Medida
%	Porcentagem	
ACM	Association for Computing Machinery	
IEEE	Institute of Electrical and Electronics Engineers	
MDPI	Multidisciplinary Digital Publishing Institute	
SP	Supervisionado	
NSP	Não supervisionado	
MTD/TNQ	Método/técnica	
LT	Tipo de aprendizado	
R	Correlation	
IoU	Intersection over Union	
M/MGT(%)	Master of management	
F1-Score	F-beta Score	
NN	Neural Network	
RGB	Red, Green e Blue	
RF	Random Forest	
Acc	Acurácia	
mAP	Mean Average Precision	
R	Regression	
MLP	Multi-Layer Perceptron	
CNN	Convolutional Neural Network	
SVM	Support vector machine	
KNN	K-nearest neighbors	
XGBoost	Extreme gradient boosting	
ENR	Elastic net	
GLM	General linear model	
RLM	Robust linear model	
ANN	Artificial neural network	
MLR	Multivariate linear regression	

CRT	Classification and regression tree	
RMSE	Mean-normalized root mean square error	g/m^2
NRMSE	Mean-normalized root mean square error	
PLS	Partial least squares	
GBDT	Gradient boosting decision tree	
VddNet	Vine disease detection network	
PSPNet	Pyramid scene parsing network	
YOLO	You Only Look Once	
YOLOR	You Only Look Once Representation	
DETR	Detection transformer	
R-CNN	Region-based convolutional neural network	
VGG	Very Deep Convolutional Network	
SLM	Sentence-level language modeling	
MAPE	Mean absolute percentage error	
GBM	Stochastic gradient boosting	
PLSR	Partial least square regression	
GBR	Gradient boosting regression	
CD-CNN	Cross-domain convolutional neural network	
D	Altura	m
ETR	Extra trees regressor	
SVR	Support vector regression	
MLR	Multiple linear regression	
MARS	Multivariate adaptive regression splines	
CHAID	Chi-square automatic interaction detector	
ExCHAID	Exhaustive chi-square automatic interaction detector	
CART	Classification and regression tree	
DNN	Deep neural network	

RRMSE	Relative root mean square error
CPU	Unidade central de processamento
GPU	Unidade de processamento gráfico
RAM	Memória de acesso aleatório
OpenCV	Biblioteca de visão computacional de código aberto
CUDA	Compute unified device architecture
SGD	Stochastic gradient descent
MS COCO Dataset	Conjunto de dados Microsoft coco
M	Mask
B	Bounding box
AP	Average Precision
API	Average Precision large
AR	Average Recall
UAV	Unmanned Aerial Vehicle

RESUMO GERAL

SILVA, JOSEF AUGUSTO OBERDAN SOUZA. Instituto Federal Goiano – *Campus Ceres* – GO, março de 2024. **Modelos de Aprendizagem Profunda para Detecção e Segmentação de Plantas Daninhas com Imagens Obtidas por UAV**. Orientador: Dr. Henrique Fonseca Elias de Oliveira. Coorientador: Dr. Luís Sérgio Rodrigues Vale.

Plantas daninhas competem por recursos naturais e interferem no desenvolvimento das plantas comerciais presentes na área. Com o avanço de tecnologias com aprendizado de máquina profundo, surgiram estudos que propõem detectar, classificar e monitorar plantas daninhas em culturas agrícolas para o manejo e controle. Dada a relevância do assunto, este estudo teve como objetivo proceder a uma revisão dos principais estudos com aplicação de aprendizado de máquina profundo em culturas agrícolas e avaliar a aplicação destes modelos para a detecção e segmentação de plantas daninhas em imagens capturadas por UAV. O estudo contribui para o campo da visão computacional com uma revisão dos estudos recentes sobre a aplicação, comparação e desempenho de três modelos com arquiteturas diferentes entre si e torna público o conjunto de dados com imagens aéreas de culturas de soja e feijão. O conjunto de dados foi anotado, redimensionado e aumentado, usando a interface de aplicação Roboflow e, posteriormente, treinado. YOLO, Mask R-CNN com Detectron2 e U-Net foram treinados e avaliados usando as métricas de validação mAP50, mAP50-90, precisão, acurácia e recall e, em seguida, comparados entre si. A variante YOLOv8s obteve maior desempenho, com maior valor de mAP50 de 97%, recall de 99% e precisão de 99,7%, em comparação com os demais modelos. A comparação dos resultados dos diferentes modelos de aprendizagem profunda, neste estudo, demonstrou grande potencial no uso de algoritmos avançados de aprendizagem profunda para segmentação de plantas invasoras.

PALAVRAS-CHAVE: Agricultura de precisão, algoritmos de segmentação, inteligência artificial, modelos de aprendizagem.

GENERAL ABSTRACT

SILVA, JOSEF AUGUSTO OBERDAN SOUZA. Goiano Federal Institute, Ceres Campus, Goiás State (GO), Brazil, March 2024. **Deep Learning Models for Weed Detection and Segmentation with Images Obtained by UAV.** Advisor: Prof. PhD Oliveira, Henrique Fonseca Elias de. Co-advisor: Prof. PhD Vale, Luís Sérgio Rodrigues.

Weeds compete for natural resources and interfere with the development of business plants present in the area. With the advancement of deep machine learning technology, studies have emerged proposing to detect, classify, and monitor weeds in agricultural crops for management and control. Due to the importance of the subject, this paper aimed to review the main studies applying deep learning to agricultural crops and evaluate the application of these models to detect and segment weeds in images captured by unmanned aerial vehicles (UAVs). This paper contributes to the computer vision field reviewing recent studies about the application, comparison, and performance of three models with different architectures from one another and makes public the dataset with aerial images of soybean and bean crops. The dataset was annotated, resized, and increased by the Roboflow application interface and, subsequently, trained. You Only Look Once (YOLO), Mask R-CNN with Detectron2, and U-Net were trained and evaluated by the mAP50, mAP50-90, precision, accuracy, and recall validation metrics and then compared to each other. The YOLOv8s variant achieved higher performance with a higher mAP50 value of 97%, recall of 99%, and precision of 99.7%, when compared to the other models. The results comparison of the different deep learning models in this paper showed great potential in the use of advanced deep learning algorithms to segment invasive plants.

Keywords: Artificial intelligence. Learning models. Precision agriculture. Segmentation algorithms.

1. INTRODUÇÃO GERAL

As técnicas de aprendizagem de máquina profundo estão se tornando cada vez mais importantes para a automatização de processos agrícolas em aplicações na agricultura de precisão [1-5]. Os modelos de aprendizado de máquina podem contribuir com diversos usos na agricultura, incluindo controle de pragas agrícolas, estimativa de produtividade, deficiência nutricional, estresse hídrico e doenças em plantas, destacando-se a identificação e o monitoramento de plantas daninhas [6-8].

Estudos recentes se dedicam a pesquisar especificamente plantas agrícolas comerciais, no entanto, em função do avanço das técnicas de agricultura de precisão, *drones* agrícolas para aplicação localizada de produtos químicos (fertilizantes, herbicidas) ou para monitoramento de pragas nas culturas começam a se tornar viáveis [44-48].

Nesta vertente, é fundamental a identificação das plantas que crescem espontaneamente em áreas de cultivo e interferem no desenvolvimento das plantas agrícolas comerciais presentes na área e concorrem com recursos naturais, como, por exemplo, água, nutrientes do solo e luz. Tais plantas são vistas como problema por apresentarem alta resistência às adversidades, adaptando-se a ambientes que apresentam estresse hídrico, altos índices de salinidade e acidez no solo, além de ambientes com alta temperatura e umidade desfavoráveis ao cultivo [28].

Neste contexto, os métodos tradicionais de monitoramento de pragas e saúde de culturas envolvem a inspeção visual e a coleta manual de amostras do solo em locais aleatórios [47]. Este tipo de monitoramento pode conter limitações e desafios quando se trata de grandes áreas agrícolas [48]. Por esta razão, os modelos de aprendizado de máquina podem auxiliar na localização de plantas encontradas no local de cultivo, por meio da visão computacional, e colaborar para o seu controle [24,25]. Modelos de aprendizagem profunda (*Deep Learning*) podem ser utilizados para aplicações agrícolas, em função da capacidade de aprender padrões por meio de experiências [11].

Deep Learning (DL) se refere a algoritmos de aprendizado de máquina profundo que usam múltiplas camadas entre a entrada e a saída de uma rede neural para identificar padrões em grandes conjuntos de imagens [10,11]. Diversos modelos de aprendizagem profunda podem ser usados para reconhecimento de padrões, destacando-

se nesta categoria o Mask R-CNN com Detectron2, o YOLO e o U-Net.

Mask R-CNN é um modelo, usado com o *framework* Detectron2, projetado para tarefas de detecção e segmentação de instâncias, o que permite sua integração com diversas redes neurais [33]. Por sua vez, o modelo YOLO (*You Only Look Once*) considera o recurso multiescala dos objetos, usando três camadas de detecção ao dispor de objetos de diferentes escalas, sendo capaz de classificar e identificar objetos examinando uma única vez o conjunto de dados de imagem ou vídeo [29]. O U-Net é um modelo de segmentação de imagens na área médica, com base na rede totalmente convolucional (FCN, sigla em inglês), proposto por Ronneberger, Fisher e Brox [36], que contém somente camadas totalmente convolucionais, composto também por duas unidades principais: codificador (captura o contexto da imagem) e decodificador (permite a localização precisa do objeto na imagem).

Neste sentido, dado o grande potencial do uso de ferramentas de inteligência artificial, na perspectiva de trazer maior eficiência para as práticas agrícolas, há grande relevância em estudos que confirmem a avaliação detalhada do desempenho de algoritmos avançados de aprendizado de máquina profundo para segmentação de objetos, aplicados a análises de dados oriundos do sensoriamento remoto.

2. OBJETIVOS

2.1 Geral

Avaliar o desempenho de algoritmos avançados de aprendizado de máquina profundo para detecção e segmentação de plantas daninhas em imagens RGB (*Red, Green e Blue*) capturados por UAV (*Unmanned Aerial Vehicles*) em cultivos agrícolas.

2.2 Específicos

- Identificar por meio de uma revisão sistemática os principais estudos com aplicação de aprendizado de máquina profundo aplicado às culturas agrícolas;
- Construir um conjunto de dados públicos com imagens RGB capturadas por UAV, em cultivos de plantas de soja e feijão;
- Avaliar o desempenho dos modelos de segmentação de instâncias Mask R-CNN (com *framework* Detectron2), U-Net e YOLO para plantas específicas, comparando-o com outros modelos de aprendizagem de máquina profunda, e suas variantes;
- Realizar teste de múltiplas análises de validação para melhor compreensão sobre o desempenho de diferentes modelos de aprendizagem de máquina profunda;
- Analisar o impacto das técnicas de aumento de dados na avaliação dos modelos Mask R-CNN (com *framework* Detectron2), U-Net e YOLO, apresentando perspectivas futuras.

CAPÍTULO I – INTELIGÊNCIA ARTIFICIAL APLICADA A DECISÕES AGRONÔMICAS NA ANÁLISE AÉREA AUTOMÁTICA DE IMAGENS CAPTURADAS POR UAV: UMA REVISÃO SISTEMÁTICA

(Normas de acordo com a revista Remote Sensing)

RESUMO

A integração entre tecnologias avançadas, como Inteligência Artificial (IA), e práticas agrícolas tradicionais modificou a forma como as atividades são desenvolvidas na área agrícola, visando a automatizar processos manuais, melhorar a eficiência e a qualidade das decisões agrícolas. Com o advento de modelos de aprendizagem profunda, como Rede Neural Convolutacional (CNN) e *You Only Look Once* (YOLO), surgiram também diversos estudos com a necessidade de desenvolver soluções para os problemas, a fim de aproveitar todo o potencial que este tipo de tecnologia tem a oferecer. Esta Revisão Sistemática da Literatura (RSL) teve como objetivo apresentar uma investigação aprofundada da aplicação da IA para apoiar as principais decisões de manejo agrícola em função de plantas daninhas, deficiência nutricional de plantas, deficiência hídrica, pragas agrícolas e doenças de plantas. A extração dos dados dos artigos indicou que o principal interesse de pesquisa dos estudos compreende quatro grupos: 1) Melhoria na Qualidade da Imagem; 2) Extração de recursos de imagem; 3) Quantificação e Análise; e 4) Detecção e Classificação. Os artigos foram categorizados e agrupados para mostrar as principais contribuições da literatura objetivando apoiar decisões agrícolas utilizando IA. Este estudo desta RSL observou que os métodos se comportam melhor no apoio à detecção de ervas daninhas, classificação de doenças de plantas e estimativa da produtividade agrícola nas lavouras ao utilizar imagens capturadas por UAVs. Além disso, CNN e YOLO bem como suas variações apresentam os melhores resultados para todos os grupos apresentados. Esta RSL também aponta as limitações e os desafios potenciais quando se trabalha com modelos de aprendizagem de máquina profundo, visando a contribuir com a sistematização do conhecimento e a beneficiar pesquisadores e profissionais sobre as aplicações da IA na mitigação de problemas agronômicos.

Palavras-chave: Aprendizado profundo, aprendizado de máquina, agricultura de precisão, veículo aéreo não tripulado.

CHAPTER I - ARTIFICIAL INTELLIGENCE APPLIED TO SUPPORT AGRONOMIC DECISIONS FOR THE AUTOMATIC AERIAL ANALYSIS IMAGES CAPTURED BY UAV: A SYSTEMATIC REVIEW

(Standards according to Remote Sensing magazine)

ABSTRACT

The integration of advanced technologies such as Artificial Intelligence (AI) with traditional agricultural practices has changed how activities are developed in the agricultural area, aiming to automate manual processes and improve the efficiency and quality of agricultural decisions. With the advent of deep learning models such as Convolutional Neural Network (CNN) and You Only Look Once (YOLO), many studies have also emerged with the need to develop solutions to problems with the view to take advantage of all potential that this type of technology has to offer. This Systematic Literature Review (SLR) aimed to present an in-depth investigation of the AI application to support the main types of agricultural management due to weeds, plant nutritional deficiency, water deficiency, agricultural pests, and plant diseases. Data extraction from different papers indicated that the main research interests are comprised of four groups: (a) Improving Image Quality; (b) Image feature extraction; (c) Quantification and Analysis; and (d) Detection and Classification. The papers were categorized and grouped to show the main contributions of the literature to support agricultural decisions using AI. This study found that the methods perform better in supporting weed detection, classification of plant diseases, and estimation of agricultural yield in crops when using images captured by Unmanned Aerial Vehicles (UAVs). Furthermore, CNN and YOLO, as well as their variations, present the best results for all groups presented. This SLR also points out the limitations and potential challenges when working with deep machine learning models, aiming to contribute to the knowledge systematization and to benefit researchers and professionals on the AI applications in mitigating agronomic problems.

Keywords: Deep learning. Machine learning. Precision agriculture. Unmanned aerial vehicle.

1. INTRODUÇÃO

Modelos de aprendizado de máquina (*Machine learning* - ML) e aprendizado profundo (*Deep learning* - DL) para automatizar processos agrícolas manuais e repetitivos desempenham papel importante em aplicações que utilizam Veículos Aéreos Não Tripulados (*Unmanned Aerial Vehicle* – UAV) [1-3]. Desta forma, as aplicações com Inteligência Artificial (IA) transformaram, nas últimas décadas, a forma como os processos agrícolas convencionais são realizados [4].

O termo *Machine Learning* é usado para algoritmos treinados para aprender padrões por experiência e são capazes de resolver problemas específicos por meio de dados de entrada e parâmetros fornecidos a eles [5]. Já o termo *Deep Learning* diz respeito a uma classe de programação de aprendizagem de máquina que utiliza grandes volumes de dados de entrada em busca de soluções para diversos problemas, incluindo a área agrícola [6].

Nos últimos anos, a produção de alimentos em todo o globo tem se tornado prioridade, impulsionada pelo aumento populacional e as mudanças climáticas severas [7]. Com isso, a produção crescente de alimentos tem de ser realizada sem desperdícios e de forma rentável [8]. Além disso, as práticas de produção agrícola tradicionais podem levar à mão-de-obra limitada, escassez de recursos e produtividade abaixo do esperado [9,10]. Sendo assim, alguns dos problemas recorrentes que afetam diretamente a produção final são o aparecimento de plantas daninhas em culturas, deficiência nutricional, estresse hídrico, pragas agrícolas e doenças em plantas [11,12].

A maioria dos problemas agrônômicos atuais dependem da experiência de um profissional agrícola, o que torna o processo lento e dispendioso [13]. Ademais, caso o problema não seja previamente identificado, monitorado e corrigido, o rendimento das culturas agrícolas pode ser afetado, ocasionando prejuízos financeiros ao produtor rural [14].

Neste contexto, com o advento das tecnologias UAV na agricultura, combinadas com algoritmos de ML e DL, a automação de processos agrícolas tornou-se cada vez mais comum e prática [15]. A IA pode ser usada como uma ferramenta auxiliar para identificar, quantificar e interpretar imagens capturadas por UAVs [16]. O uso de IA na agricultura pode também reduzir o tempo necessário para analisar imagens aéreas e prever problemas agrônômicos [17-19]. Com isso, pesquisas com inteligência

artificial, sensoriamento remoto, Internet das Coisas (IoT) e *drones*, entre outras tecnologias aplicadas ao meio rural, tornaram-se cada vez mais presentes nos últimos anos [20-22]. Neste sentido, os modelos de aprendizagem profunda aliados à visão computacional possibilitam que UAVs façam diagnósticos remotos e prescrição no local, sem causar danos às plantas [23].

Este trabalho apresenta uma revisão sistemática de estudos sobre técnicas de Inteligência Artificial (IA) aplicadas na análise automática de imagens aéreas capturadas por UAVs para ajudar a orientar manejos e decisões agrícolas. Esta revisão sistemática incluiu 70 artigos, a maioria deles cobrindo uma variedade de aplicações de IA para automatizar processos, identificar tipos de problemas agronômicos e apoiar decisões agrícolas.

O objetivo deste artigo foi realizar um estudo sobre técnicas de IA utilizadas para apoiar manejos agrícolas e automatizar processos que utilizam imagens como dados de entrada. Os objetivos específicos foram: pesquisar as principais bases científicas de estudos sobre técnicas de IA aplicadas à agricultura; ler os artigos e criar resumos de cada um; agrupar os estudos com objetivos semelhantes; categorizar os resumos; identificar o estado da arte sempre que possível; e identificar os desafios/limitações da utilização da IA neste contexto.

Esta RSL apresenta uma investigação sobre os avanços na aplicação de IA para análise automatizada de imagens agrícolas [24]. Os artigos foram agrupados e categorizados por identificação de problemas agronômicos, técnicas e métodos de ML e DL utilizados em cada artigo e suas respectivas métricas e precisões e desafios e limitações do problema de investigação identificado.

2. MATERIAL E MÉTODOS

Primeiramente, esta RSL é um estudo sobre técnicas de IA aplicadas à análise automatizada de imagens aéreas capturadas por UAVs para identificar os problemas agronômicos mais comuns encontrados em campo. A revisão apresenta os resultados obtidos para imagens em canais de cores RGB (*Red*, *Green* e *Blue*), imagens multiespectrais, hiperespectrais e térmicas. Esta RSL foi dividida em três etapas: planejamento da pesquisa, seleção dos artigos e resultados e discussão. Nesse sentido, uma RSL segue com base no estudo de Siqueira *et al.* [24], sendo realizada de acordo

com as diretrizes descritas por Kitchenham [25].

2.1. Planejamento da pesquisa

A etapa de planejamento foi conduzida da seguinte forma: 1) Foi feita uma análise exploratória da literatura para definição das palavras-chave e das fontes pesquisadas; 2) A pesquisa foi conduzida nas principais bases de dados científicos (*ACM, IEEE, Science Direct, MDPI e Web of Science*), nas páginas oficiais disponíveis na internet.

A busca foi restrita a artigos publicados entre janeiro de 2018 e janeiro de 2024, escritos em inglês. A Revisão Sistemática da Literatura teve como objetivo responder às seguintes questões de pesquisa:

Q1) Em que tipo de análise de imagem a IA foi aplicada para apoiar decisões agrícolas?

Q2) Quais foram as técnicas e de precisão dos modelos de IA aplicadas?

Q3) Quais desafios/limitações na aplicabilidade da IA para cada tipo de análise de imagens agrícolas?

Q4) Quais técnicas/métodos foram mais utilizados?

Q5) Como a IA pode contribuir para apoiar decisões agrícolas na análise de imagens?

Q6) Qual foi o tipo de problema agrônômico mais estudado na pesquisa?

2.2. Seleção dos artigos

Para selecionar os artigos que compõem a RSL, o protocolo seguiu a linha de pesquisa de Siqueira *et al.* [24] e Kitchenham [25]. A seleção dos artigos seguiu os seguintes critérios de inclusão e exclusão:

I1) Artigos que utilizaram técnicas de IA para análise agrícola;

I2) Artigos completos escritos em inglês;

I3) Artigos de periódicos revisados por pares;

E1) Artigos que não descreviam o tipo de análise agrícola utilizada;

E2) Artigos que não especificavam a técnica de IA utilizada e que estavam incompletos ou abstratos; e

E3) Artigos que não apresentaram resultados experimentais substanciais.

A Figura 1 apresenta um resumo dos resultados quantitativos retornados de cada base de dados científicos utilizando a *string* de busca mencionada nesta etapa de seleção dos artigos da RSL. As buscas nas principais bases de dados científicas retornaram um total de 343 artigos. Após a leitura dos títulos e resumos, foram descartados 249 artigos. Assim, restaram 94 artigos. Portanto, foram selecionados 94 artigos para leitura na íntegra e fase de extração de dados. Após a leitura completa dos artigos, 24 atenderam aos critérios de exclusão (E1, E2 e E3) e não foram incluídos. Por fim, 70 artigos foram incluídos na RSL.




Figura 1. Etapas de seleção da RSL.

Inicialmente, os termos “Erva Daninha”, “Deficiência Nutricional”, “Estresse Hídrico”, “Doença”, “Praga” e “Yield Estimation” foram usados para pesquisar artigos relevantes para encontrar uma palavra-chave de pesquisa satisfatória. Foram adicionados filtros de busca com a inclusão dos termos “Machine learning OR Deep Learning” para refinar a busca. Foi acrescentado o termo “UAV” para filtrar apenas artigos relacionados a imagens captadas por drones. As *strings* de pesquisa completas foram as seguintes: ((Weed) AND (“Machine learning” OR “Deep Learning”) AND (“UAV”)); ((Deficiência nutricional) AND (“Aprendizado de máquina” OR

“Aprendizado profundo”) AND (“UAV”)); ((Estresse hídrico) AND (“Aprendizado de máquina” OR “Aprendizado profundo”) AND (“UAV”)); ((“Doença”) AND (“Aprendizado de máquina” OR “Aprendizado profundo”) AND (“UAV”)); ((Pragas) AND (“Aprendizado de máquina” OU “Aprendizado profundo”) AND (“UAV”)); ((Estimativa de rendimento) AND (“Aprendizado de máquina” OR “Aprendizado profundo”) AND (“UAV”)). Outras palavras-chave como “Inteligência Artificial”, “Agricultura de Precisão”, “Problemas Agronômicos” e “RGB” foram testadas, porém não agregaram resultados à busca. Por fim, os artigos foram extraídos das seguintes bases científicas de dados: Associação de Máquinas de Computação (*Association for Computing Machinery – ACM*) [26]; Instituto de Engenheiros Elétricos e Eletrônicos (*Institute of Electrical and Electronic Engineers – IEEE*) [27]; *Science Direct* [28]; Instituto Multidisciplinar de Publicação Digital (*Multidisciplinary Digital Publishing Institute – MDPI*) [29]; e *Web of Science* [30].

Durante a fase de extração de dados nos artigos, foram identificadas diversas técnicas que automatizam processos agrícolas como ervas daninhas, deficiência nutricional, estresse hídrico e doenças de plantas. A Figura 2 apresenta um resumo do fluxo sequencial do desenvolvimento da RSL.

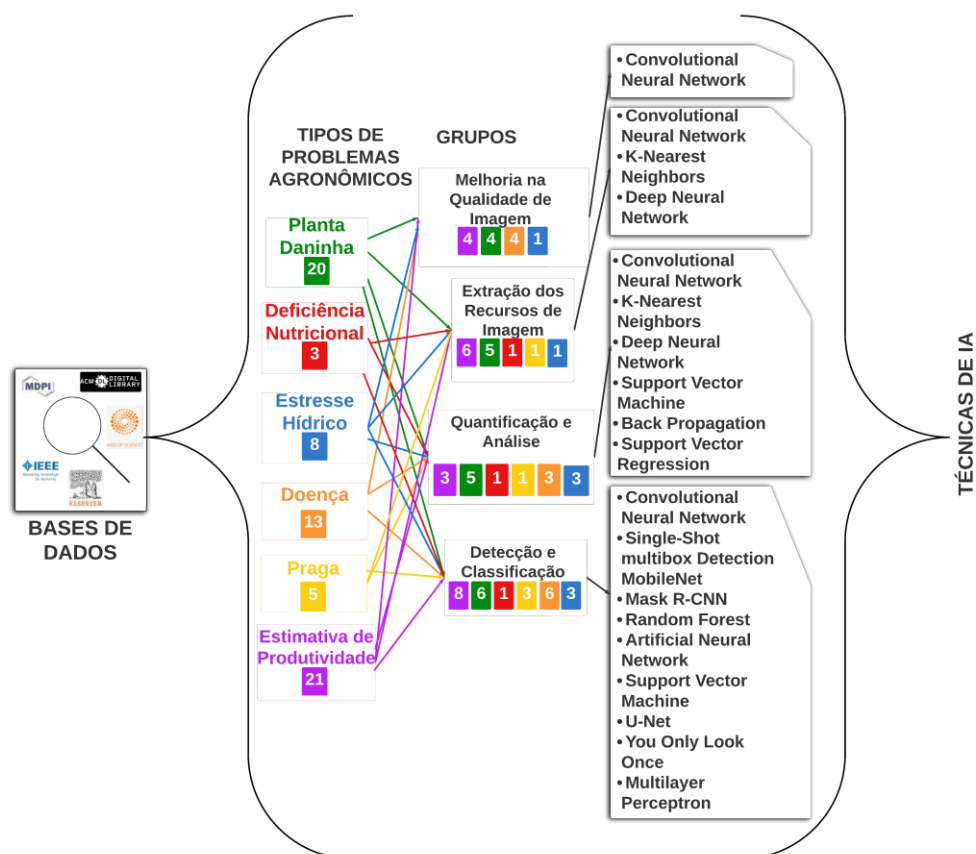


Figura 2. Fluxograma da extração de dados e destaques de sequência da RSL, adaptado de Siqueira *et al.* [24].

A Tabela 1 apresenta a distribuição dos artigos científicos por ano de publicação e o número de publicações em cada ano nas principais bases de dados utilizadas para construção da revisão sistemática.

Tabela 1. Artigos selecionados por ano de publicação e principais bases bibliográficas utilizadas

Ano de Publicação	Número de Publicação (n)	Base de dados bibliográfica
2018	2	IEEE ² (n = 2) IEEE (n = 1);
2019	3	MDPI ³ (n = 1); Web of Science ⁴ (n=1) IEEE (n = 1);
2020	5	Science Direct (n = 2); MDPI (n = 1);

2021	13	Web of Science (n=1) IEEE (n = 2); Science Direct (n = 8); MDPI (n = 2); Web of Science (n=1) ACM ¹ (n = 1); IEEE (n = 2);
2022	20	Science Direct (n = 12); MDPI (n = 5) IEEE (n = 2);
2023	22	Science Direct (n = 15); MDPI (n = 5)
2024	5	Science Direct (n = 5)
Total	70	

¹ Association for Computing Machinery (ACM), ² Institute of Electrical and Electronics Engineers (IEEE), ³ Multidisciplinary Digital Publishing Institute (MDPI), ⁴ Web of Science.

3. REVISÃO DE LITERATURA

Nos últimos anos, em todas as áreas, a Inteligência Artificial mudou a forma como os processos são desenvolvidos [31]. Na área agrícola, por exemplo, a Inteligência Artificial é utilizada para auxiliar em processos manuais e repetitivos [32]. Algumas tarefas comuns como a avaliação de deficiências nutricionais e hídricas no campo ou a identificação de ervas daninhas nas plantações são realizadas com interferência humana direta [33]. Nesse sentido, a automatização de tarefas rotineiras otimiza o tempo dos produtores rurais [34].

Várias soluções promissoras foram apresentadas ao longo dos anos para automatizar processos agrícolas, entre elas estão *softwares* de mercado para geoprocessamento e análise de imagens [35].

3.1. Planta Daninha

Plantas daninhas são responsáveis por quedas substanciais de produtividade em culturas agrícolas [36]. Por este motivo, medidas de controle de infestação de plantas daninhas são essenciais para o rendimento final da colheita.

Neste sentido, estudos recentes abordam que a supervisão constante e precisa se torna indispensável perante as dificuldades de controlar plantas daninhas em meio

aos campos agrícolas [37]. Visto isso, estudos atuais mostraram que é possível controlar a proliferação de plantas invasoras com o uso de modelos de aprendizagem profunda.

Modelos DL são amplamente utilizados na agricultura de precisão para detectar e controlar plantas invasoras. Um exemplo é o modelo UNET-ResNet, que foi aplicado em imagens aéreas capturadas por UAV e treinado para detectar automaticamente plantas daninhas no inverno em campos de trigo. A acurácia mostrou ser superior a 90%, com correlação estatisticamente significativa ($r > 0,75$ e $p < 0,00001$) entre os mapas de plantas daninhas, derivados de imagens aéreas, e os dados coletados em campo [38].

Em um estudo que se propôs utilizar Redes Neurais Convolucionais (CNN) para detectar linhas de colheita em imagens aéreas capturadas por UAV nas culturas de espinafre e feijão, os autores rotularam as linhas de cultivo e as usaram para identificar plantas daninhas entre as linhas. A comparação do método proposto com o tradicional detectou cerca de 93,58% de taxa de sucesso para a linha de cultura de 70% [39].

Huang *et al.* [40] apresentaram Análise de Imagens Baseada em Objetos (OBIA) e um modelo de aprendizado de máquina profundo, aplicado a imagens aéreas capturadas por UAV para mapear ervas daninhas em plantações de arroz. Para segmentar imagens em muitos objetos diferentes, os autores aplicaram segmentação multirresolução e um método K-means. Para classificar as imagens, os autores utilizaram uma máquina de vetores de suporte, uma rede neural *Back Propagation* e *Random Forest* (RF).

Beehary e Bassoo [41] propuseram um estudo do desempenho de dois modelos de aprendizado de máquina, Rede Neural Artificial (RNA) e o algoritmo AlexNet. Os autores dividiram as imagens em três partes: soja, solo e erva daninha para treinamento e testes. Os algoritmos RNA e AlexNet apresentaram acurácia de 48,09% e 99,81%, respectivamente.

Reedha *et al.* [42] investigaram os transformadores visuais (ViT) e sua aplicabilidade à classificação de plantas daninhas em imagens aéreas capturadas por UAV em culturas de espinafre. A pesquisa apresentou o desempenho do ViT para treinamento com poucos dados, mostrando-se tão eficiente quanto outros modelos, como EficienteNet e ResNet.

Genze *et al.* [43] investigaram a capacidade de métodos de aprendizado de máquina profundo, testando três arquiteturas diferentes, utilizando imagens capturadas por UAV, em culturas de sorgo sob diferentes condições. Os resultados do estudo,

utilizando uma arquitetura do tipo U-Net com ResNet-34, mostraram pontuação de 89,0% em um conjunto de testes *standby* realizado pelos autores. Além disso, a abordagem foi capaz de detectar ervas daninhas nas linhas de cultivo.

Gallo *et al.* [44] apresentaram uma nova abordagem de detecção de ervas daninhas *Chicory* e, em seguida, testaram algoritmos de aprendizado de máquina profundo para detectar objetos em imagens aéreas RGB capturadas por UAV. Os resultados do estudo, comparando o modelo de Rede Neural Convolutacional (CNN) YOLOv7 com suas versões mais antigas, foram 61%, 74,10% e 48% para o mAP total (Precisão Média), demonstrando o potencial do YOLOv7 para detecção de ervas daninhas. A Figura 3 mostra um exemplo de resultado da segmentação de plantas daninhas, em cultura de soja e feijão, utilizando o modelo YOLOv7, com 300 épocas de treinamento.




Figura 3. Exemplo de saída de dados após o treinamento do modelo YOLOv7 para segmentação de plantas daninhas em culturas agrícolas comerciais.

Ajayi *et al.* [45] propuseram avaliar um modelo de Rede Neural Convolutacional YOLOv5 para classificar automaticamente ervas daninhas em culturas, usando imagens

RGB capturadas por UAV. O modelo classificou as ervas daninhas em diferentes culturas, como espinafre, cana-de-açúcar e pimenta, em épocas diferentes. O resultado mostrou uma precisão de classificação de ervas daninhas de até 65% e uma precisão de classificação de até 78%.

Pei *et al.* [46] apresentaram uma nova abordagem de detecção de ervas daninhas usando um modelo CNN, YOLOv4 e imagens aéreas RGB capturadas por UAV em lavouras de milho. As linhas de cultivo de milho foram detectadas e mascaradas usando YOLOv4-Tiny para que fosse necessário rotular apenas as ervas daninhas na imagem mascarada. O resultado mostrou que a acurácia média de detecção e de classificação de plantas daninhas foi de 86,90%.

Su *et al.* [47] propuseram o mapeamento da erva daninha *blackgrass* no cultivo de trigo usando imagens aéreas multiespectrais capturadas pelo UAV DJI S-1000, a uma altitude de 20 metros, e técnicas de aprendizado de máquina. Os autores usaram um classificador RF com otimização de parâmetros para criar um mapa de classificação. O resultado mostrou uma precisão de classificação de ervas daninhas da ordem de 93,80%.

Barrero e Perdomo [48] propuseram um novo método para combinar imagens aéreas RGB e multiespectrais capturadas por UAV e método de detecção com Redes Neurais (NN) para classificar plantas daninhas do tipo *Gramineae* na cultura do arroz. O estudo combina as informações de textura presentes em imagens RGB com as informações de refletância fornecidas por imagens multiespectrais para detectar ervas daninhas. O resultado do estudo mostrou que os índices M/MGT e MP, que calculam a avaliação de desempenho, ficaram entre 80 e 108% e entre 70 e 85%, respectivamente, e apresentaram melhor desempenho obtido pela RN com a imagem fundida.

Bah *et al.* [49] apresentaram um novo método de aprendizado de máquina profundo usando Redes Neurais Convolucionais (CNN), usando um conjunto de imagens, capturadas com UAV, para treinamento não supervisionado para detecção de ervas daninhas. O novo método, proposto pelos autores, apresenta três fases de treinamento: detecção de linhas de cultivo e ervas daninhas e construção do modelo final. O resultado foi comparado ao treinamento supervisionado, com diferenças de acurácia de 1,50% na cultura do espinafre e de 6% na cultura do feijão.

Naveed *et al.* [50] aplicaram um método de detecção de ervas daninhas usando um modelo de rede neural de modulação de codificação preditiva/entrada de competição tendenciosa (PC/BC-DIM) e imagens aéreas multiespectrais capturadas por UAV. Os

autores determinaram um mapa de saliência utilizando uma rede neural e imagens multiespectrais para detectar ervas daninhas. O resultado do modelo proposto alcançou uma precisão média de 94,38% na detecção de ervas daninhas.

Chegini *et al.* [51] projetaram um modelo de detecção e monitoramento de plantas daninhas em pastagens na Califórnia, nos Estados Unidos, com o uso dos quatro modelos SSD, SSD Lite, Fast RCNN e MaskRCNN, em imagens RGB, para analisar o desempenho na detecção de plantas daninhas. O resultado do estudo mostrou que o modelo aprimorado apresentou 93% de acurácia do mAP na detecção de plantas daninhas.

Xu *et al.* [52] apresentaram uma nova abordagem para detecção de plantas daninhas no cultivo de soja usando imagens capturadas por UAV e modelos de aprendizado de máquina. Os autores usaram um índice de cores para destacar as plantas do solo e mitigar os efeitos de iluminação e de fundo e usaram algoritmos de aprendizado de máquina ResNet101_v e DSASPP na arquitetura do codificador-decodificador para aprimorar a geração de informações e aumentar a precisão na segmentação de plantas e a detecção de ervas daninhas no conjunto de imagens. Os resultados do estudo mostraram que os modelos de aprendizado de máquina combinados obtiveram precisão de 0,905 para ervas daninhas.

Nagothu *et al.* [53] usaram um algoritmo de aprendizado de máquina SSD Mobilenet e imagens capturadas por UAV para detectar ervas daninhas na cultura do algodão. Os autores usaram uma combinação de imagens multiespectrais e RGB e treinaram um modelo SSD Mobilenet com um extenso conjunto de dados. Os resultados do estudo mostraram que o modelo de aprendizado de máquina apresentou precisão de até 95% na detecção de plantas daninhas na cultura do algodão.

Nasiri *et al.* [54] empregaram a arquitetura de aprendizado de máquina profundo U-Net, como uma rede neural artificial (CNN) para reconhecimento de plantas daninhas, usando imagens aéreas, na cultura da beterraba. Os autores treinaram um modelo de aprendizado de máquina profundo U-Net com ResNet50, usando um conjunto de imagens RGB em diversas condições de voo. Os resultados do estudo comprovaram que o modelo treinado obteve pontuações de precisão e de interseção sobre união (IoU) de 0,9606 e de 0,8423, respectivamente, demonstrando bom desempenho do reconhecimento de plantas daninhas na cultura da beterraba.

Ajayi e Ashi [55] avaliaram o efeito de várias épocas de treinamento de uma rede neural convolucional baseada na região e imagens capturadas por UAV para

detectar e classificar ervas daninhas em uma mistura agrícola (cana-de-açúcar, espinafre, banana e pimenta). Os autores utilizaram o algoritmo de rede neural convolucional RCNN, ao longo de cinco épocas, e imagens aéreas RGB para a classificação de ervas daninhas, mas o desempenho do modelo é saturado quando o intervalo é este limite. Os resultados mostraram que o desempenho do modelo RCNN melhorou com o aumento do número de épocas, alcançando 99% de precisão na detecção e classificação de ervas daninhas em culturas mistas.

Rahman *et al.* [56] avaliaram o desempenho de modelos de aprendizado de máquina profundo para detecção de plantas daninhas na cultura do algodão. Os autores do estudo usaram treze modelos de aprendizado de máquina profundo e um conjunto de dados de três classes de ervas daninhas, incluindo YOLOv5, RetinaNet, EfficientDet, Fast RCNN e Faster RCNN. O resultado do estudo mostrou que o modelo YOLOv5 tem potencial para ser implementado em dispositivos em tempo real e uma precisão de detecção de 76,58%.

Diao *et al.* [57] propuseram um algoritmo de extração de linha de navegação que usa o kernel da planta de milho para identificar e localizar plantas de milho para robôs de pulverização com base na rede YOLOv8s aprimorada. O estudo capturou imagens por UAV em uma área experimental em Zhengzhou, China, em diferentes ambientes e períodos de crescimento, incluindo ambientes com presença de ervas daninhas. Os autores desenvolveram um modelo YOLOv8s aprimorado para detecção mais precisa do núcleo das plantas de milho, tendo as coordenadas centrais da caixa de detecção da rede sido usadas como alvo para localizar os pontos característicos de cada planta. O resultado do estudo mostrou que o YOLOv8 melhorado teve um bom desempenho na extração de núcleos de plantas de milho com precisão média (mAP) e F1 de 86,4% e 86%, respectivamente.

Mekhalfa *et al.* [58] avaliaram o desempenho de modelos de aprendizado de máquina profundo para detectar a presença de ervas daninhas em lavouras de soja usando imagens de UAV. Os autores classificaram o conjunto de dados e treinaram seis modelos de aprendizado de máquina, que incluem AlexNet, VGG16, GoogLeNet, ResNet50, SqueezeNet e MobileNet para detecção de ervas daninhas. Os resultados do estudo mostraram que os modelos de redes neurais convolucionais (CNN) obtiveram melhor desempenho, atingindo 98% de precisão.

3.2. Deficiência Nutricional

A deficiência nutricional de plantas é um problema comum em colheitas agrícolas que pode causar perdas financeiras ao produtor [59]. As pesquisas mostraram que métodos não destrutivos para detecção de deficiência nutricional que utilizam modelos de aprendizado de máquina podem ajudar na avaliação deste problema e auxiliar na saúde das plantas [60].

Sánchez-DelaCruz *et al.* [61] utilizaram processamento de imagens e algoritmos de aprendizado de máquina para identificar e classificar danos nutricionais nas folhas da cultura da laranja. O estudo fez a extração de características da folha de laranja utilizando métodos de processamento de imagem e aprendizado de máquina Multi-layer Perceptron (MLP), obtendo uma precisão de 96,66% na classificação de anormalidades nas folhas.

Sathyavani *et al.* [62] detectaram deficiência nutricional em folhas de coentro, tomate e pimentão, entre outras plantas, com dispositivos de Internet das Coisas (IoT) e uma Rede Neural Convolucional (CNN). O estudo extraiu padrões em imagens de folhas de plantas e captura dados por meio de um dispositivo de análise nutricional de plantas, posteriormente processado na CNN para emitir um relatório final. Os resultados mostraram que, entre os modelos CNN testados, o ResNet50 apresentou acurácia de 88% ao detectar deficiência nutricional nas folhas.

Estudos recentes revelam que a falta ou o excesso de nutrientes, como nitrogênio, potássio e cálcio, podem ocasionar sintomas fisiológicos na superfície das folhas em culturas agrícolas, prejudicando o desenvolvimento das plantas [63]. Sabzi *et al.* [64] propuseram prever o conteúdo de nitrogênio em pepino (*Cucumis sativus L*, var. Super Arshiya-F1) usando método de rede neural artificial (RNA), exame de partículas (ANN-PSO), rede neural convolucional (CNN) e imagens hiperespectrais. Os autores capturaram imagens hiperespectrais de folhas antes e depois da aplicação do excesso de nitrogênio. Os resultados mostraram que os coeficientes de regressão médios para ANN-PSO na faixa entre 0,937 e 0,965, e CNN entre 0,965 e 0,98 foram precisos na previsão do teor de nitrogênio nas folhas de pepino.

3.3. Estresse Hídrico

O estresse hídrico nas culturas é um desafio quando se trata da gestão de água de irrigação no solo e do rendimento da colheita [65]. As metodologias convencionais para medição do teor de água no solo são exaustivas e onerosas [66]. Para o controle eficiente de deficiência hídrica em culturas agrícolas, métodos baseados em tecnologia de sensoriamento remoto e IA podem auxiliar no monitoramento desse tipo de estresse na planta [67].

Bhandari *et al.* [68] treinaram modelos de aprendizado de máquina, utilizando Rede Neural Convolutiva (CNN) e imagens aéreas RGB e multiespectral capturadas por UAV. O estudo propôs detectar nitrogênio e estresse hídrico na cultura da alfaca e, ao final, correlacionou os dados obtidos nas imagens aéreas com os dados coletados no local do experimento, com precisão de 62,30% para detecção de estresse hídrico.

Sankararao *et al.* [69] usaram um sensor de imagem hiperespectral (HSI) e um UAV para capturar imagens aéreas e identificar o estresse hídrico na copa da cultura de milho, juntamente com um classificador SVM (Support Vector Machine). Os autores apresentaram cinco métodos de seleção de recursos baseados em aprendizado de máquina usados para identificar dez bandas de ondas mais sensíveis ao estresse hídrico nas copas das plantas. O resultado obtido mostrou que o classificador SVM com núcleo linear apresentou acurácia de 80,76% na detecção precoce de estresse hídrico na copa do milho.

Shankararao *et al.* [70] propuseram o uso de um modelo de Rede Neural Convolutiva (CNN) 3D-2D para classificar o estresse hídrico na copa do grão de bico usando imagens aéreas hiperespectrais capturadas por UAV. Os autores compararam o desempenho da CNN 3D-2D com um modelo SVM e um modelo CNN 2D+1D na identificação do estresse hídrico. O resultado do estudo mostrou o potencial do HSI na detecção de estresse hídrico nas culturas de grão de bico com precisão de 95,44%.

Tunca *et al.* [71] usaram modelos de aprendizado de máquina e imagens aéreas para calibrar medições de sensores térmicos acoplados a UAVs. Os autores usaram dois tipos diferentes de sensores térmicos comerciais, o Micasense Altum e o Flir Duo Pro-R (FDP-R), para testes de campo para avaliar o desempenho de cada um. Em seguida, cinco algoritmos de aprendizado de máquina foram utilizados para calibrar os sensores térmicos. Os resultados mostraram que o R^2 dos sensores Micasense Altum e FDP-R aumentou de 0,89 para 0,96 e 0,87 para 0,94, respectivamente.

Bertalan *et al.* [72] estudaram o desempenho de câmeras térmicas e multiespectrais baseadas em UAV usando modelos de aprendizado de máquina para

estimar o conteúdo de água no solo. Os autores usaram quatro algoritmos de aprendizado de máquina, Random Forest (RF), Elastic-Net (ENR), General Linear Model (GLM) e Robust Linear Model (RLM), combinados com três métodos de extração de valor de pixel, para estimar o conteúdo de água do solo. Os resultados do estudo mostraram que a câmera multiespectral teve melhor desempenho nos dados de entrada do que a câmera térmica, apresentando um valor R^2 de 0,97 e um erro quadrático médio normalizado de 10%. Os melhores modelos de aprendizado de máquina capazes de prever o teor de água no solo foram Random Forest e ENR, com R^2 de 0,97 e 0,88, respectivamente.

Niu *et al.* [73] fizeram avaliações sobre o cultivo de milho, na Mongólia Interior, para diferentes níveis de irrigação e estresse hídrico, durante os anos de 2018 e 2019. As imagens capturadas pelo UAV foram utilizadas para investigar o efeito dos sensores de imagem. Os autores utilizaram cinco índices de vegetação, a partir de imagens multiespectrais, e três algoritmos de aprendizado de máquina, RF, Rede Neural Artificial (RNA) e algoritmo de Regressão Linear Multivariada (MLR), para construir o modelo de Cobertura Vegetal Fracionada (CVF), para detectar o estado de crescimento da cultura e seu rendimento final. Os resultados do estudo mostraram que o modelo de regressão RF teve melhor desempenho na previsão do CVF no milho, apresentando R^2 de 0,892 e Root Mean Square Error (RMSE) de 0,066.

Das *et al.* [74] propuseram uma abordagem usando um modelo de aprendizado de máquina e imagens térmicas capturadas por UAV para prever a biomassa e o rendimento do trigo cultivado sob estresse hídrico. Os autores quantificaram dezoito genótipos de trigo em solos com moderado e alto teor de sódio no nordeste da Austrália, tendo usado um algoritmo de classificação e regressão de árvores (CRT) para classificar o estresse hídrico das culturas e prever a biomassa e o rendimento de grãos. Os resultados do estudo indicaram que o modelo de aprendizado de máquina apresentou coeficiente de determinação R^2 de 0,86, Root Mean Square Error (RMSE) de 41,3 g/m² e R^2 de 0,75, para solo com moderado teor de sódio, e R^2 de 0,78 para grãos de rendimento em soja.

Wang *et al.* [75] propuseram um modelo de aprendizado de máquina para diagnosticar o estresse hídrico no inverno na China em culturas de trigo com base em imagens multiespectrais e térmicas capturadas por UAV. Os autores capturaram imagens em seis estágios de crescimento do trigo e calcularam quatorze índices de vegetação e dois índices térmicos para o estudo. O teor de água e a condutância

estomática normalizada no solo foram medidos para obter uma referência. Algoritmos de mínimos quadrados parciais (PLS), máquina de vetores de suporte (SVM) e árvore de decisão de aumento de gradiente (GBDT) foram usados para prever o conteúdo de água e a condutância estomática normalizada no solo para cada estágio. Os resultados do estudo mostraram que o modelo GBDT teve melhor desempenho na fase de floração, com índice R^2 de 88%, erro quadrático médio (RMSE) de 8%, erro quadrático médio normalizado (NRMSE) de 14,7%, fase de enchimento com R^2 de 90%, RMSE de 5% e NRMSE de 15,9%.

3.4. Doença em Planta

As doenças em plantas são um problema recorrente em produções agrícolas [76]. A avaliação de doenças de plantas em campo é demorada, menos eficiente e dispendiosa. Desde então, muitas pesquisas sobre o tema têm surgido a fim de encontrar métodos precisos e eficientes para auxiliar na detecção de doenças em plantas [77].

Pan *et al.* [78] apresentaram uma abordagem baseada em aprendizado de máquina profundo, com *Pyramid Scene Parsing Network* (PSPNet) para identificar ferrugem linear no cultivo de trigo, usando imagens aéreas capturadas por UAV. O estudo propôs uma solução alternativa ao método utilizado manualmente. Os resultados do estudo apresentaram eficácia da abordagem proposta com 98% de precisão.

Wu *et al.* [79] discutiram o diagnóstico precoce da “doença da murcha do pinheiro” (PWD, sigla em inglês) usando algoritmos de aprendizado de máquina profundo e detecção de objetos em imagens aéreas capturadas por UAVs. Os autores do estudo explicaram que o diagnóstico precoce da doença no pinheiro é importante, mas os métodos existentes não são adequados para um rastreamento rápido e em grande escala no terreno. O objetivo do estudo foi gerar um conjunto de dados com imagens aéreas de copas de pinheiros em estágio inicial. Em seguida, os autores aplicaram algoritmos de aprendizado de máquina profundo, Faster R-CNN e YOLO, para detecção de doenças. Os resultados mostraram precisão acima de 75%, o que torna o método promissor.

Selvaraj *et al.* [80] propuseram classificar quatro tipos de doenças das bananeiras na África usando imagens aéreas capturadas por UAV com imagens de satélite e modelos de aprendizado de máquina. Os autores classificaram imagens aéreas de bananeiras com base em pixels usando modelos de aprendizado de máquina como

RF e SVM. Os resultados mostraram uma precisão de 99,40% para o *Banana Fan Top Virus* e 92,80% para a doença causada pela bactéria *Xanthomonas campestris* pv. *masacearum*.

Amarasingam *et al.* [81] aplicaram técnicas de sensoriamento remoto usando imagens capturadas por UAV e modelos de aprendizado de máquina profundo (YOLOv5, YOLOR, DETR e Faster R-CNN) para detectar “doenças das folhas brancas” nas lavouras de cana-de-açúcar. O estudo utilizou uma metodologia baseada na aquisição de imagens RGB, pré-processamento do conjunto de dados e treinamento com algoritmos de aprendizado de máquina. A pesquisa avaliou o desempenho entre os modelos e os resultados experimentais mostraram que a rede YOLOv5 foi mais precisa em comparação com as demais, com precisão média de 95%.

Yu *et al.* [82] propuseram monitorar a infecção da “doença da murcha do pinheiro” (PWD) usando imagens multiespectrais capturadas por UAVs e algoritmos de aprendizado de máquina profundo. No estudo, os autores dividiram a infecção em estágios inicial, intermediário e tardio, com base na cor ou na secreção da resina do pinheiro. Modelos de aprendizado de máquina profundo (Faster R-CNN e YOLOv4) foram treinados usando um conjunto de imagens multiespectrais para reconhecer pinheiros infectados com a doença. Os resultados mostraram acurácia de 66,70% para o modelo Faster R-CNN e 63,55% para o modelo YOLOv4.

Shi *et al.* [83] apresentaram um novo modelo de aprendizado de máquina profundo (CropdocNet) para detecção de doenças em culturas de batata usando imagens aéreas hiperespectrais. Os autores do estudo consideraram a variação potencial da refletância de radiação da doença ao treinar o novo modelo de aprendizagem profunda e, ao final, os resultados do modelo proposto alcançaram uma precisão de 98%.

Kerkech *et al.* [84] aplicaram uma nova arquitetura de aprendizado de máquina profundo chamada Vine Disease Detection Network (VddNet) usando imagens multiespectrais e mapas de profundidade. O novo modelo apresentado pelos autores tem três autodecodificadores que acabam atribuindo uma classe a cada pixel da imagem. O modelo foi comparado com outras arquiteturas conhecidas como SegNet, U-Net, DeepLabv3+ e PSPNet. Os resultados do treinamento mostraram que a arquitetura proposta é mais precisa do que modelos de benchmark conhecidos.

Shankar *et al.* [85] propuseram o uso de um modelo de aprendizado de máquina e algoritmos de Rede Neural Artificial (RNA) para localizar regiões afetadas por doenças e pragas nas lavouras, usando imagens aéreas capturadas por UAVs, na

Índia. Os autores concentraram-se em regiões afetadas por doenças agrícolas para identificá-las e aplicar os produtos químicos em áreas específicas, reduzindo custos e desperdícios. Os resultados obtidos pelos autores mostraram que o modelo utilizado apresentou resultados satisfatórios na detecção de doenças nas culturas.

Delgado *et al.* [86] utilizaram um modelo de aprendizado de máquina para classificar a infecção pelo vírus *Hoja Blanca* (RHBV) em lavouras de arroz, usando imagens aéreas multiespectrais capturadas por UAVs. O estudo demonstrou que os melhores classificadores SVM apresentaram melhores taxas de sensibilidade quando comparados aos métodos SVM (taxa de 0,74) e RF (taxa de 0,71), permitindo a caracterização precoce de variedades do vírus *Hoja Blanca*.

Khan *et al.* [87] apresentaram a classificação de diferentes pragas utilizando um modelo de aprendizado de máquina profundo EfficientNet e imagens aéreas capturadas por UAV, em diferentes culturas. Os autores utilizaram o modelo EfficientNet de última geração, que compreende quatro locais diferentes conectados a um modelo global que recebe vários parâmetros do modelo local. Os resultados do estudo mostraram que o sistema alcançou uma precisão de 99,55% ao aumentar o conjunto de imagens em diferentes ângulos, contribuindo para a classificação de pragas no ambiente agrícola.

Oide *et al.* [88] simplificaram o método de detecção automática da “doença da murcha do pinheiro” (PWD) usando modelos de aprendizado de máquina e imagens aéreas capturadas por UAVs. Os autores usaram seis algoritmos de aprendizado de máquina, incluindo regressão logística, máquina de vetores de suporte linear, SVM, k-vizinhos mais próximos, RF e rede neural artificial (RNA), para detectar PWD e validar o desempenho dos algoritmos utilizando as métricas de exatidão, precisão, recall, pontuações F1 e área sob a curva característica com intervalos de confiança de 95%. Os resultados do estudo mostraram que o modelo de aprendizado de máquina de melhor desempenho combinado com o conjunto de dados do espaço de cores HSV foi o RNA com precisão de 99,50%.

Deng *et al.* [89] propuseram uma metodologia para análise de regressão em nível de pixel para quantificar o índice de ferrugem no trigo usando imagens hiperespectrais capturadas por UAV e aprendizado de máquina profundo. Os autores usaram um método de segmentação semântica, e um algoritmo Unet foi treinado para obter limiares precisos e gerar anotações sobre doenças de ferrugem nas culturas. Para modelar os resultados das diferentes funções de perda, foi utilizado o algoritmo

HRNet_W48 no conjunto de dados. O resultado do estudo mostrou que a combinação dos algoritmos produziu um valor de R^2 de 87,5% e um erro quadrático médio (MSE) de 1,29%, ambos significativos para o monitoramento de doenças nas culturas de trigo.

Casas *et al.* [90] apresentaram uma ferramenta para detecção de doenças como *Servomyces phoenicis* e *Phenacoccus malfatti* em palmeirais usando imagens multiespectrais e aprendizado de máquina. Os autores utilizaram técnicas de segmentação e classificação de imagens para calcular o número de folhas afetadas por doenças de cada palmeira. Em seguida, os autores compararam os dados calculados com as informações coletadas no local do experimento. Os resultados do estudo mostraram que a precisão da detecção da doença em palmeiras foi de 96% para folhas afetadas e saudáveis.

3.5. Praga Agrícola

Desde a semeadura até a colheita, pragas agrícolas podem invadir plantações e causar prejuízo financeiro ao produtor [91]. Por esta razão, novos estudos buscam detectar precocemente a aparição de pragas em plantações além de tornar mais eficiente a aplicação de insumos [92]. Neste contexto, o uso de equipamentos de sensoriamento remoto, com câmeras de alta resolução compostas por múltiplos sensores, além de aprendizagem profunda para análise de padrões, pode ser um aliado importante na detecção e classificação de pragas agrícolas [93].

Duarte *et al.* [94] apresentaram um estudo que aprimora o processo de classificação de pragas da Broca *Longhorned* (ELB) em culturas de eucalipto, utilizando imagens aéreas multiespectrais capturadas por UAV e modelos de aprendizado de máquina. Os autores aplicaram o algoritmo de aprendizado de máquina supervisionado RF e SVM para classificar as copas das árvores e separá-las em árvores saudáveis e mortas. O resultado do estudo mostrou 98,35% de acerto ao utilizar o algoritmo RF e 97,70% de acerto na classificação de pragas ELB em culturas de eucalipto ao utilizar o algoritmo de aprendizado de máquina SVM.

Tetila *et al.* [95] compararam os resultados de cinco arquiteturas de aprendizado de máquina para classificação de pragas agrícolas em soja (*Glycine max* L. Merrill) usando imagens capturadas por UAVs. Os autores compararam o desempenho do Inception-v3, Resnet-50, VG-16, VGG-19 e Xception, com diferentes estratégias de

ajuste fino, utilizando 5.000 imagens aéreas. O resultado do estudo mostrou que as arquiteturas de aprendizado de máquina profundo alcançaram uma precisão de 93,32% em comparação com outras abordagens algorítmicas para algoritmos de classificação de imagens como SVM, K-NN e Random Forest.

Retallack *et al.* [96] demonstraram a viabilidade do uso de modelos de aprendizado de máquina profundo e imagens capturadas por UAV em pastagens no sul da Austrália para combater a degradação antropogênica e facilitar práticas de manejo eficazes. Os autores usaram sete detectores de objetos diferentes junto com a arquitetura de Rede Neural Convolutiva (CNN) para identificar uma espécie dominante de arbusto árido Pearl Bluebush (*Maireana sedifolia*). Os resultados do estudo mostraram uma precisão de 75% na detecção do arbusto dominante em uma área de pastagem.

Lia *et al.* [97] propuseram um modelo de aprendizado de máquina profundo para detectar tricomas de repolho chinês em um conjunto de dados com 10.955 imagens RGB. Os autores do estudo adicionaram um módulo RepVGG ao Backbone, bem como uma nova camada de detecção, e usaram a função *Wassertein Gaussian Distance Loss* normalizada para melhorar o desempenho. Os resultados mostraram que o modelo proposto pelos autores superou os modelos clássicos com precisão média de 94,4%.

Lin *et al.* [98] desenvolveram uma nova abordagem para detectar ataques de besouros do pinheiro (PSB) em plantações de pinheiro no sudoeste da China usando aprendizado de máquina e imagens hiperespectrais e térmicas capturadas por UAV. Os autores do estudo usaram um modelo de aprendizado de máquina RF para classificar diferentes níveis de danos às árvores causados pelo besouro do pinheiro, com base em medições de campo e diferentes características especiais de distribuição. Os resultados do estudo mostraram que o conjunto de dados de treinamento e de validação apresentou boa acurácia, índice R^2 acima de 95% e RMSE abaixo de 1,15 $\mu\text{g}/\text{cm}^2$, sendo a clorofila uma variável importante na detecção precoce do PSB.

3.6. Estimativa de Produtividade

Os desafios na produção de alimentos no mundo têm se tornado frequentes diante do crescimento da população e das mudanças climáticas [99]. O rendimento agrícola pode ser estimado para contribuir no aprimoramento das técnicas de produção de alimentos [100]. Neste sentido, estudos recentes que utilizam tecnologia de

sensoriamento remoto e IA buscam, principalmente, prever o número de sementes produzidas por planta e o comportamento de determinada variedade para obter o maior rendimento final possível [101].

Guo *et al.* [102] apresentaram uma metodologia para extração de altura em culturas de milho, baseada em imagens aéreas RGB e multiespectrais de UAV e aprendizado de máquina, em diferentes estágios de crescimento. Os autores utilizaram um modelo logístico único (SLM) e análise de série temporal harmônica (HANTS) para identificar a fenologia da cultura usando a altura da planta de milho. Os resultados do estudo mostraram que os índices de vegetação baseados em RGB foram eficazes na extração da altura do milho, com índice R^2 de 93%.

Xu *et al.* [103] estabeleceram um modelo para estimar a produção de algodão com base em dados de sensoriamento remoto de UAV e modelos de aprendizado de máquina. Os autores utilizaram o modelo de aprendizado de máquina U-Net para reconhecer e extrair pixels do conjunto de imagens, estimando a porcentagem de pixels na região de interesse. Em seguida, os autores combinaram imagens multiespectrais com as coberturas de pixels extraídas anteriormente e usaram uma rede neural de regularização bayesiana (*Back Propagation*) para estimar a produtividade do algodão. O resultado do estudo mostrou que o R^2 do modelo proposto é de 0,853 em uma escala de $0,81\text{m}^2$, o que pode atender aos requisitos para revisão de produtividade em algodão.

Ilniyaz *et al.* [104] avaliaram a capacidade de modelos de aprendizado de máquina em estimar o índice de área foliar em culturas de uva, utilizando imagens multiespectrais e RGB capturadas por UAV. Os autores fizeram testes de campo com diferentes épocas de cultivo da cultura, coletando 465 amostras de índice de área foliar. Eles então começaram a treinar cinco modelos de aprendizado de máquina com diferentes índices espectrais de imagens aéreas, incluindo o treinamento com o modelo de rede neural convolucional (CNN), baseado em ResNet. Os resultados do estudo mostraram que as imagens multiespectrais tiveram melhor desempenho na estimativa do índice de área foliar do que as imagens RGB, com valores de R^2 e *Root Mean Square Error* (RMSE) de 0,899 e 0,434, respectivamente.

Peng *et al.* [105] propuseram uma estimativa da produtividade do líquido primário no cultivo do milho usando imagens aéreas multiespectrais e modelos de aprendizado de máquina. Os autores usaram quatro algoritmos de aprendizado de máquina, incluindo *RF*, *Support Vector Regression* (SVR), *Gradient Boosting Regression* (GBR) e índices de vegetação, solo e fatores de radiação fotossintetizantes

ativos para estimar a produtividade do líquido primário diurno na copa do milho. Os resultados mostraram que o modelo GBR obteve o melhor desempenho, com R^2 igual a 0,958, o que pode estimar 89,90% de produtividade de líquido primário na cultura do milho com imagens aéreas.

Barbosa *et al.* [106] usaram algoritmos de aprendizado de máquina e imagens capturadas por UAV para estimar a altura e o diâmetro da copa do cafeeiro para prever a produtividade da cultura. Os autores utilizaram seis parâmetros, entre eles, índice de área foliar, altura da planta e diâmetro da copa para estimativa de produtividade, tendo sido utilizados cinco modelos de aprendizado de máquina, incluindo algoritmos SVM, GBR, RF, Regressão Parcial de Quadrados Mínimos (PLSR) e Neuroevolução de Topologias de Aumento (NEAT). O resultado do estudo mostrou que o modelo de aprendizado de máquina com melhor desempenho na previsão de produtividade foi o NEAT com 31,75% de erro percentual médio absoluto (MAPE).

Alabi *et al.* [107] usaram modelos de aprendizado de máquina e imagens multiespectrais capturadas por UAV para auxiliar no fluxo de trabalho fenotípico para estimar a produtividade na cultura da soja (*Glycine max* L. Merr.), na Nigéria, em 2020. Os autores usaram índices de vegetação, textura e altura da copa das plantas, além de cinco algoritmos de aprendizado de máquina, incluindo *Cubist*, XGBoost, GBM, SVM e RF, para prever o rendimento de grãos na cultura da soja. Os resultados do estudo mostraram que os modelos de aprendizado de máquina cubista e RF, com R^2 de 0,89, previram efetivamente o rendimento da cultura da soja.

Teshome *et al.* [108] avaliaram a eficácia da combinação de imagens aéreas capturadas usando UAV e técnicas de aprendizado de máquina para estimar a altura do milho, biomassa e produtividade do tipo doce *Zea mays* var. *saccharata*. Os autores utilizaram um UAV DJI Matrice 210 v2 equipado com um sensor multiespectral para capturar as imagens e três modelos de aprendizado de máquina para prever a altura e a biomassa da planta, o algoritmo GLMNET, RF, SVM e o algoritmo k - vizinho mais próximo (KNN). Os resultados do estudo mostraram que os modelos SVM e KNN apresentaram bom desempenho para estimativa de biomassa com valores de R^2 entre 0,88 e 0,99. Além disso, o algoritmo GMLNET apresentou melhor desempenho na estimativa da altura das plantas em comparação com os diversos modelos.

Ariza-Sentís *et al.* [109] estimaram a produtividade de sementes de espinafre (*Spinacia oleracea*) usando um modelo de aprendizado de máquina profundo e capturaram imagens por UAV. Os autores apresentaram uma nova abordagem que

correlaciona o número de plantas com a área plantada e a porcentagem de cobertura da copa das plantas. O modelo de aprendizado de máquina profundo Mask R-CNN foi aplicado para contar o número de plantas de espinafre, obtendo a máscara do objeto da qual deriva a área da planta. Os resultados do estudo mostraram uma correlação linear entre o número de sementes e o modelo multivariado linear misto das três variáveis, com R^2 de 0,80.

Niu *et al.* [110] propuseram uma nova semântica de modelo de segmentação para mapear o rendimento das culturas usando o modelo de máquina profunda HIS-TransUNet e imagens hiperespectrais capturadas por UAV. Os autores fizeram modificações nas imagens hiperespectrais, melhorando o modelo já existente da TransUNet, para mapear culturas diversas. Os resultados do estudo mostraram que o modelo proposto pelos autores alcançou 86,05% de precisão na identificação de culturas.

Pandey e Jain [111] apresentaram um novo modelo de aprendizado de máquina profundo para identificar e classificar culturas com o uso de imagens capturadas pelo UAV. Os autores usaram um conjugado denso de rede neural convolucional (CD-CNN) com uma nova função de ativação chamada SL-ReLU para classificar culturas usando imagens aéreas RGB. Os resultados do estudo mostraram que o módulo proposto alcançou 96,20% de precisão na classificação das culturas agrícolas.

Vong *et al.* [112] estimaram e mapearam a uniformidade de emergência na cultura do milho usando imagens de UAV e um modelo de aprendizado de máquina profundo. Os autores utilizaram uma rede neural convolucional ResNet18 pré-treinada e imagens aéreas para estimar parâmetros de emergência como densidade de plantas e padrão de desvio de espaçamento entre plantas e dias médios. Os resultados do estudo mostraram que a densidade e o padrão de espaçamento de desvio entre plantas e dias médios após a emergência (DAE_{mean}) apresentaram acurácia de 97%, 73% e 95%, respectivamente.

Chen *et al.* [113] desenvolveram um canal para espectros de extração de características e morfologia de macieiras usando dois aprendizados de máquina e imagens multispectrais capturadas de um UAV. Os autores utilizaram dois modelos de aprendizado de máquina, a regressão vetorial de suporte (SVR) e o vizinho K mais próximo (KNN), usando detecção e alcance de luz (LiDAR) para prever o rendimento individual da macieira. Três métodos foram considerados para prever a produtividade das plantas, a saber: imagens do espectro dos frutos, propriedades morfológicas e

características de crescimento e desenvolvimento individual das árvores. Os resultados do estudo mostraram precisão de 75,80% e R^2 de 0,813 na predição do desempenho na cultura da maçã.

Wang *et al.* [114] usaram um modelo aprimorado de aprendizado de máquina YOLOv5s para detectar maçãs em imagens capturadas por UAV. Os autores capturaram 300 imagens de alta resolução, segmentaram a área de interesse e aplicaram melhorias nos módulos RFA, DFP e algoritmo Soft-NMS para obter precisão na detecção de objetos isolados nas imagens. O resultado do estudo mostrou que o modelo proposto pelos autores alcançou índice de acurácia de 95,4%, taxa de reconvocação de 86,1% e escore mAP de 91,8%.

Xu *et al.* [115] desenvolveram um modelo para contagem do número de folhas em culturas de milho usando imagens semissupervisionadas de dois modelos de aprendizado de máquina profundo e imagens aéreas capturadas por UAV. Os autores segmentaram o conjunto de dados de mudas completas de milho usando os algoritmos SOLOv2 e YOLOv5x. O resultado do estudo mostrou que o modelo SOLOv2 Resnet101 superou o modelo SOLOv2 Resnet50, alcançando precisão média de 93,6%. O modelo YOLOv5x apresentou acurácia média de 89,6% para folhas totalmente desdobradas e 57,4% para folhas recém-aparecidas.

Feng *et al.* [116] usaram aprendizado de máquina profundo para detectar e contar mudas de algodão com base em imagens multiespectrais capturadas por UAV. Os autores treinaram três modelos de aprendizado de máquina profundo, YOLOv7, YOLOv5 e CenterNet, para detectar e contar mudas de algodão em seis períodos diferentes. O resultado do estudo mostrou que o modelo YOLOv7 obteve melhores resultados com precisão, recall, F1-Score de 96,9%, 96,6% e 96,7%, respectivamente, e os valores dos índices R^2 , RMSE e Relative Root Mean Square Error (RRMSE) de 94%, 3,83% e 2,72%, respectivamente.

Tunca *et al.* [117] treinaram cinco modelos de aprendizado de máquina para estimar o índice de área foliar em culturas de sorgo com base em imagens aéreas de UAV. Os autores conduziram um experimento de campo com quatro tratamentos ao longo de dois anos e capturaram imagens multiespectrais e térmicas de UAV, além de medidas de índice de área foliar destrutiva para comparação. Os cinco algoritmos usados para treinamento de modelo incluem K-Nearest Neighbors (K-NN), Extra Trees Regressor (ETR), XGBoost, RF e Support Vector Regression (SVR). Os resultados do estudo mostraram que o modelo K-NN apresentou a maior acurácia entre os demais

modelos, com índices R^2 , RMSE e MAPE de 97%, 46% e 19,7%, respectivamente.

Ma *et al.* [118] propuseram um modelo de aprendizado de máquina profundo para prever a produtividade agrícola com base em imagens multiespectrais e térmicas capturadas por drones em plantações de trigo. Os autores utilizaram um modelo denominado MultimodalNet e compararam métodos e recursos baseados em imagens multimodais. Em seguida, um modelo final de aprendizado de máquina foi construído usando recursos espectrais, térmicos e de textura do dossel. Os resultados do estudo mostraram que o modelo teve melhor desempenho na fase de forçamento, com coeficiente de determinação de 74,11% e erro percentual absoluto médio (MAPE) de 6,05%.

Liu *et al.* [119] desenvolveram um método para melhorar a precisão da estimativa da área foliar do milho, utilizando imagens multiespectrais e aprendizado de máquina. Os autores usaram um algoritmo RF para processar dados de treinamento paralelo e um algoritmo *Gradient Boosting Tree* (GBDT) para minimizar a diferença entre os valores previstos e verdadeiros da saída. Os resultados do estudo mostraram que o modelo proposto apresentou melhor acurácia com índice R^2 de 94% e NRMSE de 9,35% no estágio foliar V14.

Demir *et al.* [120] desenvolveram modelos de previsão de rendimento para cultivo de rosas orgânicas, com base em imagens capturadas por UAV e algoritmos de aprendizado de máquina. Os autores usaram modelos de aprendizado de máquina, que incluem regressão linear múltipla (MLR), splines de regressão adaptativa multivariada (MARS), árvores de decisão (detector de interação automática qui-quadrado (CHAID), detector de interação automática qui-quadrado exaustivo-quadrado) (ExCHAID), árvore de classificação e regressão (CART), floresta aleatória (RF)) e rede neural artificial (RNA) para prever a produtividade agrícola no cultivo orgânico de rosas. Os resultados mostraram que os modelos treinados obtiveram índices R^2 de 90,7% (MARS), R^2 de 88,8% (Ex-CHAID), R^2 de 93,1% (CART 1) e R^2 de 90,9% (RF1), e foram capazes de predeterminar o rendimento precoce das rosas orgânicas.

Jamali *et al.* [121] monitoraram variáveis biofísicas do trigo usando imagens aéreas multiespectrais de UAV e modelos de aprendizado de máquina profundo. Os autores estimaram a altura da planta de trigo, o estágio foliar, o índice de área foliar, o teor de nitrogênio e a matéria seca na cultura do trigo em vários estágios de crescimento. Os modelos de aprendizado de máquina profundo usados no estudo incluem Rede Neural Artificial (ANN), SVM e Rede Neural Profunda (DNN). Os

resultados do estudo mostraram que o modelo Rede Neural Profunda apresentou melhor desempenho em todos os parâmetros, exceto no percentual de nitrogênio, com índice R^2 de 0,8; 0,95; 0,95 e 0,90, RMSE de 9,61; 0,46; 0,47 e 1,2 e Erro Percentual Médio Absoluto (MAPE, sigla em inglês) de 26,4; 0,34; 0,28 e 0,84 para estimar a altura da planta de trigo, o estágio foliar, o índice de área foliar, o teor de nitrogênio e a matéria seca na cultura do trigo em vários estágios de crescimento, respectivamente.

Qu *et al.* [122] avaliaram dois modelos de aprendizado de máquina para estimar o rendimento agrícola de culturas de mirtilo silvestre usando UAVs. Os autores utilizaram imagens aéreas RGB e suas características de cor e textura para prever a produção de mirtilo em uma área experimental, com base nos modelos RF e XGBoost. Os resultados do estudo mostraram que o modelo XGBoost obteve melhor desempenho, com índice R^2 de 89%, RMSE de 542,91 e MAPE de 379,94, quando comparado ao modelo RF.

4. RESULTADOS E DISCUSSÃO

A interpretação dos tipos de problemas agrícolas recorrentes no campo depende do nível de experiência do profissional que irá trabalhar no problema, além de uma análise para cada caso aqui apresentado, o que levará tempo até que seja identificado e resolvido. Para Sivakumar *et al.* [123], há interesse recente na utilização de algoritmos de aprendizado de máquina que possam ajudar a reduzir trabalhos repetitivos no campo e otimizar tarefas que envolvem o diagnóstico e a análise de dados agrícolas, economizando tempo e dinheiro para o produtor rural.

Esta Revisão Sistemática da Literatura identificou que pesquisas com imagens capturadas por UAVs, combinadas aos modelos de aprendizado de máquina, podem auxiliar significativamente na detecção, classificação e solução de problemas de análise em culturas agrícolas. A popularização do ML e DL e o aumento do poder computacional nos últimos anos contribuiriam consideravelmente para a melhoria na precisão dos resultados envolvendo a visão computacional.

4.1. Percentual de pesquisas da RSL conforme técnicas que automatizam processos agrícolas

Quantificando o percentual de artigos obtidos nesta Revisão Sistemática da

Literatura, temos o seguinte: 30,0% de Planta Daninha; 4,28% de Deficiência Nutricional; 11,42% de Estresse Hídrico; 18,57% de Doenças de Plantas; 8,57% de Pragas Agrícolas; e 28,57% da estimativa de rendimento.

4.2. Respostas para as questões da pesquisa

Q1) Em quais tipos de problemas de estudos agronômicos, através de análise de imagens, foi aplicada a IA para dar suporte às decisões agrícolas?

Esta RSL apresenta as principais aplicações da IA para os seguintes tipos de problemas agronômicos: Ervas daninhas na subseção 3.2 e os artigos apresentados na Tabela 2; Deficiência Nutricional (subseção 3.3) e Tabela 3; Estresse Hídrico (subseção 3.4) e Tabela 4; Doenças de Plantas (subseção 3.5) e Tabela 5; Pragas Agrícolas (subseção 3.6) e Tabela 6; e Estimativa de rendimento (subseção 3.7) e Tabela 7.

Q2) Quais foram as técnicas e precisão dos modelos de IA aplicados?

Técnicas/métodos, métricas e acurácia estão disponíveis nas Tabelas 2 a 7, nas colunas “Métricas” e “Precisão”, ficando o percentual de artigos obtidos nesta Revisão Sistemática da Literatura com a seguinte configuração: 30,0% de Planta Daninha; 4,28% de Deficiência Nutricional; 11,42% de Estresse Hídrico; 18,57% de Doenças de Plantas; 8,57% de Pragas Agrícolas; e 28,57% da estimativa de rendimento.

Tabela 2. Artigos incluídos na RSL – Planta daninha

Id	Ref.	Culture	LT ⁴	MTD/TNQ ³	Sensor Type	Metrics	Precision
1	Fraccaro et al. [38]	Trigo	SP ¹	UNET-ResNet	RGB ¹¹	r ⁵ , Acc	90,0%
2	Bah et al. [39] Huang et al. [40]	-	SP	CNN Back Propagation, RF ¹² ,	RGB	Acc	93,58%
3		Arroz	SP	AlexNet, VGGNet, GoogleNet e ResNet	RGB	Acc	80,2%
4	Beehary e Bassoo [41]	Soja	SP	ANN e AlexNet	RGB	Acc	99,81%
5	Reedha et al. [42]	Espinafre	SP	EfficientNet e ResNet	RGB	r	98,63%
6	Bah et al. [49]	Espinafre/Feijão	NSP ²	CNN	RGB	Acc	1,50% e 6%
7	Genze et al.	Sorgo	SP	UNET-ResNet	RGB	Houd-out test	89%

8	[43] Gallo et al. [44]	Beterraba	SP	YOLOv7	RGB	mAP	74%
---	------------------------------	-----------	----	--------	-----	-----	-----

Tabela 2. *Continuação*

Id	Ref.	Cultura	LT	MTD/TNQ	Tipo de Sensor	Métricas	Precisão
9	Ajayi et al. [45]	Espinafre/ca na-de-açúcar	SP	CNN e YOLOv5	RGB	Acc	78%, recall de 65
10	Pei et al. [46]	Milho	SP	YOLOv4	RGB	mAP	87%
11	Su et al. [47]	Trigo	SP	RF	Multiespectr al	Acc	94%
12	Barrero e Perdomo [48]	Arroz	SP	NN ¹⁰	RGB e Multiespectr al	M/MGT(%) e MP(%) ⁹	80 a 108%
13	Naveed et al. [50]	-	SP	Neural modulation Network (PC/BC- DIM)	Multiespectr al	Acc	94%
14	Chegini et al. [51]	Pasto	SP	MaskRCNN	Multiespectr al	mAP e Acc	93% e 95%
15	Xu et al. [52]	Soja	SP	ResNet101_ v e DSASPP	RGB	Acc	91%
16	Nagothu et al. [53]	Algodão	SP	SSD Mobilenet	RGB e Multiespectr al	Acc	95%
17	Nasiri et al. [54]	Beterraba	SP	U-Net e CNN	RGB	IoU ⁸	As pontuaçõe s de 0,9606 e 0,8423, respectiva mente. 97%, recall de 99%, e pontuação F1 de 99% em 242.000 épocas.
18	Ajayi e Ashi [55]	Cana-de- açúcar, banana, espinafre e pimenta	SP	RCNN	RGB	Acc	
19	Rahman et al. [56]	Algodão	SP	YOLOv5, RetinaNet, EfficientDet, Fast RCNN, e Faster	RGB	Acc ¹¹ e mAP ¹²	79,98% e mAP@0. 50

20	Diao et al. [57]	Milho	SP	YOLOv8s	RGB	mAP e F1 ¹³	86,4% e 86%
21	Mekhalifa et al. [58]	Soja	SP	AlexNet, VGG16, GoogLeNet, ResNet50, SqueezeNet e MobileNet	RGB	Acc	98%

¹ Supervisionado (SP), ² Não supervisionado (NSP), ³ método/técnica (MTD/TNQ), ⁴ tipo de aprendizado (LT), ⁵ correlation (r), ⁶ intersection over union (IoU), ⁷ master of management (M/MGT(%), MP(%)), ⁸ neural network (NN), ⁹ red, green and blue (RGB), ¹⁰ random forest (RF), ¹¹ accuracy (Acc), ¹² mean average precision (mAP), ¹³ F-Score (F1).

Tabela 3. Artigos incluídos na RSL – Deficiência nutricional

Id	Ref.	Cultura	LT	MTD/TNQ	Tipo de Sensor	Métricas	Precisão
1	Sánchez-DelaCruz et al. [61]	Laranja	SP	MLP ¹⁵	RGB	Acc	96,66%
2	Sathyavani et al. [62]	Tomate/Pimenta	SP	CNN ¹⁶	RGB	Acc	79,11%
3	Sabzi et al. [64]	Pepino	SP	CNN	Hiperespectral	R ¹⁴	96,50%

¹⁴ Regression (R), ¹⁵ multi-layer perceptron (MLP), ¹⁶ convolutional neural network (CNN).

Tabela 4. Artigos incluídos na RSL – Estresse hídrico

Id	Ref.	Cultura	LT	MTD/TNQ	Tipo de Sensor	Métricas	Precisão
1	Bhandari et al. [68]	Alface	SP	CNN	RGB e Multiespectral	R	62,30%
2	Sankararao et al. [69]	Painço	NSP	SVM	Hiperespectral	Acc	81%
3	Sankararao et al. [70]	Grão de bico	SP	CNN	Hiperespectral	Acc	95,44%
4	Tunca et al. [71]	-	SP	RF, SVM ¹⁶ , KNN ¹⁷ e XGBoost ¹⁸	RGB	r	r = 0,89 a 0,96 Micasens e Altum e 0,87 a 0,94 (FDP-R).
5	Bertalan et al. [72]	Milho	SP	RF, ENR ¹⁹ , GLM ²⁰ e RLM ²¹	Termal e Multiespectral	r e NRMSE	r = 0,97 vs 0,71, NRMSE = 10 vs

25%,
respectiva
mente,
RF (r =
0,97) e
ENR (r =
0,88).

Tabela 4. *Continuação*

Id	Ref.	Cultura	LT	MTD/TNQ	Tipo de Sensor	Métricas	Precisão
6	Niu et al. [73]	Milho Trigo	SP	RF, ANN ²² e MLR ²³	RGB e Multiespectr al	r e NRMSE	r = 0,01 e diferença de RMSE = 0,01. r = 0,86; RMSE = 41,3 g/m ² , r = 0,75; RMSE = 47,7 g/m ² , produtivi dade do grão, onde r = 0,78; RMSE = 16,7 g/m ² , r = 0,69; RMSE = 23,2 g/m ² . r = 88%, RMSE = 8%, NRMSE = 14,7%, e fase de preenchi mento com r = 90%, RMSE = 5% e NRMSE = 15,9%.
7	Das et al. [74]		SP	CRT ²⁴	Termal	r, RMSE ²⁵ e NRMSE ²⁶	
8	Wang et al. [75]	Trigo	SP	PLS ²⁷ , SVM e GBDT ²⁸	Multiespectr al e Termal	r, RMSE e NRMSE	

¹⁶ Support vector machine (SVM), ¹⁷ K-nearest neighbors (KNN), ¹⁸ extreme gradient boosting (XGBoost), ¹⁹ elastic net (ENR), ²⁰ general linear model (GLM), ²¹ robust linear model (RLM), ²² artificial neural network (ANN), ²³ multivariate linear regression (MLR), ²⁴ classification and regression tree (CRT), ²⁵ root mean square error

(RMSE), ²⁶ mean-normalized root mean square error (NRMSE), ²⁷ partial least squares (PLS), ²⁸ gradient boosting decision tree (GBDT).

Tabela 5. Artigos incluídos na RSL – Doença em planta

Id	Ref.	Cultura	LT	MTD/TNQ	Tipo de Sensor	Métricas	Precisão
1	Pan et al. [78]	Trigo	SP	PSPNet ³⁰	RGB	Acc	98%
2	Wu et al. [79]	Pinho	SP	Faster R-CNN ³⁴ e YOLO ³¹	RGB	Acc	78%
		Banana					Doença do topo da banana (99,40%), Murcha de Banana Xanthomonas (92,80%), cacho de banana saudável (93,30%), e plantas de bananas individuais (90,80%).
3	Selvaraj et al. [80]		SP	RF e RetinaNet	RGB	Acc	
4	Amarasingam et al. [81]	Cana de açúcar	SP	YOLOv5, YOLOR ³² , DETR ³³ e Faster R-CNN	RGB	Acc	95%
		Pinho					66,70% (Faster R-CNN) e 63,55% (YOLOv4)
5	Yu et al. [82]		SP	Faster R-CNN e YOLOv4	Multiespectral	Acc	
6	Shi et al. [83]	Batata	SP	CropdocNet	Hiperespectral	Acc	98%
		Uva					92% de detecção ao nível da videira e 87% ao
7	Kerkech et al. [84]		SP	VddNet ²⁹	Multiespectral	Acc	

Table 5. Cont.

Id	Ref.	Cultura	LT	MTD/TNQ	Tipo de Sensor	Métricas	Precisão
8	Shankar et al. [85]	-	SP	ANN	RGB	-	-
9	Delgado et al. [86]	Arroz	NSP	SVM e RF	Multiespectral	r	0,74 (SVM) versus 0,71 (RF)
10	Khan et al. [87]	-	SP	EfficientNet	RGB	Acc	99,55%
11	Oide et al. [88]	Pinho	SP	SVM, RF, ANN	RGB	Acc	99,50%
12	Deng et al. [89]	Trigo	SP	Unet, HRNet_W48	Hiperespectral	r, MSE	r = 87,5% e MSE = 1,29%
13	Casas et al. [90]	Palmeira	SP	SVM, ANN, e RF	Multiespectral	Acc	96%

²⁹ Vine disease detection network (VddNet), ³⁰ pyramid scene parsing network (PSPNet), ³¹ you only look once (YOLO), ³² you only look once representation (YOLOR), ³³ detection transformer (DETR), ³⁴ region-based convolutional neural network (R-CNN).

Tabela 6. Artigos incluídos na RSL – Praga agrícola

Id	Ref.	Cultura	LT	MTD/TNQ	Tipo de Sensor	Métricas	Precisão
1	Duarte et al. [94]	Eucalipto	SP	SVM e RF	Multiespectral	Acc	RF = 98,35%, SVM = 97,7%
2	Tetila et al. [95]	Soja	SP	Inception-v3, Resnet-50, VGG-16 ³⁵ , VGG-19, Xception	RGB	Acc	93,82%
3	Retallack et al. [96]	Pasto	SP	CNN	RGB	Acc	75%
4	Lia et al. [97]	Repolho	SP	YOLOv8	RGB	AP50	94,40%
5	Lin et al. [98]	Pinho	SP	RF	Hiperespectral e termal	R ² e RMSE	R ² = 95% e RMSE = 1,15 µg/cm

³⁵ Very Deep Convolutional Network (VGG), ³⁶ sentence-level language modeling (SLM)

Tabela 7. Artigos incluídos na RSL – Estimativa de produtividade

Id	Ref.	Cultura	LT	MTD/TNQ	Tipo de Sensor	Métricas	Precisão
1	Guo et al. [102]	Milho	SP	SLM ³⁶ e HANTS	Multiespectral e RGB	r	93%.
2	Xu et al. [103]	Algodão	SP	U-Net, Back Propagation	Multiespectral	r	85,3%
3	Ilniyaz et al. [104]	Uva	SP	CNN, ResNet	Multiespectral e RGB	r e RMSE	r = 89,8% e RMSE = 0,434
4	Peng et al. [105]	Milho	SP	RF, SVR, GBR ⁴⁰	Multiespectral	r	0,899
5	Barbosa et al. [106]	Café	SP	SVM, RF, GBR, PLSR ³⁹	RGB	MAPE ³⁷	31,75%
6	Alabi et al. [107]	Soja	SP	Cubist, XGBoost, GBM ³⁸ , SVM e RF	Multiespectral	r	0,89
7	Teshome et al. [108]	Milho	SP	SVM, RF, KNN, GLMNET	Multiespectral	r, d e MAPE	d ⁴² = 0,99; r = 0,99; MAPE = 5cm
8	Ariza-Sentís et al. [109]	Espinafre	SP	Mask R-CNN	RGB	r	0,80
9	Niu et al. [110]	-	SP	TransUNet	Hiperespectral	Acc	86,05%
10	Pandey e Jain [111]	-	SP	CD-CNN ⁴¹	RGB	Acc	96,20%
11	Vong et al. [112]	Milho	SP	CNN ResNet18	RGB	Acc	97%, 73% e 95%
12	Chen et al. [113]	Maçã	SP	KNN, SVR	Multiespectral	Acc, r	Acc = 75,80% e r = 0,813
13	Wang et al. [114]	Maçã	SP	YOLOv5s	RGB	Acc, mAP, recall	Acc = 95,4%, mAP = 86,1% e recall = 91,8%
14	Xu et al. [115]	Milho	SSP	SOLOv2 e YOLOv5x	RGB	mAP	93,6%, 89,6% e 57,4%
15	Feng et al. [116]	Algodão	SP	YOLOv7, YOLOv5 e CenterNet	Multiespectral	r, RMSE e RRMSE ⁵¹	0,94, 3,83 e 2,72%, respectivamente

Tabela 7. Cont.

Id	Ref.	Cultura	LT	MTD/TNQ	Tipo de Sensor	Métricas	Precisão
16	Tunca et al. [117]	Sorgo	SP	K-NN, ETR ⁴³ , XGBoost, RF e SVR ⁴⁴	Multiespectral e termal	r, RMSE e MAE	0,97, 0,46 e 0,197, respectivamente
17	Ma et al. [118]	Trigo	SP	Multimodal Net	Multiespectral e termal	r e MAE	r = 74,11% e MAE = 6,05%.
18	Liu et al. [119]	Milho	SP	RF e GBDT	Multiespectral	r e rRMSE	r = 94% e rRMSE = 9,35% no estágio de folha V14
19	Demir et al. [120]	Rosa	SP	MLR ⁴⁵ , MARS ⁴⁶ , CHAID ⁴⁷ , ExCHAID ⁴⁸ , CART ⁴⁹ , RF e RNA	RGB	r	r = 90,7% (MARS), r = 88,8% (ExCHAID), r = 93,1% (CART 1) e r = 90,9% (RF1).
20	Jamali et al. [121]	Trigo	SP	ANN, SVM e DNN ⁵⁰	Multiespectral	r, RMSE e MAE	r = 0,82, 0,95, 0,95 e 0,90 RMSE = 9,61, 0,46, 0,47 e 1,2, e MAE = 26,4, 0,34, 0,28 e 0,84
21	Qu et al. [122]	Mirtilo	SP	RF e XGBoost	RGB	r, RMSE e MAE	r = 89%, RMSE = 542,91 e MAE = 379,94

³⁷ Mean absolute percentage error (MAPE), ³⁸ stochastic gradient boosting (GBM), ³⁹ partial least square regression (PLSR), ⁴⁰ gradient boosting regression (GBR), ⁴¹ cross-domain convolutional neural network (CD-CNN), ⁴² height (d), ⁴³ extra trees regressor (ETR), ⁴⁴ support vector regression (SVR), ⁴⁵ multiple linear regression (MLR), ⁴⁶ multivariate adaptive regression splines (MARS), ⁴⁷ chi-square automatic interaction detector (CHAID), ⁴⁸ exhaustive chi-square automatic interaction detector (ExCHAID), ⁴⁹ classification and regression tree (CART), ⁵⁰ deep neural network (DNN), ⁵¹ relative root mean square error (RRMSE).

Q3) Quais os desafios/limitações na aplicabilidade da IA a cada tipo de análise de imagem agrícola?

Os desafios/limitações do uso de IA nas análises foram coletados dos artigos e adicionados, tendo sido observado que a principal limitação da área era a falta de um conjunto de dados públicos, pois são utilizados conjuntos de dados privados, em que os experimentos não podem ser replicados ou comparados, impossibilitando a avaliação de resultados do estado da arte. Além disso, para o treinamento dos modelos, são necessárias anotações sobre uma grande quantidade de dados para treinamento supervisionado, visto ser trabalhoso o processo de rotulagem de imagens e exigir muito esforço humano para tal tarefa.

Q4) Quais técnicas/métodos foram mais utilizados?

Técnicas de aprendizado de máquina baseadas em supervisão de aprendizagem foram mais utilizadas, principalmente articulações de modelos em redes neurais convolucionais. As técnicas apresentaram boa precisão nas tarefas de detecção, segmentação e classificação de imagens. Os modelos CNN são capazes de detectar soluções de última geração para problemas que envolvem visão computacional.

Q5) Como a IA pode contribuir para apoiar a análise de imagens agrícolas?

Pesquisas recentes indicam que os sistemas que utilizam IA têm o potencial de automatizar processos na agricultura, como, por exemplo, detecção automática de ervas daninhas, detecção e classificação de doenças em plantas e estimativa de rendimento, entre outros. Além disso, os modelos de aprendizagem profunda podem automatizar processos com durabilidade de tempo menor para concluir tarefas, refletindo na lucratividade do produtor.

Q6) Qual foi o tipo de problema agrônômico mais estudado nas pesquisas?

O resultado da quantificação da RSL mostra que os estudos com Planta Daninha correspondem a 30% dos artigos. Este percentual indica que esta foi a área de maior interesse estudada pela comunidade científica. Observando as Figuras 4 e 5, é possível notar que ficou evidente a discrepância de quantidade entre o número de publicações por ano e por tipo de problema agrônômico.




Figura 4. Número de artigos e cronologia de publicações por tipo de problema agrônômico.




Figura 5. Número de artigos publicados e plataformas científicas por tipo de problema agrônômico.

5. CONCLUSÃO

Os resultados apresentados nesta RSL mostram que nos últimos seis anos houve avanços significativos no apoio às decisões agrícolas. Os métodos de Deep Learning mostraram melhores resultados no apoio à detecção de ervas daninhas, classificação de doenças de plantas e estimativa da produtividade agrícola nas culturas através de imagens capturadas por UAVs. Os modelos YOLO e CNN e suas variações apresentaram os melhores resultados para todos os grupos apresentados nesta RSL. Este tema de pesquisa ainda está aberto, em razão da rápida evolução dos sistemas que utilizam IA para auxílio à tomada de decisões, no entanto já apresenta resultados altamente satisfatórios quanto à eficiência na análise dos dados. O acompanhamento das atualizações e aplicações das ferramentas de IA merece a atenção de pesquisadores que buscam continuamente melhorar os processos automatizados, com incrementos na eficiência de análise de dados advindos do manejo agrícola.

6. REFERÊNCIAS BIBLIOGRÁFICAS

1. *Brazil na revolução 4.0*. CEPEA-ESALQ/USP. 2019. Available online: <https://www.cepea.esalq.usp.br/br/opiniao-cepea/o-brasil-na-revolucao-4-0.aspx> (accessed on 03 April 2023).
2. Rossetto, R.; Santiago, A. D. *Cana: Plantas Daninhas*. Brasília, DF: Embrapa: Parque Estação Biológica, PqEB, 2022. Available online: <https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/cana/producao/manejo/plantas-daninhas> (accessed 05 April 2023).
3. Bah, M.D., Hafiane, A., Canals, R. CRoWNet: Deep network for Crop row detection in UAV images. *IEEE Access*. 2019. <https://10.1109/ACCESS.2019.2960873>.
4. Castro, A.I., Torres-Sánchez, J., Peña, JM, Jiménez-Brenes, FM, Csillik, O., López-Granados, F. An automatic random forest-OBIA algorithm for early weed mapping between and within crop rows using UAV imagery. *Remote Sens*. 2018, 10, 1–21. <https://doi.org/10.3390/rs10030443>.
5. Gill, S. S, Tuli, S., Xu, M., Singh, I., Singh, K. V., Lindsay, D., Tuli, S., Smirnova, D., Singh, M., Jain, U., Pervaiz, H., Sehgal, B., Kaila, S, S., Misra, S., Aslanpour, M. S., Mehta, H., Stankoviski, V., Garraghan, P. Transformative effects of IoT, Blockchain and Artificial Intelligence on cloud computing: Evolution, vision, trends and open challenges. *Internet of Things*. 2019, 8. <https://doi.org/10.1016/j.iot.2019.100118>.
6. Lolito, V., Zmbelli, T. Pattern detection in colloidal assembly: A mosaic of analysis techniques. *Advan. in Colloid and Inter. Science*. 2020, 284, 102252. <https://doi.org/10.1016/j.cis.2020.102252>
7. Etienne, A., Ahmad, A., Aggarwal, V., Saraswat, D. Deep learning-based object detection system for identifying weeds using UAS imagery. *Remote Sens*. 2021, 13, 1–22. <https://doi.org/10.3390/rs13010162>.
8. Inteligência artificial torna mais preciso o mapeamento da intensificação agrícola no Cerrado. *Embrapa*, 2023. Available online: <https://www.embrapa.br/busca-de-noticias/-/noticia/83327528/inteligencia-artificial-torna-mais-preciso-o-mapeamento-da-intensificacao-agricola-no-cerrado> (accessed on 06 April 2023).
9. Shankar, H.R., Veeraraghavan, A.K., Uvais, Sivaraman, K., Ramachandran, S.S. Application of UAV for Pest, Weeds and Disease Detection using Open Computer Vision. 2018 *International Conference on Smart Systems and Inventive Technology (ICSSIT)*, Tirunelveli, India. 2018, 287-292. <https://doi.org/10.1109/ICSSIT.2018.8748404>.
10. Hassler, S.C., Baysal-Gurel, F. Unmanned aircraft system (UAS) technology and applications in agriculture. *Agronomy*. 2019, 9. <https://doi.org/10.3390/agronomy9100618>.
11. Hamylton, S.M., Morris, R.H., Carvalho, R.C rderder, N., Barlow, P., Mills, K., Wang, L., 2020. Evaluating techniques for mapping island vegetation from unmanned aerial vehicle (UAV) images: Pixel classification, visual interpretation

- and machine learning approaches. *Int. J. Appl. Earth Obs. Geoinf.* 89, 102085. <https://doi.org/10.1016/j.jag.2020.102085>.
12. Haq, M.A. CNN Based Automated Weed Detection System Using UAV Imagery. *Computing Syst. Sci Eng.* 2021, 42, 837–849. <https://doi.org/10.32604/csse.2022.023016>.
 13. Islam, N., Rashid, M.M., Wibowo, S., Xu, C.Y., Morshed, A., Wasimi, S.A., Moore, S., Rahman, S.M. Early weed detection using image processing and machine learning techniques in an Australian chili farm. *Agric.* 2021, 11. <https://doi.org/10.3390/agriculture11050387>.
 14. Belete, N.A.S., Tetila, E.C., Astolfi, G., Pistori, H. Classification of weed in soybean crops using unmanned aerial vehicle images. *XV Workshop de Visão Computacional.* 2019, 121–125. <https://doi.org/10.5753/wvc.2019.7639>.
 15. Salazar, J., Sánchez-De La Cruz, E., Ochoa-Zezzatti, A., Rivera, M.M. Diagnosis of Collateral Effects in Climate Change Through the Identification of Leaf Damage Using a Novel Heuristics and Machine Learning Framework. *Metaheuristics in Machine Learning: Theory and Applications.* 2021, 61-75. https://doi.org/10.1007/978-3-030-70542-8_3.
 16. Ferreira, C.M., Barrigossi, J.A.F. *Embrapa Rice and beans: tradition and food security.* Technical editors. 2021, 16. Accessed online: <http://www.cnpaf.embrapa.br/languages/ricebeans.php> (accessed on 06 April 2023).
 17. Sanders, J.T., Jones, E.A.L., Austin, R., Roberson, G.T., Richardson, R.J., Everman, W.J. Remote sensing for palmer amaranth (*Amaranthus palmeri* s. wats.) detection in soybean (*Glycine max* (L.) Merr.). *Agro.* 2021, 11, 1–16. <https://doi.org/10.3390/agronomy11101909>.
 18. Sanders, J.T., Jones, E.A.L., Austin, R., Roberson, G.T., Richardson, R.J., Everman, W.J. Remote Sensing for Palmer Amaranth (*Amaranthus palmeri* S.Wats.) Detection in Soybean (*Glycine max* (L.) Merr.). *Agro.* 2021, 11, 1909. <https://doi.org/10.3390/agronomy11101909>.
 19. Valente, J.; Doldersum, M.; Roers, C.; Kooistra, L. Detecting *Rumex Obtusifolius* weed plants in grasslands from UAV RGB imagery using deep learning. *Remote Sens. Spat. Inf. Sci.* 2019, 4, 179–185. <https://doi.org/10.5194/isprs-annals-IV-2-W5-179-2019>.
 20. Peña, J.M., Torres-Sánchez, J., Castro, A.I., Kelly, M., López-Granados, F. Weed Mapping in Early-Season Maize Fields Using Object-Based Analysis of Unmanned Aerial Vehicle (UAV) Images. *PLoS One.* 2018, 8. <https://doi.org/10.1371/journal.pone.0077151>.
 21. Pham, F., Raheja, A., Bhandari, S. Machine learning models for predicting lettuce health using UAV imagery. *Proceedings SPIE 11008, Autonomous Air and Ground Sensing Systems for Agricultural Optimization and Phenotyping IV.* 2019, 110080Q. <https://doi.org/10.1117/12.2519157>.
 22. Preethi, C., Brintha, N.C., Yogesh, C.K. A comprehensive survey on applications of precision agriculture in the context of weed classification, leave disease detection, yield prediction and UAV Image analysis. *Adv. Parallel Computing.* 2021, 39, 296–306. <https://doi.org/10.3233/APC210152>.

23. Sun, G., Xie, H., Sinnott, R.O. A Crop Water Stress Monitoring System Utilizing a Hybrid e-Infrastructure. *Proceedings of the 10th International Conference on Utility and Cloud Computing*. 2017, 161–170. <https://doi.org/10.1145/3147213.3147222>.
24. Siqueira, V. S.; Borges, M. M.; Furtado, R. G.; Dourado, C. N.; Costa, R. M. Artificial intelligence applied to support medical decisions for the automatic analysis of echocardiogram images: A systematic review. *Artif. Intell. Med.* 2021 120:102165. doi: 10.1016/j.artmed.2021.102165.
25. Kitchenham, B. *Procedures for performing systematic reviews*. Keele, UK, Keele Univ. 2004. 1–26. ISSN:1353-7776.
26. *ACM digital library*. Available online: <https://dl.acm.org/search/advanced> (accessed on 03 April 2023).
27. *IEEE Xplore Digital Library*. Available online: <http://ieeexplore.ieee.org/Xplore/home.jsp> (accessed on 03 April 2023).
28. *Science Direct – Elsevier*. Available online: <https://www.sciencedirect.com/search/advanced> (accessed 03 April 2023).
29. *MDPI - Publisher of Open Access Journals*. Available online: <https://www.mdpi.com/> (accessed 05 April 2023).
30. *Web of science*. Available online: <https://apps.webofknowledge.com> (accessed 05 April 2023).
31. Jackulin, C., Murugavalli, S. A comprehensive review on detection of plant disease using machine learning and deep learning approaches. *Measurement: Sensors*. 2022, 24. <https://doi.org/10.1016/j.measen.2022.100441>.
32. Mohidem, N.A., 'he'ya, N.N., Juraimi, A.S., Ilahi, W.F.F., Roslim, M.H.M., Sulaiman, N., Saberioon, M., Noor, N.M. How can unmanned aerial vehicles be used for detecting weeds in agricultural fields? *Agric.* 2021, 11. <https://doi.org/10.3390/agriculture11101004>.
33. Rai, N., Zhang, Y., Ram, B.G., Schumacher, L., Yellavajjala, R.K., Bajwa, S., Sun, X. Applications of deep learning in precision weed management: A review. *Comput. Electron. Agric.* 2023, 206. <https://doi.org/10.1016/j.compag.2023.107698>.
34. Shahi, T.B.; Xu, C.-Y.; Neupane, A.; Guo, W. Recent Advances in Crop Disease Detection Using UAV and Deep Learning Techniques. *Remote Sens.* 2023, 15, 2450. <https://doi.org/10.3390/rs15092450>.
35. Kuswidiyanto, L.W.; Noh, H.H.; Han, X.Z. Plant disease diagnosis using deep learning based on aerial hyperspectral images: A review. *Remote Sens.* 2022, 14, 6031. <https://doi.org/10.3390/rs14236031>.
36. Varah, A.; Ahodo, K.; Coutts, S.R.; Hicks, H.L.; Comont, D.; Crook, L.; Hull, R.; Neve, P.; Childs, D.Z.; Freckleton, R.P. The costs of human-induced evolution in an agricultural system. *Nat. Sustain.* 2020, 3, 63–71. <https://doi.org/10.1038/s41893-019-0450-8>.
37. Hoerer, T.; Bachofer, F.; Kuenzer, C. Object detection and image segmentation with deep learning on Earth observation data: A review—Part II: Applications. *Remote Sens.* 2020, 12, 3053. <https://doi.org/10.3390/rs12183053>.

38. Fraccaro, P., Butt, J., Edwards, B., Freckleton, R.P., Childs, D.Z., Reusch, K., Comont, D. A Deep Learning Application to Map Weed Spatial Extent from Unmanned Aerial Vehicles Imagery. *Remote Sens.* 2022, 14, 4197. <https://doi.org/10.3390/rs14174197>.
39. Bah, H., Hafiane, A., Canals, R. Deep Learning with Unsupervised Data Labeling for Weed Detection in Line Crops in UAV Images. *Remote Sens.* 2018, 10, 1690. <https://doi.org/10.3390/rs10111690>.
40. Huang, H., Lan, Y., Yang, A., Zhang, Y., Wen, S., Deng, J. Deep learning versus Object-based Image Analysis (OBIA) in weed mapping of UAV imagery. *Int. J. Remote Sens.* 2020, 41, 3446–3479. <https://doi.org/10.1080/01431161.2019.1706112>.
41. Beeharry, Y., Bassoo, V. Performance of ANN and AlexNet for weed detection using UAV-based images. In *2020 3rd International Conference on Emerging Trends in Electrical, Electronic and Communications Engineering (ELECOM)*, Balaclava, Mauritius. 2020, 163-167. <https://doi.org/10.1109/ELECOM49001.2020.9296994>.
42. Reedha, R., Dericquebourg, E., Canals, R., Hafiane, A. Transformer Neural Network for Weed and Crop Classification of High-Resolution UAV Images. *Remote Sens.* 2022, 14, 592. <https://doi.org/10.3390/rs14030592>.
43. Genze, N., Ajekwe, R., Güreli, Z., Haselbeck, F., Grieb, M., Grimm, D. G. Deep learning-based early weed segmentation using motion blurred UAV images of sorghum fields. *Comput. Electron. Agric.* 2022. <https://doi.org/10.1016/j.compag.2022.107388>.
44. Gallo, I., Rehman, A.U., Dehkord, R.H., Landro, N., La Grassa, R., Boschetti, M. Deep Object Detection of Crop Weeds: Performance of YOLOv7 on a Real Case Dataset from UAV Images. *Remote Sens.* 2023, 15, 539. <https://doi.org/10.3390/rs15020539>.
45. Ajayi, O.G., Ashi, J., Guda, B. Performance evaluation of YOLO v5 model for automatic crop and weed classification on UAV images. *Smart Agric. Tech.* 2023, 5. <https://doi.org/10.1016/j.atech.2023.100231>.
46. Pei, H., Sun, Y., Huang, H., Zhang, W., Sheng, J., Zhang, Z. Weed Detection in Maize Fields by UAV Images Based on Crop Row Preprocessing and Improved YOLOv4. *Agric.* 2021, 975. <https://doi.org/10.3390/agriculture12070975>.
47. Su, J., Yi, D., Coombes, M., Liu, C., Zhai, X., McDonald-Maier, K., Chen, W.-H. Spectral analysis and mapping of blackgrass weed by leveraging machine learning and UAV multispectral imagery. *Comput. Electron. Agric.* 2022, 192, 106621. <https://doi.org/10.1016/j.compag.2021.106621>.
48. Barrero, O., Perdomo, S.A. RGB and multispectral UAV image fusion for Gramineae weed detection in rice fields. *Precision Agric.* 2018. <https://doi.org/10.1007/s11119-017-9558-x>.
49. Bah, M.D., Hafiane, A., Canals, R., Emile, B. Deep features and One-class classification with unsupervised data for weed detection in UAV images. 2019 *9th Int. Conf. Image Processing. Theory, Tools Appl. IPTA 2019*, 1–5. <https://doi.org/10.1109/IPTA.2019.8936091>.
50. Naveed A., Muhammad, W., Irshad, M.J., Aslam, M.J., Manzoor, S.M., Kauser,

- T., Lu, Y. Saliency-Based Semantic Weeds Detection and Classification Using UAV Multispectral Imaging. *IEEE Access*. 2023
<https://doi.org/10.1109/ACCESS.2023.3242604>.
51. Chegini H., Beltran F., Mahanti A. Designing and Developing a Weed Detection Model for California Thistle. *ACM Trans. Internet Technol.* 2023, 48, 29.
<https://doi.org/10.1145/3544491>.
 52. Xu, W., Chen, P., Zhan, Y., Chen, S., Zhang, L., Lan, Y. Cotton yield estimation model based on machine learning using time series UAV remote sensing data. *International Journal of Applied Earth Observ. Geoinfo.* 2021, 104, 102511.
<https://doi.org/10.1016/j.jag.2021.102511>.
 53. Nagothu, S. K., Anitha, G., Siranthini, B., Anandi, V., Prasad, P. S. Weed detection in agricultural crops using unmanned aerial vehicles and machine learning. *Materialstoday: Proceedings*. 2023.
<https://doi.org/10.1016/j.matpr.2023.03.350>.
 54. Nasiri, A., Omid, M., Taheri-Garavand, A., Jafari, A. Deep learning-based precision agriculture through weed recognition in sugar beet fields. *Sustainable Comput.: Informatics and Systems*. 2022, 35.
<https://doi.org/10.1016/j.suscom.2022.100759>.
 55. Ajayi, O.G., Ashi, J. Effect of varying training epochs of a Faster Region-Based Convolutional Neural Network on the Accuracy of an Automatic Weed Classification Scheme. *Smart Agric. Tech.* 2022, 3.
<https://doi.org/10.1016/j.atech.2022.100128>.
 56. Rahman, A., Lu, Y., Wang, H. Performance Evaluation of Deep Learning Object Detectors for Herbal Detection weeds for cotton. *Smart Agric. Tech.* 2022, 3.
<https://doi.org/10.1016/j.atech.2022.100126>.
 57. Diao, Z., Guo, P., Zhang, B., Yan, J., He, Z., Zhao, S., Zhao, C., Zhang, J. Navigation line extraction algorithm for corn spraying robot based on improved YOLOv8s network. *Comput. Electron. Agric.* 2023, 212.
<https://doi.org/10.1016/j.compag.2023.108049>.
 58. Mekhalfa, F., Yacef, F., Belhocine, M. Pre-trained Deep Learning Models for UAV-based Weed Recognition. *IEEE*. 2023. DOI:
10.23919/SPA59660.2023.10274449.
 59. Taha, M.F., Abdalla, A., ElMasry, G., Gouda, M., Zhou, L., Zhao, N., Liang, N., Niu, Z., Hassanein, A., Al-Rejaie, S., He, Y., Qiu, Z. Using Deep Convolutional Neural Network for Image-Based Diagnosis of Nutrient Deficiencies in Plants Grown in Aquaponics. *Chemosens.* 2022, 10, 45.
<https://doi.org/10.3390/chemosensors10020045>.
 60. Fischer, H., Romano, N., Jones, J., Howe, J., Renukdas, N., Sinha, A.K. Comparing water quality/bacterial composition and productivity of largemouth bass *Micropterus salmoides* juveniles in a recirculating aquaculture system versus aquaponics as well as plant growth/mineral composition with or without media. *Aquacult.* 2021, 538, 736554. <https://doi.org/10.1016/j.aquaculture.2021.736554>.
 61. Sánchez-DelaCruz, E., López, J.P.S., Ramos, M. F. Deep learning framework for leaf damage identification. *Concurrent Engineering: Research and Applications*. 2021. <https://doi.org/10.1177/1063293X21994953>.

62. Sathyavani, R., JagnMohan, K., Kalaavathi, B. Detection of plant leaf nutrients using convolutional neural network based Internet of Things data acquisition. *Int. J. Nonlinear Anal.* 2021, 2, 1175–1186. <https://doi.org/10.22075/IJNAA.2021.5194>.
63. Yang, T., Kim, H.J. Characterizing Nutrient Composition and Concentration in Tomato-, Basil-, and Lettuce-Based Aquaponic and Hydroponic Systems. *Water*, 2020, 12, 1259. <https://doi.org/10.3390/w12051259>.
64. Sabzi, S.; Pourdarbani, R.; Rhoban, M. H.; Garccía-Mateos, G.; Arribas, J. I. Estimation of nitrogen content in cucumber plant (*Cucumis sativus* L.) leaves using hyperspectral imaging data with neural network and partial least squares regressions. *Chemo. Intelligent Lab. Sys.* 2021, 217. <https://doi.org/10.1016/j.chemolab.2021.104404>.
65. Zhang, L., Niu, Y., Han, W., Liu, Z. Establishing Method of Crop Water Stress Index Empirical Model of Field Maize. *Nongye Jixie Xuebao/Trans. Chin. Soc. Agric. Mach.* 2018, 49, 233–239. <https://doi.org/10.6041/j.issn.1000-1298.2018.05.027>.
66. Zhang, Z., Bian, J., Han, W., Fu, Q., Chen, S., Cui, T. Diagnosis of Cotton Water Stress Using Unmanned Aerial Vehicle Thermal Infrared Remote Sensing after Removing Soil. *Nongye Jixie Xuebao/Trans. Chin. Soc. Agric. Mach.* 2018, 49, 250–260. <https://doi.org/10.6041/j.issn.1000-1298.2018.10.028>.
67. Li, Y., Yan, H., Cai, D., Gu, T., Sui, R., Chen, D. Evaluating the water application uniformity of center pivot irrigation systems in Northern China. *Int. Agric. Eng. J.* 2018. under review. [https://doi.org/10.1016/S2095-3119\(19\)62877-7](https://doi.org/10.1016/S2095-3119(19)62877-7).
68. Bhandari, S., Raheja, A., Do, D., Pham, F. Machine learning techniques for the assessment of citrus plant health using UAV-based digital images. *Autonomous Air and Ground Sens. Systems for Agric. Optim. and Phenotyping III.* 2018. <https://doi.org/10.1117/12.2303989>.
69. Sankararao, U.G., Priyanka, G., Rajalakshmi, P., Choudhary, S. CNN Based Water Stress Detection in Chickpea Using UAV Based Hyperspectral Imaging. *2021 IEEE International India Geosci. and Remote Sens. Symposium (InGARSS)*. 2021, 145-148. <https://doi.org/10.1109/InGARSS51564.2021.9791948>.
70. Sankararao, U.G., Rajalakshmi, P., Kaliamoorthy, S., and Choudhary, S. Water Stress Detection in Pearl Millet Canopy with Selected Wavebands using UAV Based Hyperspectral Imaging and Machine Learning. *IEEE Sensors Applications Symposium (SAS)*. 2022, 1-6. <https://doi.org/10.1109/SAS54819.2022.9881337>.
71. Tunca, E., Köksal, E.S., Taner, S.Ç. Calibrating UAV Thermal Sensors using Machine Learning Methods for Improved Accuracy in Agricultural Applications. *Infrared Physics & Techno.* 2023, 104804. <https://doi.org/10.1016/j.infrared.2023.104804>.
72. Bertalan, L., Holb, I., Pataki, A., Négyesi, G., Szabó, G., Szalóki, A.K., Szabó, S. UAV-based multispectral and thermal cameras to predict soil water content – A machine learning approach. *Comput. Electron. Agric.* 2022, 200, 107262. <https://doi.org/10.1016/j.compag.2022.107262>.
73. Niu, Y., Han, W., Zhang, H., Zhang, L., Chen, H. Estimating fractional vegetation cover of maize under water stress from UAV multispectral imagery using machine

- learning algorithms. *Comput. Electron. Agric.* 2021, 189, 106414. <https://doi.org/10.1016/j.compag.2021.106414>.
74. Das, S., Christopher, J., Apan, A., Choudhury, M. R., Chapman, S., Menzies, N. W., Dang, Y. P. Evaluation of water status of wheat genotypes to aid prediction of yield on sodic soils using UAV-thermal imaging and machine learning. *Agric. Forest Meteorol.* 2021, 307, 108477. <https://doi.org/10.1016/j.agrformet.2021.108477>.
 75. Wang, J., Lou, Y., Wang, W., Liu, S., Zhang, H., Hui, X., Wang, Y., Yan, H., Maes, W. H. A robust model for diagnosing water stress of winter wheat by combining UAV multispectral and thermal remote sensing. *Agric. Water Manag.* 2024, 291. <https://doi.org/10.1016/j.agwat.2023.108616>.
 76. Sumesh, K.C.; Ninsawat, S.; Som-ard, J. Integration of RGB-based vegetation index, crop surface model and object-based image analysis approach for sugarcane yield estimation using unmanned aerial vehicle. *Comput. Electron. Agric.* 2021, 180, 105903. <https://doi.org/10.1016/j.compag.2020.105903>.
 77. Sansechan, P.; Saengprachathanarug, K.; Posom, J.; Wongpichet, S.; Chea, C.; Wongphati, M. Use of vegetation indices in monitoring sugarcane white leaf diseasesymptoms in sugarcane field using multispectral UAV aerial imagery. *IOP Conf. Ser. Earth Environ. Sci.* 2019, 301, 12025. <https://doi.org/10.1088/1755-1315/301/1/012025>.
 78. Pan, Q., Gao, M., Wu, P., Yan, J., Li, S. A Deep-Learning-Based Approach for Wheat Yellow Rust Disease Recognition from Unmanned Aerial Vehicle Images. *Sensors.* 2021, 21, 6540. <https://doi.org/10.3390/s21196540>.
 79. Wu, B., Liang, A., HuafengZhang; Zhub, T., Zou, Z., Deming, Y., Tangb, W., Lia, J. Application of conventional UAV-based high-throughput object detection to the early diagnosis of pine wilt disease by deep learning. *Forest Eco. Manag.* 2021, 486, 15. <https://doi.org/10.1016/j.foreco.2021.118986>.
 80. Selvaraj, M.G., Vergara, A., Montenegro, F., Ruiz, H.A., Safari, N., Raymaekers, D., Ocimati, W., Ntamwira, J., Tits, L., Omondi, A.B., Blomme, G. Detection of banana plants and their major diseases through aerial images and machine learning methods: A case study in DR Congo and Republic of Benin. *ISPRS Journal of Photogram. Remote. Sens.* 2020, 169. <https://doi.org/10.1016/j.isprsjprs.2020.08.025>.
 81. 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. <https://doi.org/10.3390/rs14236137>.
 82. Yu, R., Luo, Y., Zhou, Q., Zhang, X., Wu, D., Ren, L. Early detection of pine wilt disease using deep learning algorithms and UAV-based multispectral imagery. *Forest Eco. Manag.* 2021, 497, 119493. <https://doi.org/10.1016/j.foreco.2021.119493>.
 83. Shi, Y., Han, L., Kleerekoper, A., Chang, S., Hu, T. Novel CropdocNet Model for Automated Potato Late Blight Disease De-tection from Unmanned Aerial Vehicle-Based Hyperspectral Imagery. *Remote Sens.* 2022, 14, 396. <https://doi.org/10.3390/rs14020396>.

84. Kerkech, M., Hafiane, A., Canals, R. VddNet: Vine Disease Detection Network Based on Multispectral Images and Depth Map. *Remote Sens.* 2020, 12, 3305. <https://doi.org/10.3390/rs12203305>.
85. Shankar, R.H., Veeraghavan, A.K., Sivaraman, K., Ramachandran, S.S. Application of UAV for Pest, Weeds and Disease Detection using Open Computer Vision. *International Conference on Smart Systems and Inventive Technology (ICSSIT)*, Ti-runelveli, India. 2018, 287-292, <https://doi.org/10.1109/ICSSIT.2018.8748404>.
86. Delgado, C., Benitez, H., Cruz, M., Selvaraj, M. Digital Disease Phenotyping. *IGARSS 20–9 - 2019 IEEE International Geo-science and Remote Sensing Symposium*, Yokohama, Japan. 2019, 5702-5705. <https://doi.org/10.1109/IGARSS.2019.8897854>.
87. Khan, F.S., Khan, S., Mohd, M.N.H., Waseem, A., Khan, M.N.A., Ali, S., Ahmed, R. Federated learning-based UAVs for the diagnosis of Plant Diseases. *International Conference on Engineering and Emerging Technologies (ICEET)*, Kuala Lumpur, Malaysia. 2022, 1-6. <https://doi.org/10.1109/ICEET56468.2022.10007133>.
88. Oide, A.H., Nagasaka, Y., Tanaka, K. Performance of machine learning algorithms for detecting pine wilt disease infection using visible color imagery by UAV remote sensing. *Remote Sens. Applications: Society and Environ.* 2022, 28, 100869. <https://doi.org/10.1016/j.rsase.2022.100869>.
89. Deng, J., Zhang, X., Yang, Z., Zhou, C., Wang, R., Zhang, K., Lv, X., Yang, L., Wang, Z., Li, P., Ma, Z. Pixel-level regression for UAV hyperspectral images: Deep learning-based quantitative inverse of wheat stripe rust disease index. *Comput. Electron. Agric.* 2023, 215. <https://doi.org/10.1016/j.compag.2023.108434>.
90. Casas, E., Arbelo, M., Moreno-Ruiz, J. A., Hernández-Leal, P. A., Reyes-Carlos, J. A. UAV-Based Disease Detection in Palm Groves of *Phoenix canariensis* Using Machine Learning and Multispectral Imagery. *Remote Sens.* 2023, 3584. <https://doi.org/10.3390/rs15143584>.
91. Amorim, W.P., Tetila, E.C., Pistori, H., Papa, J.P. Semi-supervised learning with convolutional neural networks for UAV images automatic recognition. *Comput. Electron. Agric.* 2019, 164, 104932. <https://doi.org/10.1016/j.compag.2019.104932>.
92. Brodbeck, C., Sikora, E., Delaney, D., Pate, G., Johnson, J., 2017. Using Unmanned Aircraft Systems for Early Detection of Soybean Diseases. *Precision Agric.* 2017, 8, 802–806. <https://doi.org/10.1017/S2040470017001315>.
93. da Silva, F.L., Sella, M.L.G., Franco, T.M., Costa, A.H.R., 2015. Evaluating classification and feature selection techniques for honeybee subspecies identification using wing images. *Comput. Electron. Agric.* 2015, 114, 68–77. <https://doi.org/10.1016/j.compag.2015.03.012>. ISSN 0168–1699.
94. Duarte, A., Borralho, N., Caetano, M. A Machine Learning Approach to Detect Dead Trees Caused by Longhorned Borer in Eucalyptus Stands Using UAV Imagery. 2021 *IEEE International Geoscience and Remote Sensing Symposium IGARSS*, Brus-sels, Belgium. 2021, 5818-5821. <https://doi.org/10.1109/IGARSS47720.2021.9554947>.

95. Tetila, E.C., Machado, B.B., Astolfi, G., Belete, N.A.S., Amorim, W.P., Roel, A.R., Pistori, H. Detection and classification of soybean pests using deep learning with UAV images. *Comput. Electron. Agric.* 2020, 179, 105836. <https://doi.org/10.1016/j.compag.2020.105836>.
96. Retallack, A., Finlayson, G., Ostendorf, B., Lewis, M. Using deep learning to detect an indicator arid shrub in ultra-high-resolution UAV imagery. *Eco. Indicators.* 2022, 145, 109698. <https://doi.org/10.1016/j.ecolind.2022.109698>.
97. Lia, X., Chen, J., He, Y., Yang, G., Li, Z., Tao, Y., Li, Y., Li, Y., Huang, L., Feng, X. High-through counting of Chinese cabbage trichomes based on deep learning and trinocular stereo microscope. *Comput. Electron. Agric.* 2023, 212. <https://doi.org/10.1016/j.compag.2023.108134>.
98. Lin, Q., Huang, H., Wang, J., Chen, L., Du, H., Zhou, G. Early detection of pine shoot beetle attack using vertical profile of plant traits through UAV-based hyperspectral, thermal, and lidar data fusion. *Intern. Journ. Applied Earth Observ. And Geoinfo.* 2023, 121. <https://doi.org/10.1016/j.jag.2023.103549>.
99. Clevers, J.G.P.W., Kooistra, L., van den Brande, M.M.M. Using Sentinel-2 Data for Retrieving LAI and Leaf and Canopy Chlorophyll Content of a Potato Crop. *Remote Sens.* 2017, 9, 405. <https://doi.org/10.3390/rs9050405>.
100. Towers, P.C., Strever, A., Poblete-Echeverría, C. Comparison of Vegetation Indices for Leaf Area Index Estimation in Vertical Shoot Positioned Vine Canopies with and without Grenbiule Hail-Protection Netting. *Remote Sens.* 2019, 11, 1073. <https://doi.org/10.3390/rs11091073>.
101. Vélez, S., Barajas, E., Rubio, J.A., Vacas, R., Poblete-Echeverría, C. Effect of Missing Vines on Total Leaf Area Determined by NDVI Calculated from Sentinel Satellite Data: Progressive Vine Removal Experiments. *Appl. Sci.* 2020, 10, 3612. <https://doi.org/10.3390/app10103612>.
102. Guo, H., Xiao, Y., Li, M., Hao, F., Zhang, X., Sun, H., Beurs, K., Fu, Y. H., He, Y. Identifying crop phenology using maize height constructed from multi-sources images. *Intern. Journ. Applied Earth Observ. And Geoinfo.* 2022, 115. <https://doi.org/10.1016/j.jag.2022.103121>.
103. Xu, B., Fan, J., Chao, J., Arsenijevic, N., Werle, R., Zhang, Z. Instance segmentation method for weed detection using UAV imagery in soybean fields. *Comput. Electron. Agric.* 2023, 211, 107994. <https://doi.org/10.1016/j.compag.2023.107994>.
104. Ilniyaz, O., Du, Q., Shen, H., He, W., Feng, L., Azadi, H., Kurban, A., Chen, X. Leaf area index estimation of pergola-trained vineyards in arid regions using classical and deep learning methods based on UAV-based RGB images. *Comput. Electron. Agric.* 2023, 207, 107723. <https://doi.org/10.1016/j.compag.2023.107723>.
105. Peng, M., Han, W., Li, C., Yao, X., Shao, G. Modeling the daytime net primary productivity of maize at the canopy scale based on UAV multispectral imagery and machine learning. *Journal of Cleaner Prod.* 2022, 367, 133041. <https://doi.org/10.1016/j.jclepro.2022.133041>.
106. Barbosa, B.D.S., Ferraz, G.A.E.S., Costa, L., Ampatzidis, Y., Vijayakumar, V., Santos, L.M.D. UAV-based coffee yield prediction utilizing feature selection and

- deep learning. *Smart Agric. Tech.* 2021, 1, 100010.
<https://doi.org/10.1016/j.atech.2021.100010>.
107. Alabi, T.R., Abebe, A.T., Chigeza, G., Fowobaje, K.R. Estimation of soybean grain yield from multispectral high-resolution UAV data with machine learning models in West Africa. *Remote Sens. Applications: Society and Environ.* 2022, 27, 100782. <https://doi.org/10.1016/j.rsase.2022.100782>.
 108. Teshome, F.T., Bayabil, H.K., Hoogenboom, G., Schaffer, B., Singh, A., Ampatzidis, Y. Unmanned aerial vehicle (UAV) imaging and machine learning applications for plant phenotyping. *Comput. Electron. Agric.* 2023, 212. <https://doi.org/10.1016/j.compag.2023.108064>.
 109. Ariza-Sentís, M., Valente, J., Kooistra, L., Kramer, H., Múcher, S. Estimation of spinach (*Spinacia oleracea*) seed yield with 2D UAV data and deep learning. *Smart Agric. Tech.* 2022, 3. <https://doi.org/10.1016/j.atech.2022.100129>.
 110. Niu, B., Feng, Q., Chen, B., Ou, C., Liu, Y., Yang, hisHSI-TransUNet: A Segmentation Model semantics based in transformer for crop mapping from UAV hyperspectral images. *Comput. Electron. Agric.* 2022, 201. <https://doi.org/10.1016/j.compag.2022.107297>.
 111. Pandey, A., Jain, K. An intelligent system for crop identification and classification from UAV images using conjugated dense convolutional neural network. *Comput. Electron. Agric.* 2021, 192. <https://doi.org/10.1016/j.compag.2021.106543>.
 112. Vong, N., Conway, L. S., Feng, A., Zhou, J., Kitchen, N.R., Sudduth, K.A. Estimating and Mapping Corn Emergence Uniformity using UAV imagery and deep learning. *Comput. Electron. Agric.* 2022, 198. <https://doi.org/10.1016/j.compag.2022.107008>.
 113. Chen, R., Zhang, C., Xu, B., Zhu, Y., Zhao, F., Han, S., Yang, G., Yang, H. Predicting Individual Apple Yield using sensing data remote from multiple UAV sources and ensemble learning. *Comput. Electron. Agric.* 2022, 201. <https://doi.org/10.1016/j.compag.2022.107275>.
 114. Wang H., Feng, J., Yin, H. Improved Method for Apple Fruit Target Detection Based on YOLOv5s. *Agric.* 2023, 2167. <https://doi.org/10.3390/agriculture13112167>.
 115. Xu, X., Wang, L., Liang, X., Zhou, L., Chen, Y., Feng, P., Yu, H., Ma, Y. Maize Seedling Leave Counting Based on Semi-Supervised Learning and UAV RGB Images. *Sustain.* 2023, 9583. <https://doi.org/10.3390/su15129583>.
 116. Feng, Y., Chen, W., Ma, Y., Zhang, Z., Gao, P., Lv, X. Cotton Seedling Detection and Counting Based on UAV Multispectral Images and Deep Learning Methods. *Remote Sens.* 2023, 2680. <https://doi.org/10.3390/rs15102680>.
 117. Tunca, E., Köksal, E. S., Öztürk, E., Akayc, H., Taner, S., Ç. Accurate leaf area index estimation in sorghum using high-resolution UAV data and machine learning models. *Phys. and Chem. Earth, Pt A/B/C.* 2024, 133. <https://doi.org/10.1016/j.pce.2023.103537>.
 118. Ma, J., Liu, B., Ji, L., Zhu, Z., Wu, Y., Jiao, W. Field-scale yield prediction of winter wheat under different irrigation regimes based on dynamic fusion of multimodal UAV imagery. *Intern. Journ. Applied Earth Observ. and Geoinfo.* 2023, 118. <https://doi.org/10.1016/j.jag.2023.103292>.

119. Liu, S., Jin, X., Bai, Y., Wu, W., Cui, N., Cheng, M., Liu, Y., Meng, L., Jia, X., Nie, C., Yin, D. UAV multispectral images for accurate estimation of the maize LAI considering the effect of soil background. *Intern. Journ. Applied Earth Observ. and Geoinfo.* 2023, 121. <https://doi.org/10.1016/j.jag.2023.103383>.
120. Demir, S., Dedeoğlu, M., Başayiğit, L. Yield prediction models of organic oil rose farming with agricultural unmanned aerial vehicles (UAVs) images and machine learning algorithms. *Remote Sens.: Socie. and Environ.* 2023, 101131. <https://doi.org/10.1016/j.rsase.2023.101131>.
121. Jamali, M., Bakhshandeh, E., Yeganeh, B., Özdoğan, M. Development of machine learning models for estimating wheat bio-physical variables using satellite-based vegetation indices. *Adv. in Space Res.* 2024. <https://doi.org/10.1016/j.asr.2023.10.004>.
122. Qu, H., Zheng, C., Ji, H., Barai, K., Zhang, Y. A fast and efficient approach to estimate wild blueberry yield using machine learning with drone photography: Flight altitude, sampling method and model effects. *Comput. Electron. Agric.* 2024, 216. <https://doi.org/10.1016/j.compag.2023.108543>.
123. Sivakumar, A.N.V., Li, J., Scott, S., Psota, E., Jhala, A.J., Luck, J.D., Shi, Y. Comparison of object detection and patch-based classification deep learning models on mid-to late-season weed detection in UAV imagery. *Remote Sens.* 2020, 12. <https://doi.org/10.3390/rs12101591>.

CAPÍTULO II – APRENDIZADO DE MÁQUINA PROFUNDO PARA DETECÇÃO E SEGMENTAÇÃO DE PLANTAS DANINHAS EM CULTURAS AGRÍCOLAS USANDO IMAGENS CAPTURADAS POR UAV (UNMANNED AERIAL VEHICLE)

(Normas de acordo com a revista Remote Sensing)

RESUMO

A Inteligência Artificial (IA) tem mudado a forma como processos são desenvolvidos e decisões são tomadas na área agrícola, substituindo processos manuais e repetitivos por processos automatizados, mais eficientes. Este estudo apresenta a aplicação de técnicas de aprendizado de máquina profundo para a detecção e a segmentação de plantas daninhas em culturas agrícolas, pela aplicação de modelos, com arquiteturas diferentes entre si, na análise de imagens capturadas por UAV. O estudo contribui para o campo da visão computacional ao comparar o desempenho dos modelos YOLO, incluídas quatro variantes do modelo YOLOv8 (YOLOv8n, YOLOv8s, YOLOv8m e YOLOv8l), Mask R-CNN (com *framework* Detectron2) e U-Net, tornando público o conjunto de dados com imagens aéreas de culturas de soja e feijão. Os modelos foram treinados utilizando um conjunto de dados composto por 3.021 imagens, divididas aleatoriamente em conjuntos de teste, validação e treinamento, que foram anotadas, redimensionadas e aumentadas pela interface do aplicativo Roboflow. Foram utilizadas métricas de avaliação, que incluem eficiência de treinamento (mAP50 e mAP50-90), precisão, acurácia e recall na avaliação e comparação dos modelos. A variante YOLOv8s obteve maior desempenho, com mAP50 de 97%, precisão de 99,7% e recall de 99%, em comparação com os demais modelos. Os dados deste estudo demonstraram que modelos de aprendizagem profunda, quando treinados com um conjunto bem rotulado e aumentado, podem gerar resultados eficientes para detecção automática de plantas daninhas. Além disso, este estudo demonstrou o grande potencial do uso de algoritmos avançados de segmentação de objetos na detecção de plantas daninhas nas culturas da soja e feijão.

Palavras-chave: Agricultura de precisão, algoritmos de segmentação, culturas agrícolas, Detectron2, feijão, Mask R-CNN, soja, U-Net, YOLO.

CHAPTER II – DEEP LEARNING FOR WEEDS DETECTION AND SEGMENTATION IN AGRICULTURAL CROPS USING IMAGES CAPTURED BY UAV

(Standards according to Remote Sensing magazine)

ABSTRACT

Artificial Intelligence (AI) has changed how processes are developed, and decisions are made in the agricultural area replacing manual and repetitive processes with automated and more efficient ones. This study presents the application of deep learning techniques to detect and segment weeds in agricultural crops by applying models with different architectures in the analysis of images captured by an Unmanned Aerial Vehicle (UAV). This study contributes to the computer vision field by comparing the performance of the You Only Look Once (YOLOv8n, YOLOv8s, YOLOv8m, and YOLOv8l), Mask R-CNN (with framework Detectron2), and U-Net models, making public the dataset with aerial images of soybeans and beans. The models were trained using a dataset consisting of 3,021 images, randomly divided into test, validation, and training sets, which were annotated, resized, and increased by the Roboflow application interface. Evaluation metrics were used, which included training efficiency (mAP50 and mAP50-90), precision, accuracy, and recall in the model's evaluation and comparison. The YOLOv8s variant achieved higher performance with mAP50 of 97%, precision of 99.7%, and recall of 99% when compared to the other models. The data from this manuscript show that deep learning models can generate efficient results for automatic weed detection when trained with a well-labeled and large set. Furthermore, this study demonstrated the great potential of using advanced object segmentation algorithms in detecting weeds in soybean and bean crops.

Keywords: Agricultural Crops. Bean. Detectron2. Mask R-CNN. Precision Agriculture. Segmentation Algorithms. Soybean. U-Net. You Only Look Once (YOLO).

1. INTRODUÇÃO

Recentemente, diversos estudos surgiram com a proposta de detectar e classificar plantas, por meio de tecnologias com aprendizado de máquina profundo [1-6]. Os modelos de *Machine Learning* (ML) e *Deep Learning* (DL) são usados para tornar automáticos os procedimentos agrícolas e auxiliam para que máquinas possam reconhecer imagens automaticamente, com precisão e eficiência [7-9].

Machine Learning é uma subárea da Inteligência Artificial que se baseia em algoritmos de autoaprendizado, ou seja, algoritmos que permitem que o sistema aprenda padrões por meio da experiência, tornando-se inteligente ao longo do tempo, sem intervenção humana. Por outro lado, *Deep Learning* refere-se a algoritmos que aprendem padrões através da experiência, mas incluem uma grande quantidade de informações fornecidas na entrada. O termo "profundo" refere-se às múltiplas camadas entre a entrada e a saída de uma rede neural [10], e o número de épocas de treinamento corresponde à quantidade de vezes que o modelo de aprendizagem profunda percorre todos os dados durante a fase de treinamento [11].

As aplicações de IA na agricultura envolvem, entre outras vertentes, o uso de imagens advindas de satélites no monitoramento de estresse das culturas agrícolas, tais como déficit hídrico, doenças em plantas, pragas agrícolas e plantas daninhas [12].

Os estudos com aplicações que utilizam satélites/sensores e aviões para a técnica de manejo específico de plantas daninhas se mostraram bem sucedidos ao monitorar e detectar plantas específicas quando, em uma determinada cultura, elas estão em suas fases iniciais de desenvolvimento [13]. No entanto, na fase de desenvolvimento das culturas de feijão e soja, as plantas invasoras podem misturar-se com a cultura e tornar o uso de satélites/sensores para monitorar e detectar ervas daninhas mais desafiador [14]. Neste contexto, as imagens capturadas por veículos aéreos não tripulados (*Unmanned Aerial Vehicle* – UAV) são mais eficientes para identificar plantas específicas em meio às culturas agrícolas [15-17].

As metodologias de detecção e classificação de plantas daninhas com o uso de imagens aéreas contribuem para a execução do seu manejo [18]. O UAV pode ser operado em altitudes mais baixas e as imagens por ele capturadas oferecem maior resolução, quando comparadas às imagens por satélite ou aeronaves convencionais [19].

As plantas daninhas podem ser eliminadas usando três técnicas convencionais de controle - mecânica, química e cultural [20], envolvendo um conjunto de

procedimentos para o monitoramento de plantas específicas [21]. Ao final, a abordagem de manejo específico de plantas daninhas oferece um mapa com informações geográficas a respeito das plantas apresentadas no local especificado, com o objetivo de auxiliar na aplicação de produtos químicos para o seu devido controle [22,23]. Os modelos de aprendizado de máquina profunda podem auxiliar na localização de plantas encontradas no local de cultivo e colaborar para seu controle [24,25].

As plantas daninhas nascem e crescem espontaneamente em áreas de cultivo e interferem no desenvolvimento dos cultivos comerciais presentes no local, concorrendo com recursos naturais, como, por exemplo, água, nutrientes e luz [26,27]. Por esse motivo, as plantas são vistas como problema por apresentarem alta resistência às adversidades, adaptando-se a ambientes que apresentam estresse hídrico, altos índices de salinidade e acidez no solo, além de ambientes com alta temperatura e umidade desfavoráveis ao cultivo [28].

Como forma de incrementar a eficiência na identificação e combate às plantas invasoras em cultivos comerciais, o uso de modelos computacionais para análise de imagens se torna uma ferramenta de grande aplicabilidade na atividade agrícola, aplicando-se modelos como YOLO (*You Only Look Once*), Mask R-CNN (com *framework* Detectron2), e U-Net [29,30].

O modelo YOLO considera o recurso multiescala dos objetos, o qual utiliza três camadas de detecção ao dispor de objetos de diferentes escalas, sendo capaz de classificar e identificar objetos examinando uma única vez o conjunto de dados de imagem ou vídeo [30,31]. Entre os modelos de segmentação de instância, incluem-se variações e versões do modelo YOLO, com destaque para o YOLOv8. O modelo YOLOv8, em particular, contém duas partes principais em sua arquitetura, o *backbone* e o *head* (cabeçalho), e pode ser usado para detectar precocemente plantas novas, apresentando resultados acima de 90%, em comparação com os modelos YOLOv5 e Faster R-CNN [31].

Detectron2 é um *framework* que contém as implementações de vários algoritmos de última geração usados para detecção e segmentação de objetos, tendo sido projetado para tarefas de detecção e segmentação de instâncias [32]. O *backbone* do *framework* Detectron2 fornece arquiteturas pré-treinadas em grandes conjuntos de dados de imagens, como, por exemplo, ResNet, ResNetXt e MobileNet, para extrair recursos de imagem [33]. A rede *backbone* é composta por camadas organizadas hierarquicamente com o objetivo de reduzir a dimensionalidade dos mapas de recursos,

de forma gradual, enquanto aumentam o número de canais [34,35].

U-Net é um modelo de segmentação de imagens na área médica, baseado em uma rede totalmente convolucional (FCN, sigla em inglês), proposto por Olaf Ronneberger, e contém somente camadas totalmente convolucionais [36]. Esta rede simétrica é dividida em duas unidades principais: codificador e decodificador [36,37]. O codificador tem como objetivo capturar o contexto da imagem, consistindo em camadas convolucionais e de *pooling* [37]. Nesta seção, que contém duas camadas de convolução 3x3 e uma unidade linear retificada (ReLU), as propriedades espaciais são extraídas da imagem e usadas para gerar um mapa de segmentação não decodificado [37,38]. A segunda parte é o decodificador usado para permitir a localização precisa do objeto na imagem usando convoluções transpostas [36,38]. O codificador é composto por camadas sucessivas, em que os operadores de *pooling* são trocados por operador de *upsampling*, aumentando a resolução da saída. Para uma localização precisa, no decodificador, os recursos de alta resolução do codificador são concatenados com a saída de amostragem aumentada [36,38].

Os modelos de aprendizagem de máquina, para que sejam devidamente avaliados quanto a seu desempenho, precisam ser treinados e, em seguida baseados em análises de avaliação [39-41]. As notas de avaliação são importantes indicadores de desempenho e resumem o estado final do modelo, incluindo expressões matemáticas para cálculos como resultados, acurácia, precisão média e recall. [42,43].

Dada a grande aplicabilidade dos modelos de aprendizagem de máquina para aplicações de imagens aéreas de área cultivadas, objetivou-se neste estudo proceder a uma avaliação detalhada do desempenho de algoritmos avançados de segmentação de objetos Mask R-CNN (com *framework* Detectron2), U-Net, YOLOv5s, YOLOv7 e YOLOv8 com suas variantes YOLOv8n, YOLOv8s, YOLOv8m e YOLOv8l para detectar plantas invasoras nas culturas da soja e feijão por meio de imagens RGB capturadas por UAV.

2. MATERIAL E MÉTODOS

2.1. Experimento de campo

O experimento foi instalado no Instituto Federal Goiano – Campus Ceres, município de Ceres, estado de Goiás, região centro-oeste do Brasil. A área agrícola

experimental foi plantada com feijão comum (*Phaseolus vulgaris*) e soja (*Glycine max*) e está localizada especificamente nas seguintes coordenadas geográficas 15°21'16" S e 49°36'23"W, com uma altitude de 570 m (Figura 1).




Figura 1. Área de estudo localizada na região Centro-Oeste do Brasil (a), no estado de Goiás (b), no Instituto Federal Goiano - Campus Ceres, no município de Ceres (c). A área experimental foi plantada com feijão comum (*Phaseolus vulgaris*) e soja (*Glycine max*) (d), e plano de voo utilizado para cobrir toda a área experimental (e).

2.2. Etapas de Processamento e Segmentação de Plantas Daninhas

O fluxo de trabalho para detecção e segmentação de ervas daninhas é composto por quatro etapas principais, incluindo preparação de dados, treinamento, avaliação de desempenho do modelo e implantação (Figura 2). Durante a preparação dos dados, a ferramenta Roboflow [44] foi utilizada para rotular e redimensionar cada imagem do conjunto. Essas imagens foram posteriormente aumentadas e treinadas nos modelos de segmentação U-Net, YOLO e Mask R-CNN (*framework* Detectron2) durante o treinamento. Os modelos treinados foram então avaliados quanto ao desempenho do modelo usando seis métricas de avaliação diferentes e, por último, os modelos foram implantados em campo.

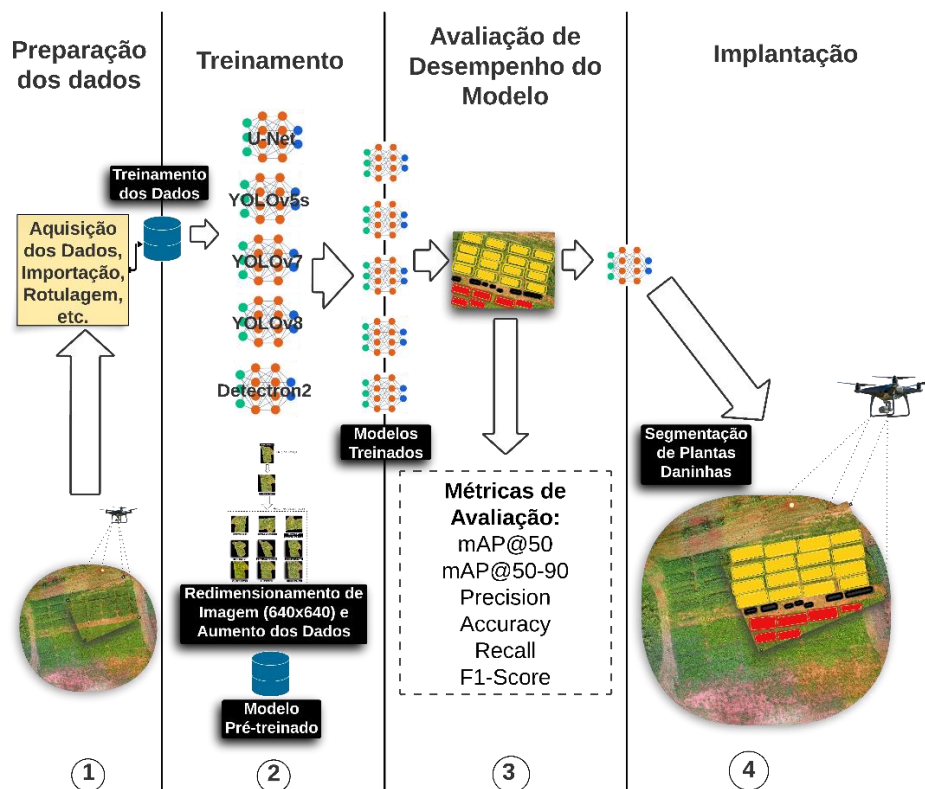


Figura 2. Fluxo do processo de treinamento para segmentação de plantas daninhas. Etapas: (1) imagens rotuladas e redimensionadas usando a ferramenta Roboflow; (2) imagens aumentadas e treinadas nos modelos de segmentação U-Net, YOLO e Mask R-CNN (*framework* Detectron2); (3) métricas de avaliação usadas nos modelos treinados; (4) teste de campo do modelo com maior eficiência.

2.3. Aquisição das imagens RGB

A aquisição das imagens foi realizada com um UAV Phantom® 3 Standard (DJI, Shen-zhen, China) com câmera digital RGB Full HD com resolução de 1980 x 1080 pixels. Foi criado um plano de voo e os parâmetros e condições de voo (data e hora da coleta e altura de voo) foram registrados em uma planilha. A captura de imagens por VANT nas culturas de soja e feijão foi realizada ao longo de três meses, de dezembro de 2022 a fevereiro de 2023, compondo um conjunto de dados de 793 imagens. Os voos foram realizados uma vez por dia em condições climáticas favoráveis (dias de sol). O plano de voo foi criado utilizando o software Pix4D®capture. As sobreposições frontais e laterais para captura de imagens foram de 80% e 72%, respectivamente, a altura de voo foi de 20 metros resultando em uma distância de amostragem do solo (GSD – *Ground Sample Distance*) de 0,88 cm/px. Isso significa

que um pixel na imagem representa linearmente 0,88 centímetros no solo.

2.3.1. Anotação do Conjunto de Dados

A ferramenta Roboflow [44] foi usada para rotular e classificar os objetos no conjunto de dados. O conjunto de dados contém três classes denominadas “feijão”, “soja” e “erva daninha”, divididas aleatoriamente em conjuntos de treinamento, validação e teste, com 75%, 12% e 13% de todas as imagens, respectivamente. Para anotar o conjunto de dados, as imagens foram rotuladas utilizando a ferramenta Roboflow e o processo foi realizado com a rotulagem automática dos polígonos dos objetos que a própria ferramenta disponibiliza em seu sistema (Figura 3). A ferramenta aplicou uma etiqueta inicial e depois o sistema sugeriu um contorno preciso do objeto marcado. As posições reais resultantes dos objetos na imagem foram armazenadas em formato JSON e convertidas para o formato de dados desejado para treinamento.




Figura 3. Isolamento de objetos do conjunto de imagens.

Após o processo de rotulagem de cada imagem do conjunto, foi possível proceder à contagem do número de instâncias (objetos), subdivididas por classes (“bean”, “soybean” e “weed”). As características do conjunto de dados gerado (soja e

feijoeiro) são mostradas na Tabela 1.

Tabela 1. Conjunto de dados Bean Soy Dataset

Características	Conjunto de dados (Soja e Feijão)
Número de fotografias	793
Número de instâncias	16.113
Média de plantas daninhas por fotografia	8,92
Número total de ervas daninhas	7.074
Número de pés de feijão	4.532
Número de plantas de soja	4.507

2.3.2. Redimensionamento das imagens

As imagens foram redimensionadas para 640 x 640 pixels e 512 x 512 pixels (Figura 4) para os modelos YOLOv8, YOLOv7, YOLOv5s e Mask R-CNN (com Detectron2) e U-Net, respectivamente. Ao redimensionar as imagens do conjunto de dados, foi possível manter a proporção de largura e altura que os modelos pré-treinados solicitavam para entrada de dados. Como o modelo U-Net não possui camadas totalmente conectadas, ele pode aceitar imagens de tamanho arbitrário. No entanto, é importante redimensioná-los para reduzir o tempo de cálculo [36].




Figura 4. Redimensionamento das imagens.

2.3.3. Aplicação da técnica *Data Augmentation*

O aumento de dados foi realizado com o objetivo de aumentar o número de imagens no conjunto de dados. As 793 imagens originais coletadas com o VANT foram multiplicadas pelo uso de operações de aumento como rotação, saturação e ruído (Figura 5). As imagens foram invertidas, giradas em um ângulo de 90° no sentido horário e anti-horário, em ângulos de 10° e 15° , a saturação foi alterada em 10%, um desfoque de 2,5% foi aplicado e um ruído de 1,01%.

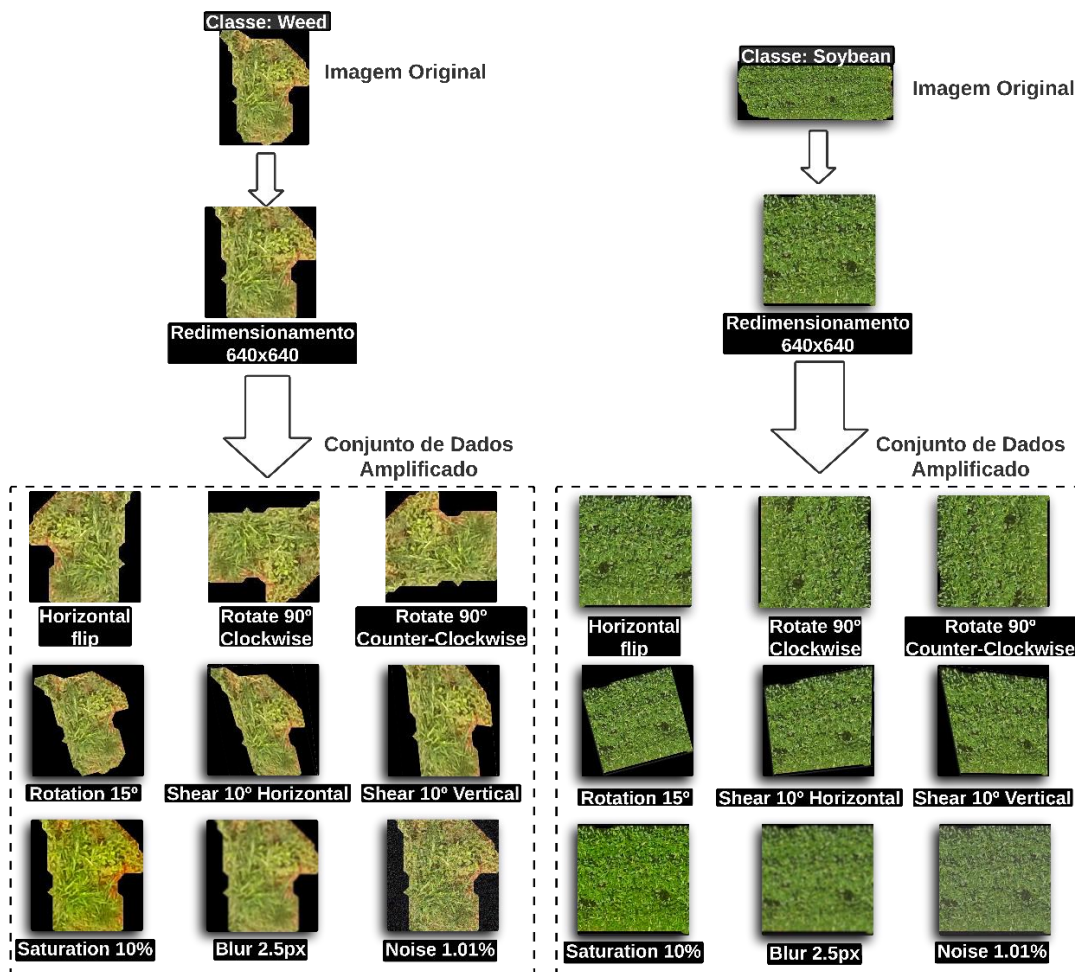


Figura 5. Aumento do conjunto de dados de imagens.

As imagens do conjunto de dados inicial foram expandidas para aumentar o tamanho do conjunto e evitar *overfitting*. O *overfitting* ocorre quando a rede neural ajusta demais os dados de treinamento, memorizando os dados em vez de aprender seu padrão. Quando isso acontece, a rede passa a cometer erros com mais frequência quando exposta a outras situações [36]. As técnicas de pré-processamento e aumento de dados foram utilizadas para garantir um número mais expressivo de dados de treinamento para os algoritmos de aprendizado de máquina profundo. Através das transformações feitas nas imagens originais, o número total de imagens no conjunto de dados aumenta de 793 para 3.021 imagens, divididas aleatoriamente em conjuntos de teste, validação e treinamento (Tabela 2).

Tabela 2. Conjunto de dados após divisão, redimensionamento e aumento das imagens

Número de imagens coletadas pelo UAV	Número de imagens após pré-processamento	Pixels	Redimensionamento	Número de classes	Número de imagens após aumento	Treinamento	Validação	Teste
793	1.886	4000 x 3000	640 x 640 / 512x512	3	3.021	2270	370	381

2.3.4. Geração das Máscaras do Conjunto de Dados

As máscaras do conjunto de dados foram geradas a partir das imagens aumentadas originais e utilizadas apenas para treinar o modelo U-Net. Para gerar as máscaras foi desenvolvido um algoritmo na linguagem de programação Python, utilizando Visual Studio Code®, versão 1.87.0. O algoritmo desenvolvido percorreu cada pixel das imagens do conjunto de dados, obteve o valor dos canais de cores RGB do pixel atual, depois verificou se cada pixel estava na faixa de tons verdes e posteriormente atribuiu o valor do pixel no imagem extraída com cor branca. As máscaras geradas para treinar o modelo U-Net foram salvas na pasta de saída com o mesmo nome e dimensão da imagem original. Por fim, as máscaras foram divididas em três partes para treinamento, validação e teste no modelo U-Net. O resultado da geração da máscara é mostrado na Figura 6.




Figura 6. Imagens RGB (512x512) rotuladas para criação de máscaras a partir de imagens RGB anotadas e redimensionadas (a) e máscara final criada (b). A cor branca representa as ervas daninhas e a cor preta representa a ausência de ervas daninhas na imagem.

2.4. Modelos

2.4.1. You Only Look Once (YOLO)

A versão mais recente do modelo de aprendizado de máquina YOLO (*You Only Look Once*) (Ultralytics), YOLOv8 [33], foi utilizada para detecção e segmentação de plantas daninhas neste estudo. A Figura 7 apresenta a estrutura de rede do modelo YOLOv8, descrevendo os parâmetros usados para representar o tamanho total do mapa das características que compõem este modelo.

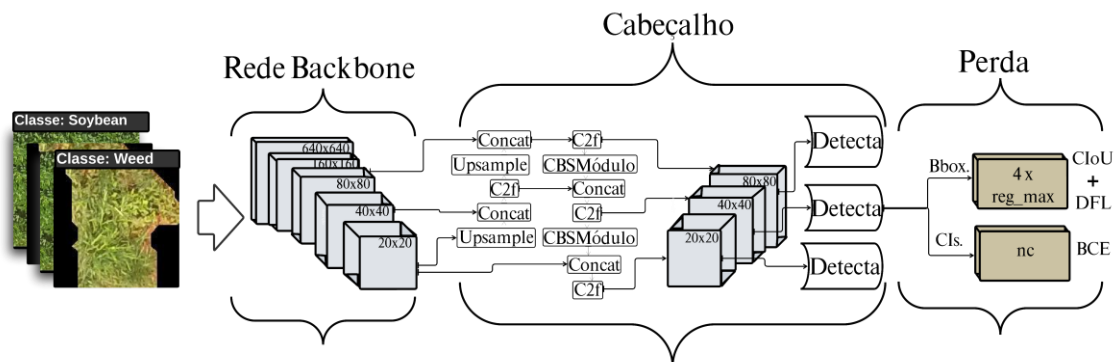


Figura 7. Arquitetura YOLOv8.

Antes de cada treinamento do conjunto de dados no modelo YOLOv8, uma versão do conjunto de dados foi gerada utilizando a ferramenta Roboflow. O conjunto de dados hospedado foi carregado diretamente no notebook Google Colab para facilitar o treinamento. O ajuste dos hiperparâmetros do modelo YOLOv8 foi feito antes do treinamento. As imagens foram utilizadas como objetos de entrada para o modelo, que então percorreu o conjunto de imagens uma vez para segmentar as ervas daninhas nas imagens.

O modelo YOLOv8 usou a rede backbone modificada, CSPDarkNet53 [34]. Os recursos de entrada são amostrados cinco vezes para obter cinco recursos de escala diferentes (Figura 7). As cinco variantes deste modelo, que variavam de modelos em escala nanométrica (YOLOv8n) a modelos extragrandes (YOLOv8x) [34], foram treinadas e comparadas entre si. Ao final de todo o treinamento, o modelo foi validado e salvo.

2.4.2. Detectron2

A Figura 8 mostra a arquitetura do modelo Mask R-CNN, no *framework* Detectron2. A rede *backbone* é responsável pela extração dos recursos da imagem na entrada. Esta rede consiste em camadas organizadas hierarquicamente, capazes de reduzir gradualmente as dimensões espaciais dos mapas de recursos ao aumentar a quantidade de canais no modelo [33,52].

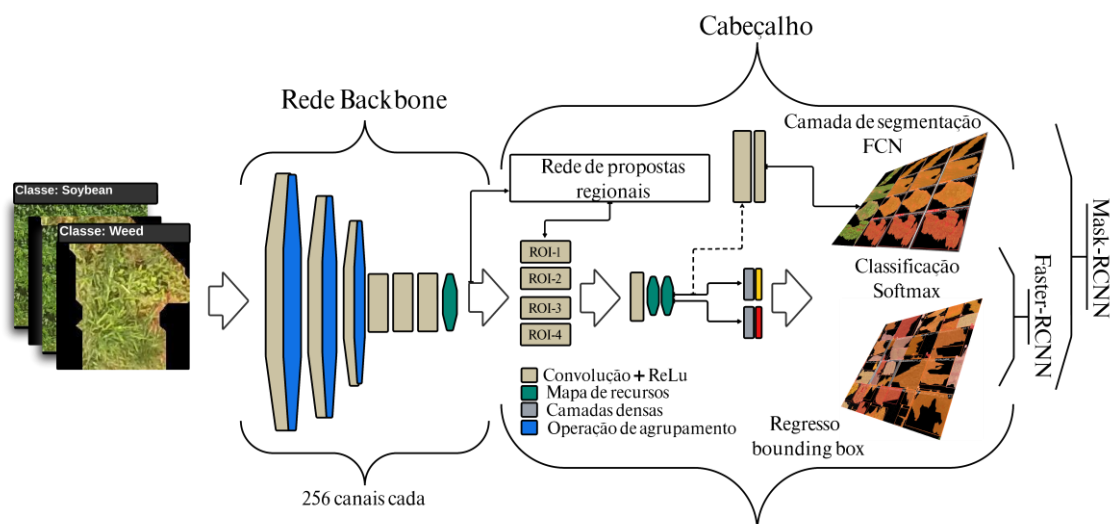


Figura 8. Arquitetura do *framework* Detectron2.

Antes de utilizar o conjunto de dados para treinar o modelo Mask R-CNN no *framework* Detectron2 o ambiente Python foi configurado e as versões das bibliotecas necessárias ao processo foram instaladas. Em seguida, foi selecionado o conjunto de dados de segmentação de instâncias, no formato “COCO Segmentation”, utilizando a ferramenta Roboflow. O ajuste dos hiperparâmetros do modelo Mask R-CNN no *framework* Detectron2 foi feito antes do treinamento e as imagens foram utilizadas como objetos de entrada para o modelo. Os três modelos selecionados para este estudo com base na estrutura mostrada são R101-FPN, X101-FPN e R101-DC5. Ao final de todo o treinamento, o modelo treinado gerado foi validado e salvo.

2.4.3. U-Net

O modelo U-Net, proposto por Ronneberger, Fisher e Brox [36], foi treinado com o conjunto de dados de soja e feijão. Na Figura 9 é possível ver uma representação da arquitetura do modelo U-Net. Os hiperparâmetros do modelo U-Net foram ajustados antes do treinamento e as imagens foram utilizadas como objetos de entrada para o modelo. O modelo U-Net, baseado em FCN, capturou o contexto da imagem com propriedades espaciais sendo extraídas da imagem e utilizadas para gerar um mapa de segmentação no decodificador. O decodificador foi usado para permitir a localização precisa do objeto na imagem usando convoluções transpostas [31,42]. O codificador,

composto por camadas sucessivas, aumentou a resolução de saída [41]. Ao final de todo o treinamento, o modelo treinado gerado foi validado e salvo.




Figura 9. Arquitetura U-Net.

2.5. Parâmetros dos modelos e configurações

O treinamento e os testes de todos os modelos deste estudo foram realizados no Google Colaboratory, em um processador gráfico NVIDIA, Tesla T4 do Google Compute Engine em Python 3. Os parâmetros de ambiente de software e hardware usados estão descritos na Tabela 3. Os modelos YOLO foram treinados com pesos do conjunto de dados MS COCO, como mostrado na Tabela 4.

Tabela 3. Parâmetros de ambiente de software e hardware

Nome	Parâmetros/versão
Sistema operacional	Windows 10
CPU ¹	AMD Ryzen 7 6800H
GPU ²	NVIDIA Tesla T4
RAM ³	16 GB (8GB x 2)
Python	V3.12
Pytorch	V2.1
OpenCV ⁴	V4.9.0
CUDA ⁵	V12.2

¹ Unidade central de processamento (CPU), ² unidade de processamento gráfico (GPU), ³ memória de acesso aleatório (RAM), ⁴ biblioteca de visão computacional de código aberto (OpenCV), ⁵ arquitetura de dispositivos unificados de computação (CUDA).

Tabela 4. Parâmetros de treinamento de modelos de segmentação de instâncias, YOLOv8, YOLOv7 e YOLOv5s.

Parâmetros	Valores
Otimizador	SGD ⁶
Taxa de aprendizado	SGD = 1×10^{-2}
Otimizador momentum	0,937
Decadência do peso base	0,0005
Tamanho do lote por imagem	16
Formato da anotação	Pytorch TXT
Pretrained	MS COCO Dataset ⁷
Formato da imagem	PNG

⁶ Descida gradiente estocástica (SGD), ⁷ Conjunto de dados Microsoft coco (MS COCO Dataset).

As Tabelas 5 e 6 apresentam os diferentes parâmetros usados para o treinamento dos modelos Mask R-CNN, no *framework* Detectron2, e U-Net. O modelo de segmentação de instância Mask R-CNN com Detectron2 usou três backbones diferentes para comparação, incluindo R101-DC5, R101-FPN e X101-FPN e o modelo U-Net usou o ResNet50.

Tabela 5. Hiperparâmetros de treinamento de modelo de segmentação de instância Mask R-CNN com detectron2

Parâmetros	Valores
Arquiteturas	mask_rcnn_R_101_DC5_3x mask_rcnn_R_101_FPN_3x mask_rcnn_X_101_32x8d_FPN_3x
Máxima iteração	20.000
Período de avaliação	200
Taxa de aprendizado	0,001
Número de classes (Class+1)	4
Tamanho do lote por imagem	64
Formato da anotação	COCO

Formato da imagem	PNG
-------------------	-----

Tabela 6. Hiperparâmetros de treinamento de modelo de segmentação de instâncias U-Net

Parâmetros	Valores
Arquitetura	ResNet50
Otimizador	SGD
Taxa de aprendizado	SGD = 1×10^{-2}
Tamanho do lote por imagem	4
Número de classes	3
Formato da imagem	TIFF

2.6. Métricas de Validação

2.6.1. Cálculos de desempenho do modelo

Para validar a performance dos algoritmos de segmentação de instância e suas variações, foram utilizadas métricas de avaliação *mean Average Precision* (mAP), determinadas pela *Precision* (P), Equação 1 e o *Recall* (R), Equação 2, a fim de medir a acurácia do modelo, bem como reconhecer as categorias dos objetos contidos nele e suas posições conhecidas [32, 33].

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

$$\text{Recall} = \frac{VP}{VP + FN} \quad (2)$$

Em que o verdadeiro positivo (VP) representa a detecção correta de uma planta daninha com a caixa delimitadora. O falso negativo (FN) representa uma planta daninha que não foi detectada na imagem, e o falso positivo (FP) indica que a localização de uma caixa delimitadora foi detectada, porém sem ter uma planta daninha nela.

Na detecção de planta daninha, mediu-se a precisão das predições, indicando o

número de objetos detectados corretamente, dividido por todos os objetos detectados. Para o cálculo do *recall*, o número de objetos detectados corretamente foi dividido por todos os objetos do *ground truth*.

Para o cálculo da acurácia, métrica de desempenho usada para calcular a proporção entre as observações previstas corretamente e todas as observações do conjunto de dados, utilizou-se a Equação (3), que descreve a expressão matemática para o devido cálculo [30,32].

$$\text{Accuracy} = (\text{VP} + \text{VN}) / (\text{VP} + \text{VN} + \text{FP} + \text{FN}) \quad (3)$$

Em que os verdadeiros negativos (VN) representam a detecção incorreta de uma planta daninha, com sua caixa delimitadora.

A Equação (4) descreve a pontuação F-beta, usada na média harmônica ponderada de precisão e *recall*, cujo valor varia entre 0 e 1, sendo 1 o melhor valor e 0 o pior valor. O peso beta é atribuído conforme o cenário em que se encontra, isto é, para beta igual a 1 (valor padrão), é usada a Equação (4) [31,33].

$$F1 = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

A precisão média (AP) é usada para calcular a área sob a curva de precisão e *recall*, conforme a Equação (5).

$$AP = \sum_{k=0}^{n-1} ((\text{Recall}_{(n)} - \text{Recall}_{(n+1)}) \times \text{Precisions}_{(k)}) \quad (5)$$

$$\text{IoU} = (\text{Object} \cap \text{Detected box}) / (\text{Object} \cup \text{Detected box}) \quad (6)$$

Para o cálculo da precisão média (mAP), usado para calcular a média aritmética de cada lista de resultados retornada pelo modelo, a Equação (7) descreve o cálculo de mAP [33,39].

$$mAP = \frac{(\sum_{i=1}^n AP_i)}{n} \quad (7)$$

Dois limites diferentes foram utilizados para detecção de objetos para a média

AP, com valores de confiança variando entre 0 e 0,50 (mAP50) e entre 0,50 e 0,95 (mAP50:90). Para avaliação de desempenho, foram utilizadas ainda as métricas AP50 e AP75, com precisão média de 50 e 75% e e API (*large*) para objetos com maior área.

3. RESULTADOS

Os quatro modelos de segmentação de instância treinados no conjunto de dados personalizado incluíram YOLOv8, e suas variantes YOLOv7, YOLOv5, U-Net, Mask R-CNN (*framework* Detectron2) em três diferentes backbones deste último modelo, baseada na arquitetura de rede de recursos em pirâmide (R101-FPN, R101-DC5 e X101-FPN), usando o *framework* Detectron2. Foi utilizado um conjunto de dados aumentado de 3.021 imagens para o treinamento dos modelos. As métricas de validação foram usadas e, em seguida, feitas comparações de desempenho de diferentes backbones e variantes, em diferentes épocas.

3.1. Desempenho de diferentes backbones e variantes de modelos

A Tabela 7 apresenta o desempenho de cinco variantes do modelo YOLOv8 na detecção e segmentação de três classes (weed, bean e soybean), assim como as métricas de precisão, *recall* e pontuações mAP para dois limites diferentes (50 e 50-95). Cada variante do modelo indica o tamanho de sua arquitetura, sendo *nano* (YOLOv8n), *small* (YOLOv8s), *medium* (YOLOv8m) e *large* (YOLOv8l). A variante YOLOv8s apresentou o maior valor de precisão em 99,7%, entre as demais variantes. Ademais, as variantes YOLOv8l e YOLOv8m, do modelo YOLO, apresentaram valores de mAP de 97% para os dois limites diferentes previstos pelo modelo (50 e 50-95), obtendo precisão média de treinamento superior às outras variantes do modelo quando treinadas em 500 épocas.

Tabela 7. Pontuações de precisão, recall e mAP das variantes YOLOv8, treinadas por 500 épocas. Os maiores resultados estão em negrito.

Modelo	Precisão	Recall	mAP _{0.5} (M) ⁸	mAP ⁹ 0.5:0.95 (M)
YOLOv8n	0,991	0,989	0,959	0,956
YOLOv8s	0,997	0,990	0,970	0,968

YOLOv8m	0,994	0,991	0,974	0,972
YOLOv8l	0,993	0,990	0,974	0,972

⁸ Mask (M), ⁹ mean average precision (mAP).

As Tabelas 8 e 9 mostram os valores de precisão, acurácia, pontuação F1 e mAP de diferentes versões do modelo YOLO. Todas as variantes do modelo YOLO apresentaram precisão acima de 90%, porém a variante que se destaca em valor de precisão entre as demais versões do modelo é o YOLOv8s, com valor acima de 99%.

Tabela 8. Pontuações de precisão, recall e mAP dos modelos YOLOv8s, YOLOv7 e YOLOv5s em 500 épocas. Os maiores resultados estão em negrito.

Modelo	Backbone	Precisão	Recall	mAP _{0.5} (M)	mAP _{0.5} (B) ¹⁰	mAP _{0.5:0.95} (M)	mAP _{0.5:0.95} (B)
YOLOv8s	CSPDarkNet53	0,997	0,990	0,970	0,970	0,968	0,965
YOLOv7	CSPDarkNet53	0,983	0,981	0,954	0,954	0,946	0,944
YOLOv5s	CSPDarkNet53	0,968	0,954	0,945	0,929	0,934	0,904

¹⁰ Bounding box (B).

Tabela 9. Pontuações de acurácia, mAP e F1-Score dos modelos YOLOv8s, YOLOv7 e YOLOv5s em 500 épocas. Os maiores resultados estão em negrito.

Modelo	Backbone	Acc_weed ¹¹	mAP_weed	mAP Score	F1-Score
YOLOv8s	CSPDarkNet53	0,980	0,987	0,985	0,964
YOLOv7	CSPDarkNet53	0,990	0,990	0,988	0,951
YOLOv5s	CSPDarkNet53	0,980	0,987	0,991	0,960

¹¹ Accuracy (Acc).

3.2. Desempenho de diferentes épocas de treinamento

Os resultados de acurácia, pontuação F1 e mAP de diferentes versões do modelo YOLO em diferentes épocas de treinamento são apresentados nas Tabelas 10 e 11. As variações dos resultados de acurácia dos modelos dizem respeito à proporção entre as observações previstas corretamente e todas as observações. Em geral, todas as versões do modelo YOLO apresentaram acurácia acima de 90%. Entretanto, a comparação entre os modelos YOLO mostrou que a variante YOLOv8s e YOLOv7 apresentaram maior acurácia, na segmentação da planta daninha, entre 100 e 500

épocas, com valores acima de 95%, quando comparados ao YOLOv5s. Ademais, dentro as versões do modelo YOLO, o YOLOv7 se destacou com os valores de mAP e F1 acima de 95% em 300 e 700 épocas.

Tabela 10. Pontuações de acurácia, mAP e F1-Score dos modelos YOLOv8s, YOLOv7 e YOLOv5s, treinados em diferentes épocas. Os maiores resultados estão em negrito.

Número de épocas	YOLOv8s			YOLOv7			YOLOv5s		
	Acc	mAP0.5 (M)	F1-Score ¹²	Acc	mAP0.5 (M)	F1-Score	Acc	mAP0.5 (M)	F1-Score
100	0,943	0,933	0,956	0,930	0,890	0,950	0,877	0,816	0,910
300	0,950	0,956	0,961	0,937	0,933	0,953	0,940	0,904	0,965
500	0,957	0,970	0,964	0,950	0,954	0,951	0,943	0,930	0,960
700	0,940	0,973	0,962	0,952	0,984	0,982	0,930	0,945	0,952

¹² F-beta score (F1-Score).

Tabela 11. Pontuações de acurácia e precisão dos modelos YOLOv8s, YOLOv7 e YOLOv5s em diferentes épocas. Os maiores resultados estão em negrito.

Número de épocas	YOLOv8s		YOLOv7		YOLOv5s	
	Acc_weed	Precisão	Acc_weed	Precisão	Acc_weed	Precisão
100	1	0,990	0,990	0,992	0,980	0,958
300	0,970	0,998	0,990	0,994	0,980	0,981
500	0,980	0,997	0,990	0,983	0,980	0,968
700	0,990	0,995	0,989	0,982	0,990	0,970

As pontuações AP para os diferentes backbones do modelo Mask R-CNN (Detectron2) são apresentados nas Tabelas 12 e 13. A Tabela 12 apresenta as pontuações AP e acurácia em diferentes iterações para cada backbone do modelo Mask R-CNN (Detectron2). O *backbone* X101-FPN apresentou uma acurácia e precisão média de 99%. A Tabela 13 apresenta as pontuações AP e AR do modelo detectron2 com diferentes *backbones* para os casos em que a máxima iteração foi escolhida. As variações no AP resumem a precisão e os recursos de *recall* dos modelos em diferentes limites de IoU. Estas métricas podem oferecer entendimento sobre a capacidade dos modelos de identificar e segmentar plantas daninhas em meio às culturas agrícolas. Visto isso, o *backbone* R101-DC5 do modelo Mask-RCNN mostrou ter maior capacidade de detectar plantas daninhas em 20.000 iterações do modelo, quando comparado aos demais *backbones* testados, com precisão média acima de 93%.

Tabela 12. Pontuações Acc e AP do modelo Mask R-CNN com detectron2 em diferentes *backbones*. Os maiores resultados estão em negrito.

Número de iterações	R101-FPN			X101-FPN			R101-DC5		
	Acc	Box AP ₁₁ _{weed}	Mask AP _{weed}	Acc	Box AP _{weed}	Mask AP _{weed}	Acc	Box AP _{weed}	Mask AP _{weed}
5000	0,986	0,993	0,890	0,987	0,992	0,897	0,988	0,986	0,892
20000	0,988	0,977	0,888	0,991	0,995	0,914	0,989	0,995	0,906

¹³ Average precision (AP).

Tabela 13. Pontuações de AP do modelo Mask R-CNN com detectron2 em diferentes *backbones*. Os maiores resultados estão em negrito.

Modelo	Backbone	Max iteração/Época	AP IoU ¹⁴			API ¹⁵
			= 0.50:0.95	AP50	AP75	
Mask R-CNN	R101-FPN	20000	0,911	0,944	0,941	0,911
Mask R-CNN	X101-FPN	20000	0,924	0,953	0,949	0,924
Mask R-CNN	R101-DC5	20000	0,933	0,965	0,960	0,932

¹⁴ Intersection of union (IoU), ¹⁵ average precision large (API).

A Tabela 14 apresenta as pontuações de acurácia e perda nas etapas de treinamento e validação do modelo U-Net, em 100 diferentes épocas. Os resultados apresentaram maior acurácia de 97,1% e 96,1%, tanto para treinamento quanto para validação do modelo, respectivamente. O valor de perda no treinamento do modelo do U-Net, em 100 épocas, foi de 2,4%.

Tabela 14. Pontuações de acurácia, perda de treinamento e validação do modelo U-Net em diferentes épocas. Os maiores resultados estão em negrito.

Modelo	Número de épocas	Train Acc	Train Loss	Valid Acc	Valid Loss
U-Net	30	0,967	0,047	0,958	0,051
U-Net	50	0,968	0,040	0,958	0,047
U-Net	80	0,968	0,042	0,960	0,049
U-Net	100	0,971	0,024	0,961	0,033

A Figura 10 mostra a comparação entre as predições feitas e as máscaras *ground truth* de todos os modelos avaliados e suas variantes. Neste sentido, pode ser

observado que as previsões feitas pelos algoritmos DL treinados apresentaram precisão na capacidade de detecção de cada objeto delimitado na imagem.




Figura 10. Comparação de máscaras de segmentação previstas e reais entre algoritmos de segmentação de instâncias e suas variantes: (a) YOLOv8s, YOLOv7 e YOLOv5s, (b) Mask R-CNN (Detectron2) e seus diferentes backbones.

Os resultados mostrados apresentam a diferença de desempenho entre os modelos YOLO e Mask R-CNN (Detectron2), mostrando que a precisão e a acurácia de todos os modelos avaliados variou entre 94% e 99%. A variante YOLOv8s apresentou maior precisão em relação às demais versões do modelo YOLO, considerando a previsão correta de plantas feita pelo modelo para todas as amostras do conjunto de dados. Entretanto, as variantes YOLOv8m e YOLOv8l apresentaram mAP50 e mAP50-95 de 97,4% e 97,2%, respectivamente. O backbone de maior desempenho foi o R101-DC5, no modelo Mask R-CNN (Detectron2), com pontuação AP50 de 96,5% e AP IoU (0,50-0,95) de 93,3%, quando comparado com os demais backbones treinados.




Figura 11. Resultados de treinamento para os modelos de segmentação de instâncias: (a) precisão dos modelos YOLOv8s, YOLOv7 e YOLOv5s em 500 épocas; (b) acurácia do modelo Mask R-CNN (Detectron2) e suas variantes, em 20.000 iterações.

A diferença na precisão, AP (50 e 50-95) e pontuações de recall entre os algoritmos de segmentação de instâncias em diferentes *backbones* em diferentes momentos e interações mostraram desempenho superior do YOLOv8s e Mask R-CNN com o *backbone* R101-DC5 (Tabela 15). Os YOLOv8s tiveram um valor mAP50 de 97% e recall de 99%. O valor de recall de 99% descreve a capacidade do modelo YOLOv8s de encontrar todos os casos relevantes dentro do conjunto, sendo o número de casos de previsões corretas de ervas daninhas para todos os casos de plantas reais e refere-se ao número de medições que o modelo previu corretamente e isso será considerado nas previsões totais relevantes [33,38]. A máscara R-CNN com *backbone* R101-DC5 teve um valor mAP50 de 96,5% e um valor de recall de 96,4%.

Tabela 15. Pontuações de acurácia, AP e recall de todos os modelos e suas variantes. Os maiores resultados estão em negrito.

Modelos	Backbone	Máx. iteração/ Época	Acc	AP50:95/mAP50:95	AP50/mAP50 ₁₆	AR/Recall
Mask R-CNN	R101-FPN	20000	0,980	0,911	0,944	0,948
Mask R-CNN	X101-FPN	20000	0,989	0,924	0,953	0,924
Mask R-CNN	R101-DC5	20000	0,991	0,933	0,965	0,964
YOLOv8s	CSPDarkNet53	500	0,957	0,965	0,970	0,990
YOLOv7	CSPDarkNet53	500	0,950	0,944	0,954	0,981

YOLOv5sCSPDarkNet53	500	0,943	0,904	0,945	0,954
U-Net ResNet50	100	0,971	-	-	-

¹⁶ Average recall (AR).

A comparação entre os modelos demonstrou que o YOLOv8s obteve desempenho significativamente maior do que o Mask R-CNN (Detectron2) e U-Net em três das quatro métricas de desempenho. Sendo assim, o modelo YOLOv8 e suas variantes apresentaram o maior resultado de mAP e *recall*, assim como maior resultado em acurácia.

4. DISCUSSÃO

Na interface de aplicação *Roboflow* [44], durante o processo de anotação dos objetos nas imagens do conjunto, os formatos poligonais das caixas delimitadoras foram utilizados em razão das formas curvas e diagonais das classes presentes, como plantas daninhas, plantas de feijoeiro e plantas de soja [45,46].

Neste sentido, a anotação precisa dos objetos e o aumento do conjunto de dados se provaram importantes para alcançar resultados satisfatórios para este estudo. Nas fases de teste dos modelos de aprendizagem profunda, ficou evidente que o uso de polígonos para a rotulagem de objetos se mostrou eficaz ao segmentar plantas daninhas em meio à culturas agrícolas comerciais [47-49].

4.1. Desempenho de diferentes backbones e variantes de modelos

Os resultados demonstrados na seção anterior mostraram a diferença entre o desempenho dos modelos de aprendizagem profunda YOLO, Mask R-CNN (Detectron2) e U-Net. As variantes YOLOv8s e YOLOv8m obtiveram os melhores resultados e, notavelmente, identificaram e localizaram os objetos dentro das imagens com maior acurácia. A acurácia é relevante quando o número de falsos positivos é próximo ao número de falsos negativos e o conjunto de dados é simétrico [33,34]. Caso o conjunto de dados seja assimétrico, é necessário recorrer a outras métricas de desempenho, pois considerar um modelo melhor com base somente na acurácia é incorreto, como descrito por Butt et al. [33]. O maior desempenho das variantes do

modelo YOLOv8 (YOLOv8s e YOLOv8m) pode estar associado a uma rede *backbone* mais recente (CSPDarkNet53) e à sua capacidade de usar mapas de recursos maiores que filtram e agregam relacionamentos complexos entre recursos e de reconhecer padrões e objetos, sendo mais eficiente [33]. Esta variante do modelo YOLOv8 (YOLOv8s) possui índice de precisão média (mAP) superior em relação às demais variantes. Além disso, o tempo gasto para o modelo YOLOv8s detectar e segmentar plantas daninhas, no conjunto de imagens, é inferior ao tempo gasto para as demais variantes realizarem as mesmas inferências [14,30,33]. Neste sentido, o modelo YOLOv8 apresentou maior índice de precisão, quando comparado com outros modelos de aprendizagem, devido a capacidade do modelo de detectar objetos dividindo a imagem em uma grade de dimensões iguais, capaz de localizar os objetos que estão no centro da grade [34]. Assim, cada grade pode prever algumas caixas delimitadoras e, por sua vez, as caixas mais representativas são escolhidas, conforme o estudo de Sportelli [50]. A capacidade que o modelo YOLO tem de localizar uma imagem com alta precisão, principalmente o YOLOv8, ocorre porque são utilizados em sua arquitetura, dentre outros fatores, os métodos de supressão não máximos (NMS, em inglês) para executar esta tarefa [51,56].

Os resultados de desempenho do modelo YOLOv8 e suas variantes foram comparados com os modelos YOLOv7 e YOLOv5 nos estudos de Guo *et al.* [30] e Gallo *et al.* [32] para diferentes épocas, de forma semelhante. Pode-se perceber que o aumento no número de épocas de treinamento pode interferir na capacidade e desempenho que as versões anteriores do modelo YOLO têm de reconhecer os padrões dos objetos no conjunto e, conseqüentemente, como resultado, poderá interferir no tempo de resposta para detectar e segmentar objetos em tempo real, conforme visto por Feng *et al.* [14], Gallo *et al.* [32] e Butt *et al.* [33].

Ao contrário do YOLOv8, o modelo YOLOv5s obteve o pior desempenho quando comparado à versão mais recente do YOLO e em relação aos demais modelos. Isso ocorre porque, de acordo com Dias e Figueiredo [45], esta versão apresenta bom desempenho em eficiência de treinamento, com até 135 épocas, porém apresenta baixo valor de precisão e qualidade na detecção e segmentação de objetos em cenários complexos.

4.2. Desempenho de diferentes épocas de treinamento

O modelo YOLOv8s apresentou precisão superior quando comparado às versões anteriores (YOLOv7 e YOLOv5s) em 500 e 700 épocas, visto a rede *backbone* mais recente (CSPDarkNet53). Os modelos YOLOv7 e YOLOv5s demonstraram desempenho com qualidade de detecção superior à versão mais recente do modelo YOLO, YOLOv8s, somente em 700 épocas de treinamento. Entretanto, o modelo YOLOv5s, em estudos que aprimoram a sua capacidade ao empregar um módulo de atenção de bloco convolucional (CBAM, em inglês) ao modelo, com o intuito de extrair características na imagem, pode alcançar precisão média acima 90% e *recall* superior à 85% em detecção de campo em tempo real, obtendo maior desempenho em qualidade de detecção [53].

O *backbone* R101-DC5, do algoritmo Mask R-CNN (Detectron2), mostrou-se superior em eficiência no treinamento ao detectar instâncias em 20.000 iterações, em relação aos modelos YOLOv5s e YOLOv7 e aos demais backbones deste modelo. O modelo Mask R-CNN obteve ainda maior acurácia em qualidade de detecção, quando comparado ao modelo U-Net. Isto ocorre porque a acurácia em qualidade de detecção do Mask R-CNN pode estar associada à implementação da rede de recursos em pirâmide (FPN, em inglês) no *framework* Detectron2, que permite a detecção de objetos e escalas dentro da imagem [43]. Assim, o algoritmo Mask R-CNN pode ser capaz de combinar mapas de recursos de diferentes escalas, sendo possível detectar objetos de diversos tamanhos na imagem, no qual pode contribuir para o aumento da quantidade de objetos detectados na imagem e, conseqüentemente, na qualidade de detecção [35]. Ajayi et al. [28] apresentaram resultados semelhantes em um estudo ao treinar uma rede neural convolucional (CNN, em inglês) para detectar e classificar planta daninha em cultura agrícola mista.

Neste contexto, os modelos Mask R-CNN (*backbone* R101-DC5) e U-Net (*backbone* ResNet50) mostraram-se superiores em qualidade de detecção ao apresentar acurácia superior ao YOLOv8s e a demais modelos. Entretanto, as pontuações mAP do modelo YOLOv8 foram superiores ao Mask R-CNN, e isto pode estar associado ao recente *backbone* presente na última versão do modelo YOLO, em que o algoritmo utiliza uma camada denominada módulo de *pooling* de pirâmide espacial rápida (SPPF, em inglês), que é capaz de agrupar recursos de diferentes escalas em um mapa de recursos de tamanho fixo com o propósito de acelerar o processamento [33].

O modelo de disparo único YOLOv8, e suas variações, conseguiu superar o modelo de disparo duplo Mask R-CNN, bem como o modelo U-Net em precisão média

de detecção e segmentação. Além disso, ao comparar o desempenho dos modelos de segmentação de instância de classe única e multiclasse, YOLOv8 e Mask R-CNN, usando grandes conjuntos de imagens, estudos recentes mostraram que o YOLOv8 obteve melhor desempenho, com precisão acima de 92% e *recall* de 97% ao detectar objetos [54]. Isso ocorre porque, uma das características da arquitetura DarkNet-53 do modelo YOLOv8 está em sua rede neural convolucional profunda e otimizada (CSPDarkNet53) de 53 camadas para extração de multiobjetos em imagens. Esta diferença significativa na arquitetura, quando comparada às demais versões YOLO e outros modelos de aprendizagem, torna o processamento, da oitava versão, mais rápido e com maior precisão de detecção, visto a substituição do módulo C3 pela versão melhorada C2F, tornando este modelo computacionalmente eficiente [54,55,59].

Em 100 épocas, o modelo U-Net apresentou maiores pontuações de acurácia, tanto na fase de treinamento quanto na fase de validação do modelo e, além disso, apresentou a pontuação de menor perda de dados no treinamento, quando comparado às demais épocas. A perda no treinamento implica comportamento do modelo após cada época, isto é, quanto menor a perda, melhor será o modelo, como descrito por Arab *et al.* [12]. Nasiri *et al.* [31] encontraram resultados semelhantes ao treinar um modelo U-Net com ResNet50 para o reconhecimento de plantas daninhas na cultura da beterraba e obtiveram pontuação de precisão de 96%.

Ainda neste sentido, o modelo U-Net, quando melhorado e treinado em 100 épocas, com o propósito de detectar e segmentar plantas daninhas, apresentou coeficiente pontuação F1 e intersecção sobre união (IoU) de 90% e 82%, respectivamente, de acordo com o estudo de Habib *et al.* [57]. Isso ocorre porque este modelo se baseia, principalmente, na arquitetura U-Net que possui um codificador (expansão) e decodificador (contração) simétricos, uma rede totalmente convolucional (FCN, em inglês), além de recurso para redução de dimensão na imagem (MaxPooling, em inglês) para pequenas mudanças espaciais em relação à imagem original [58].

5. CONCLUSÃO

A variante dos modelos YOLOv8, YOLOv8s teve o maior desempenho de mAP e *Recall*, isto é, maior eficiência no treinamento em comparação com os demais modelos de aprendizagem profundo. A variante YOLOv8m teve o maior desempenho

de mAP e *recall* quando comparada com outras variantes do modelo YOLOv8. O menor desempenho foi fornecido pelo YOLOv5, em função do valor de mAP, quando comparado com os demais modelos.

Os modelos Mask R-CNN (*backbone* R101-DC5) e U-Net (ResNet50) também mostraram qualidade ao detectar e segmentar objetos, ao longo das épocas de treinamento, quando comparados aos modelos YOLOv5s e YOLOv7. Em comparação ao modelo YOLOv8, este obteve maior precisão em detectar e segmentar multiobjetos no conjunto, quando comparado aos demais modelos de aprendizagem e versões anteriores do YOLO, visto sua arquitetura recente DarkNet-53.

Dados obtidos neste estudo demonstraram que modelos de aprendizagem profunda e algoritmos avançados de segmentação de objetos, quando treinados com um conjunto de dados bem rotulado e aumentado, podem gerar resultados eficientes para detecção automática de plantas daninhas em banco de dados de imagens RGB de alta resolução capturadas por UAV.

6. REFERÊNCIAS BIBLIOGRÁFICAS

1. Ilniyaz, O., Du, Q., Shen, H., He, W., Feng, L., Azadi, H., Kurban, A., Chen, X. Leaf area index estimation of pergola-trained vineyards in arid regions using classical and deep learning methods based on UAV-based RGB images. *Comput. Electron. Agric.* 2023, 207, 107723. <https://doi.org/10.1016/j.compag.2023.107723>.
2. Peng, M., Han, W., Li, C., Yao, X., Shao, G. Modeling the daytime net primary productivity of maize at the canopy scale based on UAV multispectral imagery and machine learning. *Journal of Cleaner Prod.* 2022, 367, 133041. <https://doi.org/10.1016/j.jclepro.2022.133041>.
3. Barbosa, B.D.S., Ferraz, G.A.E.S., Costa, L., Ampatzidis, Y., Vijayakumar, V., Santos, L.M.D. UAV-based coffee yield prediction utilizing feature selection and deep learning. *Smart Agric. Tech.* 2021, 1, 100010. <https://doi.org/10.1016/j.atech.2021.100010>.
4. Alabi, T.R., Abebe, A.T., Chigeza, G., Fowobaje, K.R. Estimation of soybean grain yield from multispectral high-resolution UAV data with machine learning models in West Africa. *Remote Sens. Applications: Society and Environ.* 2022, 27, 100782. <https://doi.org/10.1016/j.rsases.2022.100782>.
5. Teshome, F.T., Bayabil, H.K., Hoogenboom, G., Schaffer, B., Singh, A., Ampatzidis, Y. Unmanned aerial vehicle (UAV) imaging and machine learning applications for plant phenotyping. *Comput. Electron. Agric.* 2023, 212. <https://doi.org/10.1016/j.compag.2023.108064>.
6. Ariza-Sentís, M., Valente, J., Kooistra, L., Kramer, H., Múcher, S. Estimation of spinach (*Spinacia oleracea*) seed yield with 2D UAV data and deep learning. *Smart Agric. Tech.* 2022, 3. <https://doi.org/10.1016/j.atech.2022.100129>.
7. Niu, B., Feng, Q., Chen, B., Ou, C., Liu, Y., Yang, J. HSI-TransUNet: A Segmentation Model semantics based in transformer for crop mapping from UAV hyperspectral images. *Comput. Electron. Agric.* 2022, 201. <https://doi.org/10.1016/j.compag.2022.107297>.
8. Pandey, A., Jain, K. An intelligent system for crop identification and classification from UAV images using conjugated dense convolutional neural network. *Comput. Electron. Agric.* 2021, 192. <https://doi.org/10.1016/j.compag.2021.106543>.
9. Vong, N., Conway, L. S., Feng, A., Zhou, J., Kitchen, N.R., Sudduth, K.A. Estimating and Mapping Corn Emergence Uniformity using UAV imagery and deep learning. *Comput. Electron. Agric.* 2022, 198. <https://doi.org/10.1016/j.compag.2022.107008>.
10. Chen, R., Zhang, C., Xu, B., Zhu, Y., Zhao, F., Han, S., Yang, G., Yang, H. Predicting Individual Apple Yield using sensing data remote from multiple UAV sources and ensemble learning. *Comput. Electron. Agric.* 2022, 201. <https://doi.org/10.1016/j.compag.2022.107275>.
11. Sharma, N., Sharma, R., Jindal, N. Machine Learning and Deep Learning Applications-A Vision. *Global Trans. Proceed.* 2021. 24-28.

- <https://doi.org/10.1016/j.gltip.2021.01.004>.
12. Arab, A., Chinda, B., Medvedev, G., Siu, W., Guo, H., Gu, T., Moreno, S., Hamarneh, G., Ester, M., Song, X. A fast and fully-automated deep-learning approach for accurate hemorrhage segmentation and volume quantification in non-contrast whole-head CT. *Scientific Reports*. 2020. <https://doi.org/10.1038/s41598-020-76459-7>.
 13. Lopez-Granados, F., Jurado-Exposito, M., Peña-Barragan, J.M., García-Torres, L. Using remote sensing for identification of late-season grass weed patches in wheat. 2006. *Weed Sci.* 54 (2), 346–353. <https://doi.org/10.1614/WS-05-54.2.346>.
 14. Feng, Y., Chen, W., Ma, Y., Zhang, Z., Gao, P., Lv, X. Cotton Seedling Detection and Counting Based on UAV Multispectral Images and Deep Learning Methods. *Remote Sens.* 2023, 2680. <https://doi.org/10.3390/rs15102680>.
 15. Tunca, E., Köksal, E. S., Öztürk, E., Akayc, H., Taner, S., Ç. Accurate leaf area index estimation in sorghum using high-resolution UAV data and machine learning models. *Phys. and Chem. Earth, Pt A/B/C*. 2024, 133. <https://doi.org/10.1016/j.pce.2023.103537>.
 16. Genze, N., Ajekwe, R., Güreli, Z., Haselbeck, F., Grieb, M., Grimm, D. G. Deep learning-based early weed segmentation using motion blurred UAV images of sorghum fields. *Comput. Electron. Agric.* 2022. <https://doi.org/10.1016/j.compag.2022.107388>.
 17. Mohidem, N.A., Che'ya, N.N., Juraimi, A.S., Ilahi, W.F.F., Roslim, M.H.M., Sulaiman, N., Saberioon, M., Noor, N.M. How can unmanned aerial vehicles be used for detecting weeds in agricultural fields? *Agric.* 2021, 11. <https://doi.org/10.3390/agriculture11101004>.
 18. Ma, J., Liu, B., Ji, L., Zhu, Z., Wu, Y., Jiao, W. Field-scale yield prediction of winter wheat under different irrigation regimes based on dynamic fusion of multimodal UAV imagery. *Intern. Journ. Applied Earth Observ. and Geoinfo.* 2023, 118. <https://doi.org/10.1016/j.jag.2023.103292>.
 19. Liu, S., Jin, X., Bai, Y., Wu, W., Cui, N., Cheng, M., Liu, Y., Meng, L., Jia, X., Nie, C., Yin, D. UAV multispectral images for accurate estimation of the maize LAI considering the effect of soil background. *Intern. Journ. Applied Earth Observ. and Geoinfo.* 2023, 121. <https://doi.org/10.1016/j.jag.2023.103383>.
 20. Demir, S., Dedeoğlu, M., Başayığit, L. Yield prediction models of organic oil rose farming with agricultural unmanned aerial vehicles (UAVs) images and machine learning algorithms. *Remote Sens.: Socie. and Environ.* 2023, 101131. <https://doi.org/10.1016/j.rsase.2023.101131>.
 21. Jamali, M., Bakhshandeh, E., Yeganeh, B., Özdoğan, M. Development of machine learning models for estimating wheat bio-physical variables using satellite-based vegetation indices. *Adv. in Space Res.* 2024. <https://doi.org/10.1016/j.asr.2023.10.004>.
 22. Qu, H., Zheng, C., Ji, H., Barai, K., Zhang, Y. A fast and efficient approach to estimate wild blueberry yield using machine learning with drone photography: Flight altitude, sampling method and model effects. *Comput. Electron. Agric.* 2024, 216. <https://doi.org/10.1016/j.compag.2023.108543>.
 23. Sivakumar, A.N.V., Li, J., Scott, S., Psota, E., Jhala, A.J., Luck, J.D., Shi, Y.

- Comparison of object detection and patch-based classification deep learning models on mid-to late-season weed detection in UAV imagery. *Remote Sens.* 2020, 12. <https://doi.org/10.3390/rs12101591>.
24. Deng, J., Zhang, X., Yang, Z., Zhou, C., Wang, R., Zhang, K., Lv, X., Yang, L., Wang, Z., Li, P., Ma, Z. Pixel-level regression for UAV hyperspectral images: Deep learning-based quantitative inverse of wheat stripe rust disease index. *Comput. Electron. Agric.* 2023, 215. <https://doi.org/10.1016/j.compag.2023.108434>.
 25. Casas, E., Arbelo, M., Moreno-Ruiz, J. A., Hernández-Leal, P. A., Reyes-Carlos, J. A. UAV-Based Disease Detection in Palm Groves of *Phoenix canariensis* Using Machine Learning and Multispectral Imagery. *Remote Sens.* 2023, 3584. <https://doi.org/10.3390/rs15143584>.
 26. Somerville, G.J., Sønderskov, M., Mathiassen, S.K., Metcalfe, H. Spatial Modelling of within-field weed populations; a review. 2020. *Agronomy* 10 (7), 1044.
 27. Rahman, A., Lu, Y., Wang, H. Performance Evaluation of Deep Learning Object Detectors for Herbal Detection weeds for cotton. *Smart Agric. Tech.* 2022, 3. <https://doi.org/10.1016/j.atech.2022.100126>.
 28. Ajayi, O.G., Ashi, J., Guda, B. Performance evaluation of YOLO v5 model for automatic crop and weed classification on UAV images. *Smart Agric. Tech.* 2023, 5. <https://doi.org/10.1016/j.atech.2023.100231>.
 29. Wang H., Feng, J., Yin, H. Improved Method for Apple Fruit Target Detection Based on YOLOv5s. *Agric.* 2023, 2167. <https://doi.org/10.3390/agriculture13112167>.
 30. Guo, H., Xiao, Y., Li, M., Hao, F., Zhang, X., Sun, H., Beurs, K., Fu, Y. H., He, Y. Identifying crop phenology using maize height constructed from multi-sources images. *Intern. Journ. Applied Earth Observ. and Geoinfo.* 2022, 115. <https://doi.org/10.1016/j.jag.2022.103121>.
 31. Nasiri, A., Omid, M., Taheri-Garavand, A., Jafari, A. Deep learning-based precision agriculture through weed recognition in sugar beet fields. *Sustainable Comput.: Informatics and Systems.* 2022, 35. <https://doi.org/10.1016/j.suscom.2022.100759>.
 32. Gallo, I., Rehman, A.U., Dehkord, R.H., Landro, N., La Grassa, R., Boschetti, M. Deep Object Detection of Crop Weeds: Performance of YOLOv7 on a Real Case Dataset from UAV Images. *Remote Sens.* 2023, 15, 539. <https://doi.org/10.3390/rs15020539>.
 33. 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. <https://doi.org/10.3390/ai5010005>.
 34. 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.
 35. Lin, T.-Y.; Dollar, P.; Girshick, R.; He, K.; Hariharan, B.; Belongie, S. Feature Pyramid Networks for Object Detection. In *Proceedings of the IEEE Conference*

- on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, 21–26 July 2017.
36. Ronneberger, O., Fischer, P., Brox, T., U-Net: Convolutional Networks for Biomedical Image Segmentation. 2015. *Computer Science Department and BIOS Centre for Biological Signalling Studies*, University of Freiburg, Germany. Available online: <http://imb.informatik.uni-freiburg.de/> (accessed 02 March 2024).
 37. Wang, J., Lou, Y., Wang, W., Liu, S., Zhang, H., Hui, X., Wang, Y., Yan, H., Maes, W. H. A robust model for diagnosing water stress of winter wheat by combining UAV multispectral and thermal remote sensing. *Agric. Water Manag.* 2024, 291. <https://doi.org/10.1016/j.agwat.2023.108616>.
 38. Girshick, R. Fast R-CNN. In *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, Santiago, Chile, 7–13 December 2015; pp. 1440–1448.
 39. Pan, Q., Gao, M., Wu, P., Yan, J., Li, S. A Deep-Learning-Based Approach for Wheat Yellow Rust Disease Recognition from Unmanned Aerial Vehicle Images. *Sensors.* 2021, 21, 6540. <https://doi.org/10.3390/s21196540>.
 40. Lin, T.-Y.; Goyal, P.; Girshick, R.; He, K.; Dollar, P. Focal Loss for Dense Object Detection. In *Proceedings of the IEEE International Conference on Computer Vision*, Venice, Italy, 22–29 October 2017; pp. 2980–2988.
 41. Ramesh, N., Tasdizen, T., Chapter 3 - Detection and segmentation in microscopy images. 2021. *Computer Vision and Pattern Recognition*. p. 43-71. <https://doi.org/10.1016/B978-0-12-814972-0.00003-5>.
 42. Öztürk, Ş., Polat, K., Chapter 13 - A novel polyp segmentation approach using U-net with saliency-like feature fusion. 2023. *Intelligent Data-Centric Systems*. p. 251-269. <https://doi.org/10.1016/B978-0-323-96129-5.00011-1>.
 43. Kattenborn, T., Leitloff, J., Schiefer, F., Hinz, S. Review on Convolutional Neural Networks (CNN) in Vegetation Remote Sensing March. 2021. *Journal of Photogrammetry and Remote Sensing* 173(2). p. 24-49. <https://10.1016/j.isprsjprs.2020.12.010>.
 44. *Roboflow*. Available online: <https://roboflow.com/> (accessed 01 March 2024).
 45. Dias, R., L.; Figueiredo, A. P. de.; Mafra, S. B. Comparação de Modelos YOLOv5 e YOLOv8 para Detecção de Imagens de Áreas Rurais usando transferência de aprendizado. 2023. <https://10.13140/RG.2.2.30587.90400>.
 46. Hafeez, A., Husain, M., A., Singh, S., P., Chauhan, A., Khan, M., T., Kumar, N., Chauhan, A., Soni, S., K., Implementation of drone technology for farm monitoring & pesticide spraying: A review. *Information Processing in Agriculture*. 2022. <https://doi.org/10.1016/j.inpa.2022.02.002>.
 47. Robert N. Colwell Determining the prevalence of certain cereal crop diseases by means of aerial photography. *Hilgardia* 1956;26(5):223–86. <https://doi.org/10.3733/hilg.v26n05p223>.
 48. Cisternas I, Velasquez I, Caro A, Rodriguez A. Systematic literature review of implementations of precision agriculture. *Comput Electron Agric.* 2020;176. <https://doi.org/10.1016/j.compag.2020.105626>.

49. Wang H, Fapojuwo AO, Davies RJ. A wireless sensor network for feedlot animal health monitoring. *IEEE Sens. J.* 2016;(16)6433–46. <https://doi.org/10.1109/JSEN.2016.2582438>.
50. Sportelli, M.; Apolo-Apolo, O.E.; Fontanelli, M.; Frasconi, C.; Raffaelli, M.; Peruzzi, A.; Perez-Ruiz, M. Evaluation of YOLO Object Detectors for Weed Detection in Different Turfgrass Scenarios. *Appl. Sci.* 2023, 13, 8502. <https://doi.org/10.3390/app13148502>.
51. Reis, D.; Kupec, J.; Hong, J.; Daoudi, A. Real-Time Flying Object Detection with YOLOv8. *arXiv.* 2023. <https://doi.org/10.48550/arXiv.2305.09972>.
52. Ju, R.Y.; Cai, W. Fracture Detection in Pediatric Wrist Trauma X-ray Images Using YOLOv8 Algorithm. *arXiv.* 2023. <https://doi.org/10.48550/arXiv.2304.05071>.
53. Shao, Y.; Guan, X.; Xuan, G.; Gao, F.; Feng, W.; Gao, G.; Wang, Q.; Huang, X.; Li, J. GTCBS-YOLOv5s: A lightweight model for weed species identification in paddy fields. *Comput. Eletron. in Agric.* 2023, 108461. <https://doi.org/10.1016/j.compag.2023.108461>.
54. Sapkota, R.; Ahmed, D.; Karkee, M. Comparing YOLOv8 and Mask R-CNN for instance segmentation in complex orchard environments. *Art. Intel. in Agric.* 2024, 13, 84-99. <https://doi.org/10.1016/j.aiaa.2024.07.001>.
55. Amogi, Basavaraj R., Ranjan, Rakesh, Khot, Lav R. Mask R-CNN aided fruit surface temperature monitoring algorithm with edge compute enabled internet of things system for automated apple heat stress management. *Informa. Process. Agricult.* 2023. <https://doi.org/10.1016/j.inpa.2023.12.001>.
56. Niu, W.; Lei, X.; Li, H.; Wu, H.; Hu, F.; Wen, X.; Zheng, D.; Song, H.; YOLOv8-ECFS: A lightweight model for weed species detection in soybean fields. *Crop Protec.* 2024, 106847. <https://doi.org/10.1016/j.cropro.2024.106847>.
57. Habib, M.; Sekha, S.; Tannouche, A.; Ounejjar, Y. New segmentation approach for effective weed management in agriculture. *Smart Agric. Tech.* 2024, 100505. <https://doi.org/10.1016/j.atech.2024.100505>.
58. H. Zunair, A. Ben Hamza, Sharp U-Net: depthwise convolutional network for biomedical image segmentation, *Comput. Biol. Med.* 136 (2021) 104699, <https://doi.org/10.1016/J.COMPBIOMED.2021.104699>.
59. Karim, Md. J.; Nahiduzzaman, Md.; Ahsan, M.; Haider, J. Development of an early detection and automatic targeting system for cotton weeds using an improved lightweight YOLOv8 architecture on an edge device. *Knowledge-Based Sys.* 2024, 112204. <https://doi.org/10.1016/j.knosys.2024.112204>.

4. CONCLUSÃO GERAL

Este estudo apresentou uma investigação aprofundada sobre a aplicação da IA para apoiar as principais decisões de manejo agrícola e a importância no uso de modelos de aprendizado de máquina profundo para identificar, com precisão, plantas invasoras em culturas agrícolas. A RSL apontou que os métodos utilizando IA se comportam melhor na detecção de plantas daninhas, estimativa de produtividade e na classificação de doenças em plantas.

Neste contexto, a detecção automática de plantas daninhas nas culturas de soja e feijão comum, com o uso de segmentação de objetos e aprendizagem de máquina profundo, mostrou ser eficiente e capaz de detectar e monitorar o aparecimento das plantas em meio às culturas comerciais. Observou-se também que as variantes YOLOv8s e YOLOv8m tiveram o maior desempenho de mAP e Recall, em comparação com outras variantes do modelo YOLO. O modelo YOLOv5 obteve menor desempenho, em função do baixo valor de mAP e acurácia, entre todas as versões testadas do modelo YOLO.

O modelo MaskR-CNN com Detectron2 (backbone R101-DC5) demonstrou qualidade na segmentação de objetos. Este modelo obteve a maior pontuação em acurácia entre todos os modelos treinados.

Em trabalhos futuros, a expansão do conjunto de dados para diferentes culturas agrícolas poderá resultar em incrementos significativos nas análises dos modelos de aprendizagem de máquina aplicados à imagens de UAV. Além disso, o uso de fotografias multiespectrais e de outros sensores, como o espectrorradiômetro, combinados com o *drone*, poderá ser feito em pesquisas futuras.

3. REFERÊNCIAS BIBLIOGRÁFICAS GERAIS

1. Ilniyaz, O., Du, Q., Shen, H., He, W., Feng, L., Azadi, H., Kurban, A., Chen, X. Leaf area index estimation of pergola-trained vineyards in arid regions using classical and deep learning methods based on UAV-based RGB images. *Comput. Electron. Agric.* 2023, 207, 107723. <https://doi.org/10.1016/j.compag.2023.107723>.
2. Peng, M., Han, W., Li, C., Yao, X., Shao, G. Modeling the daytime net primary productivity of maize at the canopy scale based on UAV multispectral imagery and machine learning. *Journal of Cleaner Prod.* 2022, 367, 133041. <https://doi.org/10.1016/j.jclepro.2022.133041>.
3. Barbosa, B.D.S., Ferraz, G.A.E.S., Costa, L., Ampatzidis, Y., Vijayakumar, V., Santos, L.M.D. UAV-based coffee yield prediction utilizing feature selection and deep learning. *Smart Agric. Tech.* 2021, 1, 100010. <https://doi.org/10.1016/j.atech.2021.100010>.
4. Alabi, T.R., Abebe, A.T., Chigeza, G., Fowobaje, K.R. Estimation of soybean grain yield from multispectral high-resolution UAV data with machine learning models in West Africa. *Remote Sens. Applications: Society and Environ.* 2022, 27, 100782. <https://doi.org/10.1016/j.rsases.2022.100782>.
5. Teshome, F.T., Bayabil, H.K., Hoogenboom, G., Schaffer, B., Singh, A., Ampatzidis, Y. Unmanned aerial vehicle (UAV) imaging and machine learning applications for plant phenotyping. *Comput. Electron. Agric.* 2023, 212. <https://doi.org/10.1016/j.compag.2023.108064>.
6. Ariza-Sentís, M., Valente, J., Kooistra, L., Kramer, H., Múcher, S. Estimation of spinach (*Spinacia oleracea*) seed yield with 2D UAV data and deep learning. *Smart Agric. Tech.* 2022, 3. <https://doi.org/10.1016/j.atech.2022.100129>.
7. Niu, B., Feng, Q., Chen, B., Ou, C., Liu, Y., Yang, J. HSI-TransUNet: A Segmentation Model semantics based in transformer for crop mapping from UAV hyperspectral images. *Comput. Electron. Agric.* 2022, 201. <https://doi.org/10.1016/j.compag.2022.107297>.
8. Pandey, A., Jain, K. An intelligent system for crop identification and classification from UAV images using conjugated dense convolutional neural network. *Comput. Electron. Agric.* 2021, 192. <https://doi.org/10.1016/j.compag.2021.106543>.
9. Vong, N., Conway, L. S., Feng, A., Zhou, J., Kitchen, N.R., Sudduth, K.A. Estimating and Mapping Corn Emergence Uniformity using UAV imagery and deep learning. *Comput. Electron. Agric.* 2022, 198. <https://doi.org/10.1016/j.compag.2022.107008>.
10. Chen, R., Zhang, C., Xu, B., Zhu, Y., Zhao, F., Han, S., Yang, G., Yang, H. Predicting Individual Apple Yield using sensing data remote from multiple UAV sources and ensemble learning. *Comput. Electron. Agric.* 2022, 201. <https://doi.org/10.1016/j.compag.2022.107275>.
11. Sharma, N., Sharma, R., Jindal, N. Machine Learning and Deep Learning Applications-A Vision. *Global Trans. Proceed.* 2021. 24-28. <https://doi.org/10.1016/j.gltp.2021.01.004>.

12. Arab, A., Chinda, B., Medvedev, G., Siu, W., Guo, H., Gu, T., Moreno, S., Hamarneh, G., Ester, M., Song, X. A fast and fully-automated deep-learning approach for accurate hemorrhage segmentation and volume quantification in non-contrast whole-head CT. *Scientific Reports*. 2020. <https://doi.org/10.1038/s41598-020-76459-7>.
13. Lopez-Granados, F., Jurado-Exposito, M., Peña-Barragan, J.M., García-Torres, L. Using remote sensing for identification of late-season grass weed patches in wheat. 2006. *Weed Sci.* 54 (2), 346–353. <https://doi.org/10.1614/WS-05-54.2.346>.
14. Feng, Y., Chen, W., Ma, Y., Zhang, Z., Gao, P., Lv, X. Cotton Seedling Detection and Counting Based on UAV Multispectral Images and Deep Learning Methods. *Remote Sens.* 2023, 2680. <https://doi.org/10.3390/rs15102680>.
15. Tunca, E., Köksal, E. S., Öztürk, E., Akayc, H., Taner, S., Ç. Accurate leaf area index estimation in sorghum using high-resolution UAV data and machine learning models. *Phys. and Chem. Earth, Pt A/B/C*. 2024, 133. <https://doi.org/10.1016/j.pce.2023.103537>.
16. Genze, N., Ajekwe, R., Güreli, Z., Haselbeck, F., Grieb, M., Grimm, D. G. Deep learning-based early weed segmentation using motion blurred UAV images of sorghum fields. *Comput. Electron. Agric.* 2022. <https://doi.org/10.1016/j.compag.2022.107388>.
17. Mohidem, N.A., Che'ya, N.N., Juraimi, A.S., Ilahi, W.F.F., Roslim, M.H.M., Sulaiman, N., Saberioon, M., Noor, N.M. How can unmanned aerial vehicles be used for detecting weeds in agricultural fields? *Agric.* 2021, 11. <https://doi.org/10.3390/agriculture11101004>.
18. Ma, J., Liu, B., Ji, L., Zhu, Z., Wu, Y., Jiao, W. Field-scale yield prediction of winter wheat under different irrigation regimes based on dynamic fusion of multimodal UAV imagery. *Intern. Journ. Applied Earth Observ. and Geoinfo.* 2023, 118. <https://doi.org/10.1016/j.jag.2023.103292>.
19. Liu, S., Jin, X., Bai, Y., Wu, W., Cui, N., Cheng, M., Liu, Y., Meng, L., Jia, X., Nie, C., Yin, D. UAV multispectral images for accurate estimation of the maize LAI considering the effect of soil background. *Intern. Journ. Applied Earth Observ. and Geoinfo.* 2023, 121. <https://doi.org/10.1016/j.jag.2023.103383>.
20. Demir, S., Dedeoğlu, M., Başayığit, L. Yield prediction models of organic oil rose farming with agricultural unmanned aerial vehicles (UAVs) images and machine learning algorithms. *Remote Sens. Socie. and Environ.* 2023, 101131. <https://doi.org/10.1016/j.rsase.2023.101131>.
21. Jamali, M., Bakhshandeh, E., Yeganeh, B., Özdoğan, M. Development of machine learning models for estimating wheat bio-physical variables using satellite-based vegetation indices. *Adv. in Space Res.* 2024. <https://doi.org/10.1016/j.asr.2023.10.004>.
22. Qu, H., Zheng, C., Ji, H., Barai, K., Zhang, Y. A fast and efficient approach to estimate wild blueberry yield using machine learning with drone photography: Flight altitude, sampling method and model effects. *Comput. Electron. Agric.* 2024, 216. <https://doi.org/10.1016/j.compag.2023.108543>.
23. Sivakumar, A.N.V., Li, J., Scott, S., Psota, E., Jhala, A.J., Luck, J.D., Shi, Y. Comparison of object detection and patch-based classification deep learning

- models on mid-to late-season weed detection in UAV imagery. *Remote Sens.* 2020, 12. <https://doi.org/10.3390/rs12101591>.
24. Deng, J., Zhang, X., Yang, Z., Zhou, C., Wang, R., Zhang, K., Lv, X., Yang, L., Wang, Z., Li, P., Ma, Z. Pixel-level regression for UAV hyperspectral images: Deep learning-based quantitative inverse of wheat stripe rust disease index. *Comput. Electron. Agric.* 2023, 215. <https://doi.org/10.1016/j.compag.2023.108434>.
 25. Casas, E., Arbelo, M., Moreno-Ruiz, J. A., Hernández-Leal, P. A., Reyes-Carlos, J. A. UAV-Based Disease Detection in Palm Groves of *Phoenix canariensis* Using Machine Learning and Multispectral Imagery. *Remote Sens.* 2023, 3584. <https://doi.org/10.3390/rs15143584>.
 26. Somerville, G.J., Sønderskov, M., Mathiassen, S.K., Metcalfe, H. Spatial Modelling of within-field weed populations; a review. 2020. *Agronomy* 10 (7), 1044.
 27. Rahman, A., Lu, Y., Wang, H. Performance Evaluation of Deep Learning Object Detectors for Herbal Detection weeds for cotton. *Smart Agric. Tech.* 2022, 3. <https://doi.org/10.1016/j.atech.2022.100126>.
 28. Ajayi, O.G., Ashi, J., Guda, B. Performance evaluation of YOLO v5 model for automatic crop and weed classification on UAV images. *Smart Agric. Tech.* 2023, 5. <https://doi.org/10.1016/j.atech.2023.100231>.
 29. Wang H., Feng, J., Yin, H. Improved Method for Apple Fruit Target Detection Based on YOLOv5s. *Agric.* 2023, 2167. <https://doi.org/10.3390/agriculture13112167>.
 30. Guo, H., Xiao, Y., Li, M., Hao, F., Zhang, X., Sun, H., Beurs, K., Fu, Y. H., He, Y. Identifying crop phenology using maize height constructed from multi-sources images. *Intern. Journ. Applied Earth Observ. and Geoinfo.* 2022, 115. <https://doi.org/10.1016/j.jag.2022.103121>.
 31. Wang, J., Lou, Y., Wang, W., Liu, S., Zhang, H., Hui, X., Wang, Y., Yan, H., Maes, W. H. A robust model for diagnosing water stress of winter wheat by combining UAV multispectral and thermal remote sensing. *Agric. Water Manag.* 2024, 291. <https://doi.org/10.1016/j.agwat.2023.108616>.
 32. Gallo, I., Rehman, A.U., Dehkord, R.H., Landro, N., La Grassa, R., Boschetti, M. Deep Object Detection of Crop Weeds: Performance of YOLOv7 on a Real Case Dataset from UAV Images. *Remote Sens.* 2023, 15, 539. <https://doi.org/10.3390/rs15020539>.
 33. 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. <https://doi.org/10.3390/ai5010005>.
 34. 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.
 35. Lin, T.-Y.; Dollar, P.; Girshick, R.; He, K.; Hariharan, B.; Belongie, S. Feature Pyramid Networks for Object Detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, 21–

26 July 2017.

36. Ronneberger, O., Fischer, P., Brox, T., U-Net: Convolutional Networks for Biomedical Image Segmentation. 2015. *Computer Science Department and BIOS Centre for Biological Signalling Studies*, University of Freiburg, Germany. Available online: <http://lmb.informatik.uni-freiburg.de/> (accessed 02 March 2024).
37. Nasiri, A., Omid, M., Taheri-Garavand, A., Jafari, A. Deep learning-based precision agriculture through weed recognition in sugar beet fields. *Sustainable Comput.: Informatics and Systems*. 2022, 35. <https://doi.org/10.1016/j.suscom.2022.100759>.
38. Girshick, R. Fast R-CNN. In *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, Santiago, Chile, 7–13 December 2015; pp. 1440–1448.
39. Pan, Q., Gao, M., Wu, P., Yan, J., Li, S. A Deep-Learning-Based Approach for Wheat Yellow Rust Disease Recognition from Unmanned Aerial Vehicle Images. *Sensors*. 2021, 21, 6540. <https://doi.org/10.3390/s21196540>.
40. Lin, T.-Y.; Goyal, P.; Girshick, R.; He, K.; Dollar, P. Focal Loss for Dense Object Detection. In *Proceedings of the IEEE International Conference on Computer Vision*, Venice, Italy, 22–29 October 2017; pp. 2980–2988.
41. Ramesh, N., Tasdizen, T., Chapter 3 - Detection and segmentation in microscopy images. 2021. *Computer Vision and Pattern Recognition*. p. 43-71. <https://doi.org/10.1016/B978-0-12-814972-0.00003-5>.
42. Öztürk, Ş., Polat, K., Chapter 13 - A novel polyp segmentation approach using U-net with saliency-like feature fusion. 2023. *Intelligent Data-Centric Systems*. P. 251-269. <https://doi.org/10.1016/B978-0-323-96129-5.00011-1>.
43. Kattenborn, T., Leitloff, J., Schiefer, F., Hinz, S. Review on Convolutional Neural Networks (CNN) in Vegetation Remote Sensing March. 2021. *Journal of Photogrammetry and Remote Sensing* 173(2). p. 24-49. <https://10.1016/j.isprsjprs.2020.12.010>.
44. *Roboflow*. Available online: <https://roboflow.com/> (accessed 01 March 2024).