

**UNIVERSIDADE DE SÃO PAULO
INSTITUTO DE FÍSICA DE SÃO CARLOS**

Yuri Sarreta Oda

**Deteccção de plantas daninhas e plantas de soja utilizando
imagens multiespectrais e Visão Computacional**

São Carlos

2023

Yuri Sarreta Oda

**Deteccão de plantas daninhas e plantas de soja utilizando
imagens multiespectrais e Visão Computacional**

Tese apresentada ao Programa de Pós-Graduação em Física do Instituto de Física de São Carlos da Universidade de São Paulo, para obtenção do título de Doutor em Ciências.

Área de concentração: Física Biomolecular

Orientador: Prof. Dr. Jarbas Caiado de Castro Neto

Versão corrigida

(Versão original disponível na Unidade que aloja o Programa)

São Carlos

2023

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTES TRABALHOS, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Oda, Yuri Sarreta

Detecção de plantas daninhas e plantas de soja utilizando imagens multiespectrais e Visão Computacional / Yuri Sarreta Oda; orientador Jarbas Caiado de Castro Neto - versão corrigida -- São Carlos, 2023.

170 p.

Tese (Doutorado - Programa de Pós-Graduação em Física Biomolecular) -- Instituto de Física de São Carlos, Universidade de São Paulo, 2023.

1. Detecção de plantas daninhas. 2. Visão computacional. 3. Imagens multiespectrais. 4. Pulverização localizada de herbicidas. 5. Agricultura de precisão. I. Castro Neto, Jarbas Caiado de, orient. II. Título.

*À minha esposa, Natalia Cardozo,
aos meus pais, Cláudio e Renata,
e à minha tia Fernanda Sarreta,
pelo apoio incondicional durante
as mais diversas etapas de minha vida.*

AGRADECIMENTOS

De início, agradeço ao meu orientador, Prof. Dr. Jarbas C. de Castro Neto, pela excelente orientação e apoio imprescindível em todas as minhas decisões, por acreditar em mim e pela amizade construída durante o período de realização deste projeto.

Agradeço à minha esposa, Natalia Cardozo, pelo carinho, conselhos, amor e por sempre acreditar que eu sou capaz, me levantando nos momentos de desânimo e me ensinando à comemorar as pequenas vitórias. Agradeço também aos meus gatos, Draco e Jack, pela primeira sensação de ser pai que tive na vida. Me orgulho da família que estamos construindo.

Agradeço aos meus pais, Cláudio e Renata, por acreditarem em mim e fornecerem todo apoio, suporte e amor, sempre se orgulhando de minhas decisões. Agradeço à minha tia Fernanda, que sempre me incentivou à ingressar na pós-graduação, assim como ela o fez nos caminhos de sua vida. Agradeço aos meus avós Gilberto e Oneida, não mais aqui, mas sempre olhando por mim.

Agradeço a todos os meus colegas do Laboratório de Inovações Optrônicas para Oftalmologia e Agricultura pelo companheirismo, conselhos, discussões, momentos de descontração, apoio e suporte e também aos meus amigos da empresa Agrio Tecnologia, André Orlandi, Lucas Orlandi, Tiago Rosa, Osley Seixas, Bruno Sartorelli, Giuliano Rossi, Guilherme Castro e Nathalia Villani, por todo conhecimento transmitido e acolhimento nas horas necessárias.

Agradeço ao meu melhor amigo Mateus Priolo, pela amizade construída desde o primeiro dia de graduação, cerca de dez anos atrás, e que seguirá para o resto de nossas vidas.

Por fim, agradeço ao Instituto de Física de São Carlos, às bibliotecárias do IFSC pelo carinho e atenção durante a correção desta tese, ao CEPOF e ao professor Vanderlei Salvador Bagnato, que sempre disponibilizaram uma ótima infraestrutura para o desenvolvimento das pesquisas e à CAPES, que financiou este projeto.

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

*“Temos de fazer o melhor que podemos;
esta é a nossa sagrada responsabilidade humana.”*

Albert Einstein

RESUMO

ODA, Y. S. **Detecção de plantas daninhas e plantas de soja utilizando imagens multiespectrais e Visão Computacional**. 2023. 170p. Tese (Doutorado em Ciências) - Instituto de Física de São Carlos, Universidade de São Paulo, São Carlos, 2023.

Atualmente, a Agricultura de Precisão destaca-se como uma das áreas mais promissoras para o desenvolvimento de tecnologias no país. Algumas tecnologias advindas dessa área incluem, por exemplo, o mapeamento de áreas de produtividade e o desenvolvimento de sensores e sistemas para análises do solo e do clima, sempre visando o uso inteligente dos recursos durante o manejo das culturas e auxiliando o produtor durante as etapas de tomada de decisão. Dentre os problemas da agricultura moderna está o uso intensivo, não rotativo e de forma não localizada de herbicidas que, além de ser prejudicial ao meio ambiente, contribui para altos custos no orçamento do produtor e resulta na aplicação de produto em organismos não desejados. Apesar de existirem alguns sistemas de pulverização localizada disponíveis no mercado, o princípio de funcionamento da maioria deles é baseado em detectores de clorofila, não sendo capazes de distinguir plantas da lavoura de plantas daninhas com acurácia em aplicações de herbicidas após a emergência da cultura em campo. Visando contornar estes problemas, o presente trabalho aborda o uso de imagens multiespectrais para o reconhecimento de plantas daninhas pós-emergência da soja em ambientes de iluminação natural e artificial utilizando Visão Computacional e o algoritmo YOLO para tarefas de detecção e classificação. Para as imagens capturadas em iluminação artificial na primeira abordagem do projeto, os melhores resultados para a métrica $mAP_{(0,5;0,95)}$ foram para as imagens RGB (0,523), IR (0,527) e NIR (0,495). Na segunda abordagem, foi utilizado um sistema contendo uma roda de filtros e dez bandas espectrais e os melhores resultados obtidos foram para as bandas G (0,748), NDVI (0,717) e NIR-01 (0,714) para os modelos multi-classe e IR-780 (0,806), IR-850 (0,793) e NIR-01 (0,785) para os modelos uni-classe, demonstrando a importância dos comprimentos de onda do infravermelho próximo na detecção das plantas. Na terceira abordagem, os valores obtidos para as métricas *Precision*, *Recall* e $mAP_{(0,5;0,95)}$ nos modelos treinados nas imagens capturadas em ambiente com iluminação natural foram, respectivamente, 0,772, 0,726 e 0,470 para as imagens RGB e, respectivamente, 0,733, 0,735 e 0,387 para as imagens NIR, sugerindo que em imagens mais complexas o algoritmo precisa ser aprimorado para produzir resultados mais eficientes no reconhecimento de plantas daninhas. Os resultados demonstram que técnicas de Visão Computacional combinadas com imagens multiespectrais são abordagens promissoras para a detecção de plantas daninhas entre plantas de soja.

Palavras-chave: Detecção de plantas daninhas. Visão computacional. Imagens multiespectrais. Pulverização localizada de herbicidas. Agricultura de precisão.

ABSTRACT

ODA, Y. S. **Weed detection among soybean plants using multispectral images and Computer Vision**. 2023. 170p. Thesis (Doctor in Science) - Instituto de Física de São Carlos, Universidade de São Paulo, São Carlos, 2023.

Nowadays, Precision Agriculture stands out as one of the most promising areas for technology development in the country. Some technologies from this field includes, for example, productivity area mapping and the development of sensors and systems for soil and climate analysis, always aiming for intelligente resource use during crop management and helping farmers in decision-making stages. Among the problems of modern agriculture is the intensive, non-rotational and non-localized use of herbicides which, in addition to being harmful to the environment, contributes to high costs in farmer's budget and results in the application of chemicals to non-target organisms. Although some selective spraying systems are available on the market, most of them are based on chlorophyll detectors and are unable to accurately distinguish crop plants from weeds in herbicide applications after crop emergence in the field. In order to solve this problems, this work addresses the use of multispectral images for weed detection among soybean plants in natural and artificial lighting environment using Computer Vision and the YOLO algorithm for detection and classification tasks. In the first approach, for images captured under artificial lighting, the best results for the $mAP_{(0,5:0,95)}$ metric were obtained for RGB (0,532), IR (0,527) and NIR (0,495) images. In the second approach, a camera system with a filter wheel and ten spectral bands were used, and the best results were achieved for G (0,748), NDVI (0,717) and NIR-01 (0,714) bands for multi-class models, and IR-780 (0,806), IR-850 (0,793) and NIR-01 (0,785) bands for single-class models, highlighting the importance of near-infrared wavelengths in weed detection. In the third approach, the values obtained for Precision, Recall and $mAP_{(0,5:0,95)}$ metrics in models trained on images captured in natural lighting environment were, respectively, 0,772, 0,726 and 0,470 for RGB images and, respectively, 0,733, 0,735 and 0,387 for NIR images, suggesting that in more complex images, the algorithm needs improvement to produce more efficient results in weed recognition. The results demonstrate that Computer Vision techniques combined with multispectral images are promising approaches for weed detection among soybean plants.

Keywords: Weed detection. Computer vision. Multispectral images. Herbicide selective spraying. Precision agriculture.

LISTA DE FIGURAS

Figura 1 – Área colhida, quantidade produzida e valor da produção de acordo com dados da PAM em 2021. a) Área colhida (hectares); b) Quantidade produzida (toneladas); c) Valor da produção (mil reais)	32
Figura 2 – Variação anual do volume, preço em reais e faturamento das agroindústrias de base agrícola.	33
Figura 3 – Filtro de Bayer utilizado nos sensores CCD e CMOS, permitindo a transmissão das cores vermelho (R), verde (G) e azul (B) e posterior formação da imagem colorida por <i>softwares</i>	36
Figura 4 – Assinaturas espectrais nas bandas do azul (B), verde (G), vermelho (R) e infravermelho (IR) para uma folha verde, uma folha seca e amostra de solo com pouca matéria orgânica.	37
Figura 5 – <i>Pipeline</i> de um sistema de Visão Computacional clássico.	38
Figura 6 – Exemplo da arquitetura de uma rede neural convolucional.	39
Figura 7 – Exemplo da aplicação de um algoritmo de detecção e classificação na detecção de vacas em campo.	40
Figura 8 – Arquitetura básica de um algoritmo de detecção de objetos tradicional.	41
Figura 9 – Ilustração da métrica <i>Intersection over Union</i> (IoU).	42
Figura 10 – Modelagem da detecção no algoritmo YOLO. O algoritmo divide a imagem em grades de tamanho $S \times S$ e para cada célula gerada prediz B <i>bounding boxes</i> e os respectivos valores de confiança, assim como as classes C preditas.	43
Figura 11 – Imagem NDVI elaborada através de imagens do satélite Sentinel-2.	45
Figura 12 – Classificação de plantas daninhas. a) Exemplo de uma planta daninha de folha estreita; b) Exemplo de uma planta daninha de folha larga.	47
Figura 13 – Espectro da iluminação da bancada de cultivo e de captura de imagens na estufa <i>indoor</i>	51
Figura 14 – Estrutura de cultivo e captura de imagens de plantas. a) Esqueleto da estrutura de madeira construída para comportar o sistema de trilhos; b) Sistema de trilhos <i>v-slot</i> com motor de passo NEMA17 e Arduino Nano com placa <i>shield</i> CNC instalados.	52
Figura 15 – Experimento de campo para coleta de sementes de plantas daninhas. a) Lavoura de café na cidade de Jeriquara - SP utilizada para coleta de sementes; b) Exemplo de uma espécie de planta daninha coletada para identificação e coleta de sementes.	53

Figura 16 – Processo de identificação de plantas daninhas em laboratório. a) Planta da espécie <i>Amaranthus viridis</i> L.; b) Planta da espécie <i>Digitaria horizontalis</i> Willd.	54
Figura 17 – Cultivo <i>indoor</i> de sementes de plantas daninhas. a) Plântulas da espécie <i>Amaranthus viridis</i> L.; b) Plântulas da espécie <i>Digitaria horizontalis</i> Willd..	54
Figura 18 – Diagrama de posicionamento dos filtros espectrais nas câmeras CMOS monocromáticas.	55
Figura 19 – Construção da câmera multiespectral da primeira abordagem do projeto. a) Projeto do módulo da câmera multiespectral no SolidWorks®; b) Suporte impresso em PLA com as câmeras instaladas.	56
Figura 20 – Módulo contendo as quatro câmeras espectrais e a câmera RGB instalados no sistema de trilhos.	56
Figura 21 – Interface desenvolvida para automatizar o processo de captura de imagens.	57
Figura 22 – Construção do banco de imagens na primeira abordagem do projeto. Imagens obtidas nas bandas a) G, b) R, d) NIR, c) IR e e) imagem RGB.	58
Figura 23 – Ilustração do processo de rotulação das imagens utilizando o <i>software</i> CVAT.	59
Figura 24 – Projeto do módulo do sistema de captura contendo a roda de filtros no SolidWorks®.	61
Figura 25 – Espectros dos dez filtros utilizados na segunda abordagem do projeto medidos por um espectrômetro da Ocean Optics.	61
Figura 26 – Exemplos das imagens obtidas com a roda de filtros e a câmera RGB em duas condições de iluminação diferentes. a) UV+B; b) B+G, c) G, d) Y, e) R, f) R+IR, g) NIR-01, h) NIR-02, i) IR-780, j) IR-850, k) RGB-FS e l) RGB-LB.	64
Figura 27 – Processo de rotulação das imagens da banda NIR-01 da câmera monocromática e das imagens RGB no <i>software</i> CVAT. a) Rotulação das imagens NIR-01; b) Rotulação das imagens RGB.	65
Figura 28 – Resultados obtidos com o algoritmo YOLO nas imagens teste. Detecções nas imagens a) G; b) R; c) IR; d) NIR e e) RGB.	68
Figura 29 – Curvas <i>Precision-Recall</i> obtidas nas imagens teste das bandas a) G, b) R, c) IR, d) NIR e e) RGB.	70
Figura 30 – Matrizes de confusão obtidas com os modelos treinados nas diferentes imagens. Matrizes de confusão das bandas a) G, b) R, c) IR, d) NIR e e) RGB.	74
Figura 31 – Resultados obtidos para as métricas <i>Precision</i> e <i>Recall</i> nos modelos multi-classe treinados nas dez bandas espectrais e nas imagens RGB.	77

Figura 32 – Resultados obtidos com o algoritmo YOLO nas imagens teste na abordagem da roda de filtros com os modelos multi-classe. Detecções de plantas daninhas e de plantas de soja, respectivamente, nas imagens a) e b) UV; c) e d) B+G; e) e f) G; g) e h) Y; i) e j) R; k) e l) R+IR; m) e n) NIR-01; o) e p) NIR-02; q) e r) IR-780; s) e t) IR-850, u) e v) RGB-FS e w) e x) RGB-LB.	81
Figura 33 – Curvas <i>Precision-Recall</i> obtidas nas imagens teste com os modelos multi-classe treinados nas bandas a) UV; b) B+G; c) G; d) Y; e) R; f) R+IR; g) NIR-01; h) NIR-02; i) IR-780; j) IR-850, k) RGB-FS e l) RGB-LB.	87
Figura 34 – Resultados obtidos para as métricas $mAP_{(0,5)}$ e $mAP_{(0,5;0,95)}$ nos modelos multi-classe treinados nas dez bandas espectrais e nas imagens RGB.	88
Figura 35 – Matrizes de confusão obtidas nos modelos multi-classe treinados nas imagens a) UV; b) B+G; c) G; d) Y; e) R; f) R+IR; g) NIR-01; h) NIR-02; i) IR-780; j) IR-850, k) RGB-FS e l) RGB-LB.	95
Figura 36 – Resultados obtidos para as métricas <i>Precision</i> e <i>Recall</i> nos modelos uni-classe treinados nas dez bandas espectrais e nas imagens RGB.	99
Figura 37 – Resultados obtidos com o algoritmo YOLO as imagens teste na abordagem da roda de filtros com a classificação uni-classe. Detecções de plantas nas imagens a) e b) UV; c) e d) B+G; e) e f) G; g) e h) Y; i) e j) R; k) e l) R+IR; m) e n) NIR-01; o) e p) NIR-02; q) e r) IR-780; s) e t) IR-850, u) e v) RGB-FS e w) e x) RGB-LB.	103
Figura 38 – Curvas <i>Precision-Recall</i> obtidas nas imagens teste com os modelos uni-classe treinados nas bandas a) UV; b) B+G; c) G; d) Y; e) R; f) R+IR; g) NIR-01; h) NIR-02; i) IR-780; j) IR-850, k) RGB-FS e l) RGB-LB.	109
Figura 39 – Resultados obtidos para as métricas $mAP_{(0,5)}$ e $mAP_{(0,5;0,95)}$ nos modelos uni-classe treinados nas dez bandas espectrais e nas imagens RGB.	110
Figura 40 – Matrizes de confusão obtidas nos modelos treinados nas imagens a) UV; b) B+G; c) G; d) Y; e) R; f) R+IR; g) NIR-01; h) NIR-02; i) IR-780; j) IR-850, k) RGB-FS e l) RGB-LB.	117
Figura 41 – a) e b) Imagens das bandas R e c) e d) NIR-01 e detecção nas imagens NDVI nos modelos e) e f) multi-classe e g) e h) uni-classe.	119
Figura 42 – Curvas <i>Precision-Recall</i> obtidas nas imagens teste NDVI com os modelos a) multi-classe e b) uni-classe.	121
Figura 43 – Matrizes de confusão obtidas nos modelos a) multi-classe e b) uni-classe.	122
Figura 44 – Lavoura de soja onde foi construído o banco de imagens espectrais em iluminação natural na Safra 2022/23 a) Campo de coleta de imagens após a colheita do sorgo; b) Linhas contendo plantas de soja e plantas daninhas nas entrelinhas.	125

Figura 45 – Desenvolvimento do equipamento para construção do banco de imagens em campo. a) Visão geral do módulo de captura de imagens desenvolvido no SolidWorks®; b) Visão interna do módulo de captura de imagens; c) Visão lateral do módulo de captura de imagens evidenciando angulação de 45°.	126
Figura 46 – Equipamento para captura de imagens em campo desenvolvido. a) Equipamento com a câmera multiespectral, sistema embarcado Advantech instalado e com todas as conexões realizadas; b) Visão lateral do equipamento contendo o <i>display touchscreen</i> e bateria 12 V de <i>nobreak</i> ; c) Exemplo do equipamento em pleno funcionamento em campo.	127
Figura 47 – Construção do banco de imagens em campo. a), c), e) e g) Exemplos de imagens do tipo RGB coletadas em campo; b), d), f), e h) Exemplos das imagens NIR correspondentes.	128
Figura 48 – Processo de rotulação das imagens em iluminação natural utilizando o <i>software</i> CVAT.	129
Figura 49 – Resultados obtidos com o algoritmo YOLO nas imagens obtidas em uma lavoura de soja. Detecção nas imagens a), c), e) e g) RGB e b), d), f) e h) NIR.	132
Figura 50 – Curvas <i>Precision-Recall</i> obtidas nas imagens teste a) RGB e da banda b) NIR.	133
Figura 51 – Matrizes de confusão das imagens teste dos modelos a) RGB e b) NIR.	135
Figura 52 – Logo da <i>startup</i> Agrio Tecnologia LTDA.	139
Figura 53 – Desenvolvimento do nível de maturidade tecnológica TRL 4. a) Sistema de trilhos com nove metros de barras <i>v-slot</i> ; b) Visão lateral do equipamento instalado com a barra de pulverização no sistema de trilhos; c) Visão frontal do equipamento evidenciando barra de pulverização e válvulas PWM; d) <i>Design</i> experimental com plantas de soja e daninhas utilizado para validação.	140
Figura 54 – Desenvolvimento 3D do conceito da UNIDADE DE PULVERIZAÇÃO no <i>software</i> Solid Works®. a) Visão frontal, b) interna, c) traseira; d) e lateral.	143
Figura 55 – Desenvolvimento 3D do conceito da barra de pulverização que será instalada em veículo automotor projetada no <i>software</i> Solid Works®. a) Visão completa; b) Visão frontal com duas UNIDADES DE PULVERIZAÇÃO; c) Visão lateral com duas UNIDADES DE PULVERIZAÇÃO.	145
Figura 56 – Desenvolvimento inicial da UNIDADE DE PULVERIZAÇÃO. a) Carenagem desenvolvida em alumínio, anodizada e fechada; b) Instalação na haste de fixação no trator; c) Carenagem aberta com componentes ópticos e eletrônicos instalados.	149

Figura 57 – Barra de pulverização em menor escala desenvolvida para instalação em veículo automotor visando a construção de novos bancos de imagens multiespectrais em campo e validação do sistema. a) Barra aberta; b) Barra fechada.	149
Figura 58 – Instalação de uma UNIDADE DE PULVERIZAÇÃO em um pulverizador autopropelido para realização de testes de captura de imagens em altas velocidades. a) Pulverizador utilizado; b) Visão frontal; Visão lateral c) esquerda e d) direita da unidade; e) Unidade capturando imagens em movimento.	151
Figura 59 – Exemplo do processo de detecção de plantas daninhas nas imagens obtidas no primeiro teste com a UNIDADE DE PULVERIZAÇÃO instalada em um pulverizador autopropelido. a) e b) Detecção nas imagens RGB; c) e d) Detecção nas imagens NIR;	152
Figura 60 – Trabalhos recorrentes. a) Pôster do trabalho desenvolvido durante este projeto apresentado pelo Me. Lucas Orlandi de Oliveira no congresso SPIE Conference on Advanced Photonics. b) Prêmio de melhor pôster apresentado no congresso conquistado na categoria "People's Choice Award Best Poster".	170

LISTA DE TABELAS

Tabela 1 – Produção de soja (em milhões de toneladas) das safras 2021/22, 2022/23 e projeção para a safra 23/24 dos maiores produtores de soja do mundo.	35
Tabela 2 – Resultados obtidos para as principais métricas após a aplicação do YOLO nos modelos treinados nos cinco tipos de imagens.	66
Tabela 3 – Resultados obtidos para as principais métricas após a aplicação do YOLO nas imagens das dez bandas e nas imagens RGB nos modelos multi-classe.	76
Tabela 4 – Resultados obtidos para as principais métricas após a aplicação do YOLO nas imagens das dez bandas e nas imagens RGB nos modelos uni-classe.	98
Tabela 5 – Resumo dos melhores resultados obtidos para cada métrica nos modelos multi-classe e uni-classe na segunda abordagem do projeto.	124
Tabela 6 – Resultados obtidos para as principais métricas após a aplicação do YOLO v5 nas imagens RGB e NIR de campo.	130

LISTA DE ABREVIATURAS E SIGLAS

AP	Agricultura de Precisão
IA	Inteligência Artificial
YOLO	You Only Look Once
RGB	Red, Green, Blue
UAV	Unmanned Aerial Vehicle
PIB	Produto Interno Bruto
CEPEA	Centro de Estudos Avançados em Economia Aplicada
ESALQ	Escola Superior de Agricultura "Luiz de Queiroz"
CNA	Confederação Nacional da Agricultura e Pecuária do Brasil
IBGE	Instituto Brasileiro de Geografia e Estatística
PAM	Produção Agrícola Municipal
CONAB	Companhia Nacional de Abastecimento
USDA	United States Department of Agriculture
CCD	Charged Coupled Device
CMOS	Complementary Metal Oxide Semiconductor
CNN	Convolutional Neural Networks
IoU	Intersection over Union
mAP	mean Average Precision
AP	Average Precision
AUC	Area Under the Curve
NDVI	Normalized Difference Vegetation Index
PCPI	Período Crítico de Prevenção da Interferência
EPSPs	5-enolpiruvilxiquimato-3-fosfato

IBAMA	Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis
LIO ² A	Laboratório de Inovações Optrônicas para Oftalmologia e Agricultura
IFSC	Instituto de Física de São Carlos
CVAT	Computer Vision Annotation Tool

LISTA DE SÍMBOLOS

α *Threshold* da métrica IoU

SUMÁRIO

1	INTRODUÇÃO	27
1.1	Motivação	30
1.2	Estrutura do trabalho	30
2	REVISÃO BIBLIOGRÁFICA	31
2.1	Importância do Agronegócio para o Brasil	31
2.1.1	Soja (<i>Glycine max</i> L. Merrill)	34
2.2	Agricultura de Precisão	35
2.3	Imagens multiespectrais	36
2.4	Visão Computacional	38
2.4.1	Redes neurais convolucionais	39
2.4.2	Algoritmos de detecção e classificação	40
2.4.2.1	Algoritmo YOLO	43
2.5	Trabalhos relacionados	44
2.6	Manejo convencional de plantas daninhas	46
3	DESENVOLVIMENTO EM ILUMINAÇÃO ARTIFICIAL	51
3.1	Metodologia	51
3.1.1	Laboratório estufa <i>indoor</i>	51
3.1.2	Sistema de trilhos <i>v-slot</i>	52
3.1.3	Experimento de campo para coleta de sementes	53
3.1.4	Cultivo <i>indoor</i> de plantas	54
3.1.5	Módulo com quatro câmeras CMOS monocromáticas, quatro filtros espectrais e uma câmera CMOS RGB	55
3.1.5.1	Construção do banco de imagens	57
3.1.5.2	Aplicação do algoritmo YOLO	59
3.1.6	Módulo com uma câmera CMOS RGB, uma câmera CMOS monocromática e uma roda de filtros contendo dez bandas espectrais	60
3.1.6.1	Construção do banco de imagens	62
3.1.6.2	Aplicação do algoritmo YOLO	65
3.2	Resultados e discussão	66
3.2.1	Módulo com quatro câmeras CMOS monocromáticas, quatro filtros espectrais e uma câmera CMOS RGB	66
3.2.2	Módulo com uma câmera CMOS RGB, uma câmera CMOS monocromática e uma roda de filtros contendo dez bandas espectrais	76
3.2.2.1	Classificação uni-classe: planta vs solo	97

3.2.2.2	Classificação uni-classe e multi-classe em imagens NDVI	118
4	DESENVOLVIMENTO EM ILUMINAÇÃO NATURAL	125
4.1	Metodologia	125
4.1.1	Lavoura de soja	125
4.1.2	Módulo contendo uma câmera CMOS RGB e uma câmera CMOS monocromática com filtro NIR	126
4.1.3	Construção do banco de imagens	127
4.1.4	Aplicação do algoritmo YOLO	129
4.2	Resultados e discussão	130
4.2.1	Módulo contendo uma câmera CMOS RGB e uma câmera CMOS monocromática com filtro NIR	130
5	DESENVOLVIMENTO TECNOLÓGICO	139
5.1	Metodologia	141
5.1.1	Unidade de pulverização	142
5.1.2	Controlador	144
5.1.3	Barra de pulverização	144
5.2	Resultados e discussão	148
6	CONSIDERAÇÕES FINAIS	155
	REFERÊNCIAS	159
	ANEXOS	167
	ANEXO A – APRESENTAÇÃO DE TRABALHO NO CONGRESSO SPIE CONFERENCE ON ADVANCED PHOTONICS	169

1 INTRODUÇÃO

Nos últimos anos, a Agricultura de Precisão (AP) vem se destacando como uma das áreas mais promissoras para o desenvolvimento de novas tecnologias ao redor do mundo (1). Os avanços na área incluem, por exemplo, a criação de sistemas inteligentes capazes de tomar decisões mais adequadas para o manejo das lavouras por meio de análises do solo e do clima, mapeamento de áreas de produtividade por drones, desenvolvimento de sensores para o diagnóstico precoce de doenças, identificação e combate localizado de pragas, entre outros (2). Juntos, os fatores supracitados visam interligar as diversas etapas do processo de produção agrícola, fornecendo ao produtor o amplo conhecimento de sua lavoura e permitindo que as decisões tomadas durante esses processos sejam baseadas na informação gerada pelos dados. Dessa forma, os custos com herbicidas, fungicidas e fertilizantes são reduzidos, havendo uma maior produtividade ao fim da colheita e uma melhor qualidade da produção (3).

Atualmente, um dos maiores problemas enfrentados pela agricultura moderna é o controle de plantas daninhas, ou seja, o controle de plantas invasoras que competem com as plantas da cultura por recursos naturais como água, luz, nutrientes e espaço de crescimento (4). Devido ao fato de algumas cultivares das principais espécies cultivadas no país serem geneticamente modificadas para adquirir resistência aos herbicidas encontrados no mercado (5), as aplicações de herbicidas são feitas através da pulverização de agroquímicos ao longo de toda a extensão do campo (6). Além de afetar diretamente o orçamento dos produtores, as consequências dessas práticas são prejudiciais ao meio ambiente, uma vez que essas substâncias podem atingir rios e lençóis-freáticos, contaminando o solo (7) e ameaçando espécies que dependem desses ecossistemas (8).

O rápido surgimento de plantas daninhas resistentes aos herbicidas existentes preocupa os produtores agrícolas e tem chamado atenção de especialistas para as possíveis causas desse fenômeno (9). A resistência aos herbicidas é causada principalmente por aplicações contínuas do mesmo herbicida ou de diferentes agentes, mas com o mesmo mecanismo de ação. Após um período, diversos mecanismos de resistência podem ser encontrados nas plantas daninhas, uma vez que a resistência é um processo evolucionário dirigido por seleção na variação genética (10). Juntos, esses fatores contribuem para dificultar o controle de plantas daninhas durante o manejo das lavouras, resultando em reduções na produtividade e na qualidade da produção e portanto demandando métodos mais precisos, como o desenvolvimento de sistemas para aplicações localizadas de insumos agrícolas (fertilizantes, herbicidas, fungicidas) através do desenvolvimento de novas tecnologias de AP (11).

O interesse dos produtores em sistemas de pulverização localizada de herbicidas tem crescido à medida em que esses equipamentos surgem como tecnologias eficientes, sustentáveis e rentáveis (12). A maioria dos sistemas disponíveis no mercado utilizam detectores de clorofila para localizar plantas daninhas e foram desenvolvidos para aplicações específicas de herbicidas pré-emergência da cultura, ou seja, antes do processo de emergência das plantas da cultura em campo. Devido às características deste método de detecção empregado, esses sistemas não são capazes de diferenciar com eficácia plantas da lavoura entre plantas daninhas em aplicações de herbicidas pós-emergência da cultura, uma vez que todas as plantas possuem clorofila em suas folhas (13). Nesse caso, as companhias responsáveis pelo desenvolvimento e comercialização de detectores de clorofila para instalação na barra de pulverização de tratores pulverizadores alegam que calibrações em tempo real baseadas na diferença de tamanho entre plantas daninhas e da lavoura são mais do que suficientes para pulverizar herbicidas apenas nas plantas daninhas detectadas. Entretanto, para atingir máxima acurácia no reconhecimento de plantas daninhas e no controle após a emergência da cultura no campo, métodos mais robustos devem ser empregados. A Inteligência Artificial (IA) e, em particular, os avanços em um de seus campos de estudo conhecido como Visão Computacional, emergiram nos últimos anos como abordagens promissoras para a detecção e reconhecimento de plantas daninhas para posterior aplicação localizada de herbicidas (14).

De uma maneira simples, a Visão Computacional é como os computadores enxergam e entendem o mundo real. Essa subárea da IA inclui a captura, pré-processamento e extração de informações de imagens, e tem mostrado bons resultados na detecção de objetos e nas tarefas de Aprendizado de Máquina (15). O algoritmo estado da arte para detecção de objetos conhecido como YOLO* tem sido amplamente utilizado para detecção de plantas daninhas em condições de luz natural. O YOLO é um algoritmo de rede neural que realiza duas tarefas (detecção e classificação) em apenas um passo, possibilitando a detecção de objetos em tempo real com altas acurácia e velocidade (baixo tempo de inferência), sendo muito popular em aplicações de detecção de pedestres (16), parquímetros e monitoramento de animais (17). Para o reconhecimento de plantas daninhas, o algoritmo YOLO e suas diferentes versões disponíveis (v3, v4, v5...) têm sido utilizadas, como alguns exemplos, para detecção em tempo real de plantas daninhas da espécie *Solanum rostratum* Dunal (18), detecção de plantas daninhas em plantações de alface (19), cenoura (20) e gergelim (21) e detecção de plantas da espécie *Amaranthus palmeri* S. Watson em lavouras de soja (22).

Atualmente, poucas companhias comercializam soluções para detecções de plantas daninhas em tempo real utilizando câmeras coloridas instaladas na barra de pulverização de tratores para aplicações de pulverização localizada de herbicidas (23). A empresa John

* Do inglês, *You Only Look Once*

Deere, após a aquisição da empresa Blue River Technologies, foi a pioneira através do lançamento da solução See & Spray[®], uma tecnologia capaz de capturar imagens de plantas daninhas no campo e ativar as pontas de pulverização para aplicar herbicidas apenas nas plantas detectadas. Esse tipo de aplicação de Visão Computacional requer uma grande quantidade de dados, nesse caso, um grande banco de imagens contendo milhares de imagens coloridas de plantas daninhas para treinar um algoritmo de IA para tarefas de detecção e classificação (24).

Como uma variável promissora a ser explorada no campo de estudo de detecção de plantas daninhas por imageamento, imagens multiespectrais de plantas têm chamado a atenção de diversos autores recentemente (19, 25). O conceito principal de imagens multiespectrais pode ser resumido a imagens do mesmo objeto (ou área) capturadas em diferentes comprimentos de onda, e sua relevância para a AP tem sido apontada desde há muito tempo, por exemplo, com técnicas de sensoriamento remoto para mapeamento de áreas de produtividade (26), mapeamento de plantas daninhas (27) e densidade de plantas com câmeras multiespectrais instaladas em UAV[†] (28), detecção e diagnóstico de doenças em plantas (29), entre outros.

Neste trabalho, é descrito o uso de imagens multiespectrais para detecção de plantas daninhas e plantas da lavoura utilizando o algoritmo YOLO em ambientes com iluminação artificial e natural. Três espécies importantes de plantas daninhas foram utilizadas (*Amaranthus viridis* L., *Bidens pilosa* L. e *Digitaria horizontalis* Willd.) e a cultura da soja (*Glycine max* L.) foi escolhida como planta da lavoura devido à sua importância econômica na agricultura brasileira. As plantas foram crescidas em uma estufa *indoor* e um banco de imagens contendo 8.020 imagens foi construído na primeira abordagem do projeto em iluminação artificial utilizando um sistema de câmera multiespectral contendo cinco câmeras: RGB, verde (G), vermelha (R), infravermelho próximo (NIR) e infravermelho (IR). Na segunda abordagem do projeto em iluminação artificial, foi construído um banco de imagens com dez bandas espectrais utilizando um sistema de roda de filtros, imagens NDVI e duas configurações de imagens RGB, totalizando 17.420 imagens. Além disso, foi construído um banco de imagens contendo 20.000 imagens em iluminação natural utilizando um equipamento de campo com uma câmera RGB e uma câmera NIR em uma lavoura de soja na região de São Carlos - SP na Safra 2022/23.

[†] Do inglês, *Unmanned Aerial Vehicle*

1.1 Motivação

Com os crescentes problemas relacionados ao manejo convencional de plantas daninhas no campo através da aplicação de herbicidas em área total e o avanço de tecnologias na área da Agricultura de Precisão, faz-se necessária a busca por novas metodologias e o desenvolvimento de novas técnicas e/ou equipamentos capazes de realizar aplicações de defensivos agrícolas de maneira localizada, considerando a desuniformidade das lavouras e aplicando substâncias químicas apenas nos organismos desejados. Apesar da disponibilidade de alguns equipamentos de pulverização localizada no mercado, é importante o desenvolvimento de tecnologias que sejam capazes de reconhecer plantas da lavoura e diferenciá-las de plantas daninhas presentes em campo com acurácia elevada em aplicações de herbicida após o plantio, evitando que as plantas da lavoura entrem em contato com esses defensivos e aumentando a efetividade e sustentabilidade do processo. Nesse último caso, a incorporação de imagens multiespectrais para o imageamento de plantas na lavoura em conjunto com os avanços recentes na área de Inteligência Artificial podem desempenhar um papel importante no processo de detecção e classificação de plantas daninhas. Devido à importância econômica da cultura da soja para o Brasil, considerado o maior produtor da leguminosa desde a Safra 2019/20, essa cultura foi escolhida como planta da lavoura neste projeto.

1.2 Estrutura do trabalho


Este trabalho está organizado como segue: no Capítulo 2 é apresentada uma revisão da bibliografia, apresentado os principais conceitos e resultados relacionados ao tema; no Capítulo 3 é apresentada a metodologia e a discussão dos resultados obtidos em ambiente com iluminação artificial; no Capítulo 4 é apresentada a metodologia e a discussão dos resultados obtidos em ambiente com iluminação natural; no Capítulo 5 são apresentados os avanços tecnológicos do projeto na empresa Agrio Tecnologia e no Capítulo 6 são apresentadas as conclusões do projeto de pesquisa e suas perspectivas futuras. Por fim, um anexo do pôster e do prêmio conquistado pela apresentação de parte deste trabalho no congresso SPIE Conference on Advanced Photonics 2023 foi disponibilizado após as referências.

2 REVISÃO BIBLIOGRÁFICA


2.1 Importância do Agronegócio para o Brasil

O Brasil passou por uma grande transformação agrícola nos últimos 40 anos, deixando uma posição de importador de alimentos para a posição de um dos maiores provedores mundiais (30). Alguns dos grandes causadores dessa mudança foram os aumentos significativos na produtividade de grãos e na criação bovina, responsáveis por movimentar grandes parcelas do Produto Interno Bruto (PIB) (31). De acordo com dados do Centro de Estudos Avançados em Economia Aplicada (CEPEA) da Escola Superior de Agricultura Luiz de Queiroz (ESALQ-USP) em parceria com a Confederação da Agricultura e Pecuária do Brasil (CNA), o PIB do agronegócio brasileiro recuou 4,22% em 2022 frente aos valores recordes atingidos em 2020 e 2021 devido à uma forte alta dos custos dos insumos relacionados ao setor (32). Entretanto, ainda de acordo com essas organizações, o PIB do agronegócio representou cerca de 24,8% do PIB brasileiro total no ano de 2022, demonstrando a importância do agronegócio para o país.

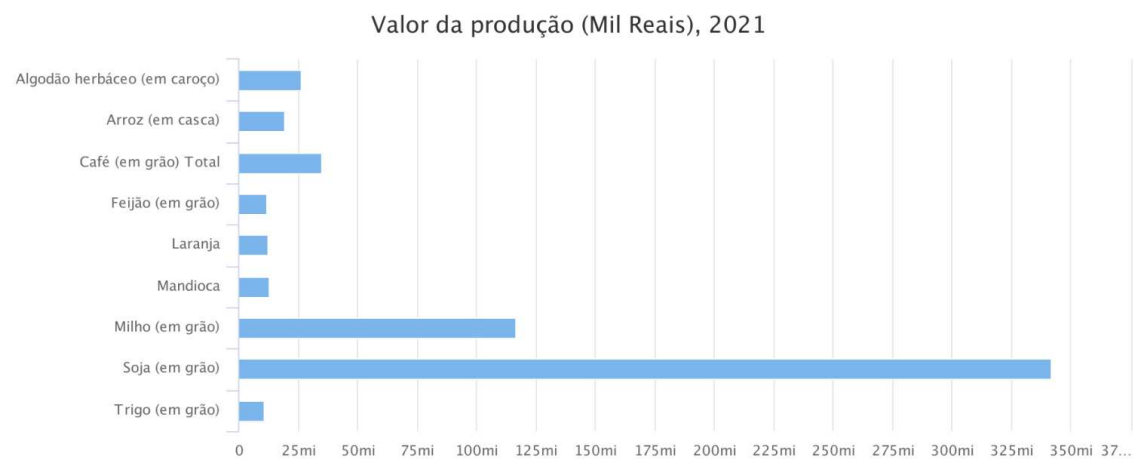
O levantamento da produção agrícola responsável por obter informações sobre área plantada, área colhida, quantidade produzida, rendimento médio e preço médio pago ao produtor é feito pelo Instituto Brasileiro de Geografia e Estatística (IBGE) através da pesquisa Produção Agrícola Municipal (PAM). De acordo com os dados levantados na última pesquisa, realizada no ano de 2021, a maior área colhida foi a da cultura da soja, com 39 milhões de hectares colhidos, seguida do milho com 19 milhões de hectares colhidos e do trigo com 2,7 milhões de hectares (Figura 1a) (33). O mesmo padrão se repete quando analisada a quantidade produzida, com a soja em grãos liderando com uma produção de 134 milhões de toneladas, seguida do milho em segundo lugar com uma produção de 88 milhões de toneladas (Figura 1b). A soma da produção agrícola de todas as culturas analisadas no gráfico da Figura 1b resulta em um valor de aproximadamente 288 milhões de toneladas produzidas. Por fim, o gráfico da Figura 1c ilustra o valor da produção das culturas analisadas, onde é possível observar que a soja e o milho em grãos apresentaram os maiores valores de produção, totalizando 341 e 116 bilhões de reais, respectivamente. Somando o valor de produção de todas as culturas observadas na Figura 1c, o valor de produção obtido no ano de 2021 foi de aproximadamente 587 bilhões de reais. A quantidade de alimentos produzida pelo Brasil e o valor gerado pela comercialização da produção agrícola, assim como observado na Figura 1, evidenciam a importância do país como um grande produtor e fornecedor mundial de alimentos. Como destaque, o aumento na produtividade de grãos demonstra a relevância de culturas como a da soja e do milho e posicionam o Brasil como um dos maiores produtores destas *commodities*.



(a)



(b)



(c)

Figura 1 – Área colhida, quantidade produzida e valor da produção de acordo com dados da PAM em 2021. a) Área colhida (hectares); b) Quantidade produzida (toneladas); c) Valor da produção (mil reais)

Fonte: PAM (33).

Outro setor de extrema importância para o agronegócio brasileiro é o setor das agroindústrias. As agroindústrias são indústrias responsáveis pela transformação das matérias-primas provenientes da agropecuária como, por exemplo, a produção de papel, tecidos, açúcar, biocombustíveis, entre outros. Mesmo com uma ligeira queda de 1,33% no crescimento das agroindústrias no ano de 2022, é possível observar na Figura 2 que as indústrias do café, produtos alimentares, açúcar, celulose e papel, óleo vegetais, entre outros, apresentaram crescimento do faturamento (34). Mais especificamente, a indústria de óleos vegetais apresentou aumento na produção anual em 1,90% e no faturamento em 8,06%, impulsionada principalmente pelo aumento na demanda por óleo de soja no Brasil e nos Estados Unidos. Após uma diminuição de 7,10% na produção, a indústria do café apresentou aumento de 23,25% no faturamento. Outra agroindústria importante é a de produção de biocombustíveis como o etanol, por exemplo, cuja produção aumentou 4,22% no ano de 2022 mesmo com o fato de que o crescimento do faturamento não acompanhou as taxas dos custos industriais, como os preços das matérias-primas, custos de energia e custos logísticos, por exemplo.

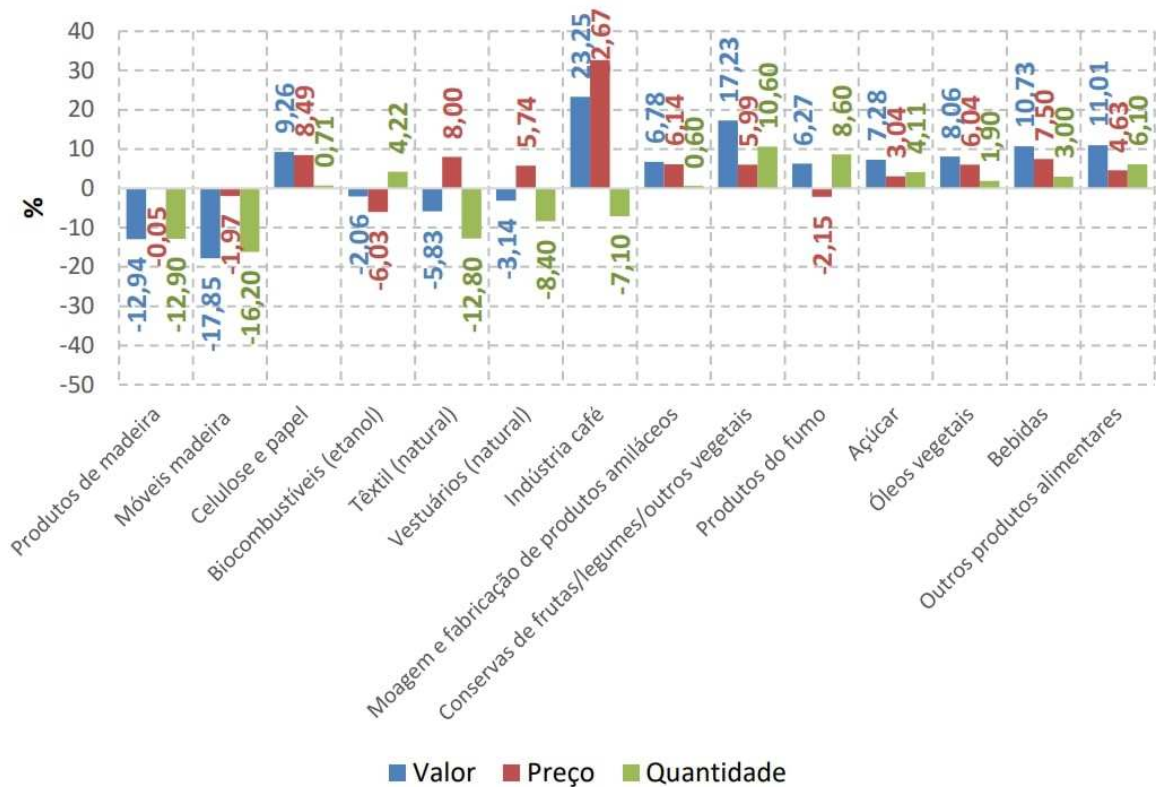


Figura 2 – Variação anual do volume, preço em reais e faturamento das agroindústrias de base agrícola.

Fonte: CEPEA (34).

2.1.1 Soja (*Glycine max* L. Merrill)

A soja (*Glycine max* (L) Merrill) é uma planta herbácea que foi introduzida no Brasil em 1882, mais especificamente na Bahia, mas que se destacou mundialmente em valores de produção apenas no ano de 1949, quando a produção brasileira do grão atingiu 25 mil toneladas (35). Por apresentar uma quantidade elevada de proteínas, carboidratos e teor de óleo (36), a soja passou a ser uma leguminosa muito indicada para alimentação humana e animal, assim como para a produção de óleo de soja ao redor do mundo (37). As plantas de soja apresentam folhas trifolioladas (com exceção do primeiro par de folhas unifoliolado), raiz principal com ramificações de raízes secundárias, desenvolvimento de vagens, flores de fecundação autógama e diferentes hábitos de crescimento de acordo com a cultivar (35). Seu desenvolvimento é dividido nas fases vegetativa (V) e reprodutiva (R), sendo a primeira responsável pela emergência das plântulas, crescimento e formação dos nós vegetativos (38).

De acordo com dados do relatório publicado pelo CEPEA em 2023 (39), a cadeia da soja e do biodiesel gerou um montante de 673 bilhões de reais em 2022, representando 27% do PIB do agronegócio brasileiro e 7% do PIB brasileiro total. Além disso, o setor representou 10,8% dos empregos no agronegócio e contribuiu com 38% das exportações, gerando uma receita de 63,1 bilhões de dólares, demonstrando a importância econômica da cultura da soja para o país. Ainda de acordo com essa organização, entre os anos de 2010 e 2022, os crescimento no PIB volume da cadeia de soja e biodiesel foram de 58%, demonstrando o potencial de crescimento econômico gerado pela cultura nas últimas décadas devido aos incrementos em produtividade gerados por novas cultivares e estratégias de manejo das lavouras.

A previsão para a produção de grãos de soja na Safra 2022/23 divulgada pela Companhia Nacional de Abastecimento (CONAB) foi de 155,7 milhões de toneladas, valor motivado principalmente pelos aumentos na produtividade do grão (40). Dados divulgados pelos relatórios mensais *World Agricultural Production* do Departamento de Agricultura dos Estados Unidos (USDA)* posicionam o Brasil como o maior produtor de soja do mundo desde a Safra 2019/20 (41), quando a produção de soja no país atingiu o patamar recorde de 124 milhões de toneladas do grão, e estimam que a produção da oleaginosa seja de 163 milhões de toneladas na Safra 2023/24 (42).

A Tabela 1 resume a produção de soja em grãos nas últimas safras, assim como faz uma projeção da produção na Safra 2023/24 para os principais produtores de soja no mundo. De acordo com a projeção realizada pelo USDA, é previsto que a Safra 2023/24 apresente um aumento de 4,49% na produção de soja no Brasil quando comparada com a safra anterior. Em segundo lugar na lista de maiores produtores do grão destaca-se os Estados Unidos, cujo aumento de produção estimado para a próxima safra é de 5,47%. No

* Do inglês, *United States Department of Agriculture*.

geral, o aumento da produção de soja em milhões de toneladas aumenta consecutivamente à cada safra, com estimativas de crescimento da produção global em 11,13% no próximo ano.

Tabela 1 – Produção de soja (em milhões de toneladas) das safras 2021/22, 2022/23 e projeção para a safra 23/24 dos maiores produtores de soja do mundo.

Países	Safra 2021/22	Safra 2022/23	Safra 2023/24 (Projeção)	Variação - 2023/24 e 2022/23
Mundo	359,91	369,57	410,70	11,13%
Brasil	130,50	156,00	163,00	4,49%
Estados Unidos	121,53	116,38	122,74	5,47%
Argentina	43,90	25,00	48,00	92,00%
China	16,40	20,28	20,50	1,08%
Paraguai	4,18	8,80	10,00	13,64%

Fonte: Adaptada de USDA (42).

Devido à importância econômica da soja para o país, faz-se necessário o estudo e desenvolvimento de novas tecnologias vislumbrando o aumento e otimização da produtividade da cultura em campo sem necessariamente expandir as áreas de plantio, seja através do desenvolvimento de novas cultivares, nutrição adequada de plantas ou do desenvolvimento de tecnologias voltadas para a área de Agricultura de Precisão visando a otimização de insumos e recursos através do manejo localizado das lavouras.

2.2 Agricultura de Precisão

A Agricultura de Precisão é definida como uma técnica de manejo que considera tanto as variabilidades espaciais quanto temporais, permitindo ao produtor o uso racional dos insumos que envolvem a cadeia agrícola, como fertilizantes, pesticidas e até mesmo a água (1). Como um sistema inteligente, a AP depende do uso de dados como, por exemplo, aqueles obtidos através de técnicas de georreferenciamento e de mapas de colheita que resultam em mapas de produtividade das lavouras. De acordo com Oliveira *et al.*, o processo de adoção de técnicas de AP divide-se em quatro etapas: a) o monitoramento intensivo; b) a geração e integração de mapas; c) a sistematização da modelagem agrônômica; e d) a aplicação diferenciada de insumos, levando em conta variáveis como local, momento e quantidades necessárias (43).

A AP lida com uma enorme quantidade de dados, tanto aqueles coletados por equipamentos e tecnologias de monitoramento, quanto aqueles gerados durante as etapas de análises desejadas pelo produtor. Em seguida, esse grande volume de dados é utilizado para a criação de modelagens matemáticas e computacionais que melhor descrevam o sistema agrônômico desejado. Por fim, todas as informações coletadas e geradas nas etapas anteriores são utilizadas para as etapas de tomada de decisão como, por exemplo, a aplicação de fertilizantes apenas em áreas cujo solo apresenta deficiência em determinados nutrientes. A integração de todas as etapas supracitadas permite o gerenciamento localizado

dos cultivos e a otimização dos gastos, fornecendo segurança para o agricultor durante suas tomadas de decisão (3).

Como exemplo de dados utilizados por ferramentas de AP, as imagens das plantações, coletadas em sua grande maioria por *drones*, representam uma parcela significativa das pesquisas e do desenvolvimento de equipamentos no setor empresarial (44). Por meio de técnicas de sensoriamento remoto, essas imagens permitem inferir, por exemplo, detecção de falhas em linhas de plantio e a presença de plantas de uma determinada espécie em áreas desejadas (45). Além disso, o sensoriamento remoto desempenha um papel fundamental durante o mapeamento por georreferenciamento, gerando estimativas de parâmetros biológicos da vegetação baseados em modelos físicos e não requerendo a intervenção no ambiente estudado. Entretanto, a tecnologia de *drones* possui algumas desvantagens, como sua cobertura espacial limitada e a demanda por operadores especializados (46).

2.3 Imagens multiespectrais

Uma imagem digital pode ser definida como uma função $f(x, y)$ em que tanto o domínio quanto a imagem são valores finitos e discretos. As variáveis x e y são coordenadas espaciais no plano cartesiano, enquanto a amplitude de f no ponto (x, y) é chamada de *intensidade* ou *nível de cinza* da imagem nesse ponto. Cada par (x, y) é denominado de *pixel* e este é definido como o elemento básico de uma imagem (47). Em uma câmera digital convencional com sensor do tipo CCD[†] ou CMOS[‡], a matriz de *pixels* que compõe o sensor é coberta por um arranjo de filtros chamados filtros de Bayer (Figura 3), com seções do tamanho dos *pixels* e que transmitem apenas a cor vermelha (um *subpixel*), azul (um *subpixel*) e verde (dois *subpixels*) (48). Dessa forma, a imagem obtida pelo sensor é um mosaico das três cores do modelo RGB (*Red, Green, Blue*). Em seguida, um algoritmo capaz de estimar a cor ideal para cada *pixel* baseado nas intensidades dos *pixels* vizinhos é utilizado, formando a imagem colorida que posteriormente pode ser observada em uma tela digital, por exemplo (49).




Figura 3 – Filtro de Bayer utilizado nos sensores CCD e CMOS, permitindo a transmissão das cores vermelho (R), verde (G) e azul (B) e posterior formação da imagem colorida por *softwares*.

Fonte: IDS IMAGING DEVELOPMENT SYSTEMS (50).

[†] Do inglês, *Charged Coupled Device*

[‡] Do inglês, *Complementary Metal Oxide Semiconductor*

Os sensores CMOS receberam mais atenção na última década devido à sua performance mais promissora quando comparada com a dos sensores CCD. Algumas vantagens desse tipo de sensor é o baixo consumo de energia, funcionamento em baixa voltagem, custo inferior comparado ao CCD e a possibilidade/flexibilidade em adquirir imagens em um período curto de tempo (51). De maneira análoga à construção destes dispositivos, uma imagem multiespectral pode ser obtida posicionando diferentes filtros em frente o sistema óptico de um sensor CMOS monocromático, como por exemplo filtros que permitem a transmissão dos comprimentos de onda do infravermelho ou do ultravioleta, dependendo da aplicação desejada. Para a AP, as imagens multiespectrais obtidas de um sensor com filtros que permitem a transmissão do infravermelho são importantes para a identificação de estágios vegetativos, sanidade das plantas e até mesmo para diferenciar as plantas do solo, uma vez que suas assinaturas espectrais (Figura 4) apresentam refletâncias diferentes para o infravermelho (52).

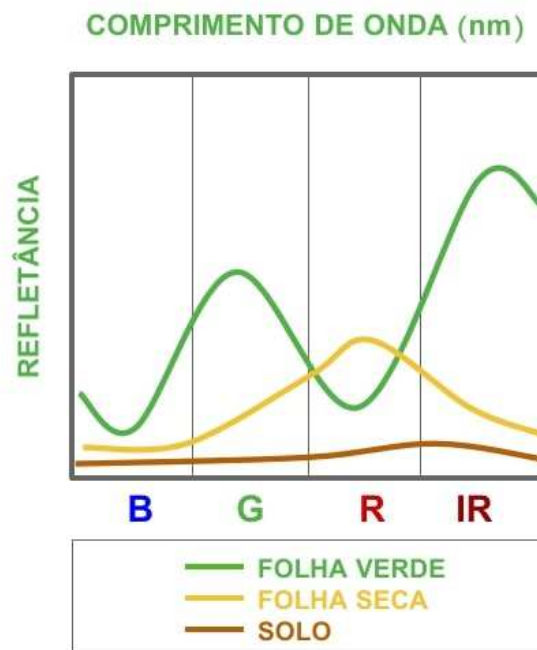


Figura 4 – Assinaturas espectrais nas bandas do azul (B), verde (G), vermelho (R) e infravermelho (IR) para uma folha verde, uma folha seca e amostra de solo com pouca matéria orgânica.

Fonte: Adaptada de INPE (52).

De acordo com a Figura 4, folhas saudáveis e de coloração verde apresentam alta refletância na banda correspondente à cor verde, baixa refletância no vermelho devido à alta absorção dessa banda pela clorofila e alta refletância no infravermelho próximo (760 nm) devido às características das estruturas que compõem o mesofilo das folhas (53). Por sua vez, folhas secas possuem refletâncias maiores nas bandas do vermelho devido à degradação da clorofila, e menores no infravermelho próximo devido à alteração nos

aspectos fisiológicos e bioquímicos das folhas que são diretamente afetados pelo conteúdo de água na estrutura celular superficial (54). Por fim, uma amostra de solo com pouca matéria orgânica apresenta baixas refletâncias para as bandas azul, verde, vermelho e infravermelho próximo, o que permite distinguir com facilidade áreas não plantadas de áreas plantadas e identificar possíveis falhas nas linhas de plantio.

Juntas, as informações obtidas através do uso de bandas multiespectrais para a captura de imagens de plantações permitem a aquisição de dados importantes para etapas posteriores de reconhecimento de padrões e classificações por métodos de Inteligência Artificial, contribuindo para o desenvolvimento da Agricultura 4.0. Entretanto, uma abordagem mais individualizada para as plantas visando o manejo localizado faz-se necessária e, para isto, técnicas de Visão Computacional podem ser aplicadas.

2.4 Visão Computacional

A Visão Computacional é uma área de estudo que tem crescido exponencialmente nos últimos anos. De acordo com Sá Junior (55), a Visão Computacional não se refere apenas ao ato de captar imagens, mas sim de melhorá-las através de etapas como a remoção de ruídos, mudanças no contraste, segmentações de áreas de interesse, extração de informações importantes e por fim, relacioná-las com outras imagens vistas anteriormente. Um sistema de Visão Computacional é constituído por diferentes etapas, como aquelas representadas na Figura 5, que constituem seu *pipeline* clássico. Neste diagrama, o processo de **aquisição** é responsável pela captação da imagem; o **processamento de imagens** pelas melhorias realizadas visando tornar as imagens mais adequadas para as próximas etapas; a **segmentação** para destacar as regiões de interesse na imagem; a **extração de características** para selecionar um conjunto de características que melhor representa cada uma das classes dos objetos a serem detectados; e o **reconhecimento de padrões**, através do uso de algoritmos de aprendizado profundo[§], para classificar ou agrupar as imagens baseadas em suas características (55).




Figura 5 – *Pipeline* de um sistema de Visão Computacional clássico.

Fonte: Adaptada de BACKES; SÁ JUNIOR (55).

[§] Do inglês, *deep learning*

2.4.1 Redes neurais convolucionais

Recentemente, algoritmos de aprendizado profundo têm sido amplamente utilizados na agricultura, por exemplo, para detecção de diversos tipos de doenças com manifestação nas folhas (56) e para classificação de inúmeras espécies de plantas daninhas presentes em plantações, ambas através de redes neurais convolucionais (57). Redes neurais convolucionais (CNN)[¶] utilizam camadas com filtros convolucionais que são aplicados nas imagens para extração de *features* e têm demonstrado bom desempenho em tarefas de classificação e reconhecimento de padrões (58). De maneira simplificada, uma CNN possui etapas de convolução, não linearidade, *pooling* e classificação como operações fundamentais, e seu funcionamento ocorre através da aplicação de filtros convolucionais na imagem de entrada (Figura 6). Após a passagem dos filtros nos *pixels* da imagem, são geradas matrizes chamadas mapas de ativação. Em seguida, os resultados desta primeira etapa são passados para camadas com etapas de não linearidade para permitir que a rede aprenda *features* de forma não-linear, e camadas com etapas de *pooling* para reduzir as dimensões dos mapas de ativação mantendo apenas as características mais relevantes (59).

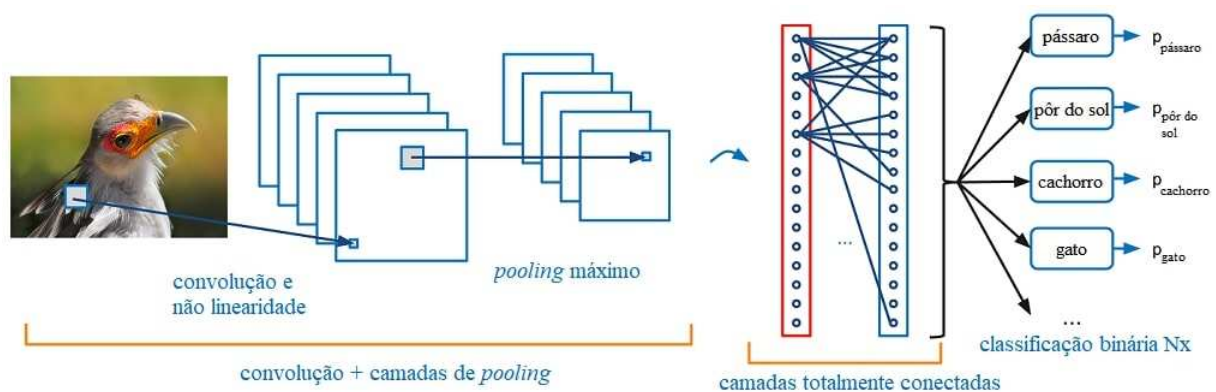


Figura 6 – Exemplo da arquitetura de uma rede neural convolucional.

Fonte: Adaptada de DESHPAND (59).

Uma vez detectadas *features* de alto nível nos mapas de ativação das etapas anteriores, camadas totalmente conectadas presentes no final da rede transformam a imagem codificada em um vetor de dimensão N , onde N é o número de classes existentes para classificação pela rede. Cada número presente neste vetor representa a probabilidade ρ da imagem pertencer a uma determinada classe. Os valores dos filtros e pesos dessas camadas são aprendidos durante o treinamento a partir da técnica de *backpropagation*, responsável por calcular o gradiente destes valores em relação a uma função de erro e atualizá-los até que o erro seja mínimo. No caso da Figura 6, o vetor gerado apresenta as probabilidades da imagem inicial ser um pássaro, um pôr-do-sol, um cachorro, um

[¶] Do inglês, *Convolutional Neural Networks*

gato, entre outras classes. Caso o algoritmo classifique a imagem inicial como um pássaro, valores mais altos seriam observados para os mapas de ativação que representam *features* de alto nível como bico ou asas, por exemplo. De maneira resumida, as camadas totalmente conectadas analisam quais *features* de alto nível se correlacionam mais fortemente com uma classe específica e, através de pesos específicos que podem ser ajustados, realizam o produto destes com a camada anterior visando obter as probabilidades corretas para as diferentes classes (59).

2.4.2 Algoritmos de detecção e classificação

A detecção de objetos em imagens é uma tarefa desafiadora no campo da Visão Computacional, uma vez que envolve a combinação das tarefas de localização e classificação de múltiplos objetos em diferentes escalas (60). Diversos avanços significativos na área foram obtidos nos últimos anos, principalmente após a implementação de redes neurais convolucionais na etapa de classificação da detecção de objetos, uma alternativa com resultados mais promissores quando comparada com os métodos de engenharia de *features* tradicionalmente utilizados (61). A Figura 7 ilustra um exemplo da aplicação de um algoritmo de detecção e classificação para detectar vacas em campo. Ao fim do processo de detecção, cada objeto presente na imagem é englobado dentro de um retângulo de coordenadas de imagem definidas chamado *bounding box*, e à cada *bounding box* é atribuída uma classe e uma probabilidade do objeto em estudo pertencer à classe em questão (62).




Figura 7 – Exemplo da aplicação de um algoritmo de detecção e classificação na detecção de vacas em campo.

Fonte: ZHAI (62)

No geral, algoritmos de detecção de objetos possuem uma imagem como *input*, um seletor de regiões, um extrator de características e um classificador (Figura 8). O seletor de regiões utiliza um algoritmo chamado *sliding window* para percorrer a imagem da esquerda para a direita, de cima para baixo, utilizando janelas de tamanhos diferentes e com objetivo

de fornecer sub-imagens para que o classificador determine se existe ou não a presença de um objeto em estudo. O extrator de características utiliza algoritmos como o HOG e o SIFT, por exemplo, para extrair características importantes dos blocos de imagens gerados na etapa anterior. Por fim, um classificador utiliza algoritmos de aprendizado de máquina, como o SVM por exemplo, para categorizar o objeto em uma determinada classe. Ao longo do processo de detecção, o mesmo objeto (ou parte dele) é detectado diversas vezes, gerando diversas *bounding boxes*. Para resolver este problema de múltiplas detecções de um mesmo objeto, um algoritmo chamado *non-maximum supression* é utilizado para suprimir detecções sobrepostas, gerando no fim do processo uma única *bounding box* para cada objeto detectado (63).




Figura 8 – Arquitetura básica de um algoritmo de detecção de objetos tradicional.

Fonte: Adaptada de XIAO (61).

De acordo com a literatura, existem duas arquiteturas comumente utilizadas em algoritmos detectores: os algoritmos com detecção em dois estágios e os algoritmos com detecção em um estágio (60,61). Os algoritmos com detecção em dois estágios, como o R-CNN e o Fast R-CNN, por exemplo, necessitam de métodos heurísticos como o *selective search* para gerar regiões onde posteriormente serão feitas as classificações (64). Já os algoritmos com detecção em um estágio, como o SSD e o YOLO, realizam a extração de *features*, classificação dos alvos e regressão da posição na rede convolucional inteira, assim obtendo a posição e a classe do alvo em apenas uma etapa (65). Enquanto no primeiro modelo de arquitetura a acurácia é mais elevada, no segundo modelo a velocidade de detecção/classificação apresenta melhoras significativas (66), tornando-o ideal para aplicações em tempo real.

Para algoritmos de detecção e classificação, duas métricas são importantes: as métricas IoU^{||} e mAP^{**} (22). A métrica IoU avalia a concordância espacial entre a *bounding box* predita pelo modelo treinado (*pd*) e aquela fornecida para o treinamento, a *ground truth* (*gt*), varia de zero a um e necessita de um *threshold* que posteriormente é utilizado para determinar se uma detecção é válida ou não. Para calcular essa métrica, é calculada a área de intersecção entre *gt* e *pd* dividida pela área de união dessas duas máscaras (Figura 10), de forma com que se o valor obtido for zero não há sobreposição entre o rótulo e a detecção, enquanto que se o valor for um tem-se uma sobreposição perfeita.

^{||} Do inglês, *Intersection over Union*

^{**} Do inglês, *mean Average Precision*




Figura 9 – Ilustração da métrica *Intersection over Union* (IoU).

Fonte: Adaptada de PADILLA (67).

Para um determinado *threshold* α , por exemplo, casos verdadeiro positivos (VP) representam detecções nas quais tem-se $\text{IoU} \geq \alpha$ e casos falso positivos (FP) representam detecções nas quais $\text{IoU} < \alpha$. Casos falso negativos (FN) representam máscaras *gt* que não foram detectadas e casos verdadeiro negativos (VN) representam todas as possíveis detecções erradas que não foram detectadas e, portanto, não apresentam relevância para algoritmos de detecção. As métricas *Precision* e *Recall*, comumente utilizadas para avaliação dos resultados obtidos durante a etapa de teste de algoritmos de IA, podem ser calculadas utilizando as Equações 2.1 e representam, respectivamente, o número de predições corretas entre todas as predições feitas e a habilidade do modelo em detectar objetos presentes no *ground truth* (67).

$$\textit{Precision} = \frac{VP}{VP + FP} \quad \text{e} \quad \textit{Recall} = \frac{VP}{VP + FN} \quad (2.1)$$

Aumentando o *threshold* do valor de confiança fará com que mais detecções de objetos sejam perdidas pelo modelo (mais FNs e baixo *Recall*), enquanto que diminuindo o *threshold* do valor de confiança gerará mais FPs (alto *Recall* e baixa *Precision*). Para equilibrar as métricas *Precision* e *Recall*, a curva *Precision-Recall* representa pares correspondentes dessas métricas em valores diferentes de confiança. Um modelo de detecção e classificação é considerado bom quando os valores de *Precision* e *Recall* se mantêm altos mesmo com as variações dos valores de confiança. Para entender a métrica mAP, é preciso entender o significado de $\text{AP}^{\dagger\dagger}$. A métrica AP é definida como a área abaixo de uma curva *Precision-Recall* avaliada em um *threshold* α e é calculada individualmente para cada classe. Por fim, a métrica mAP é definida como a média de todos os valores de AP calculados no *threshold* α sobre todas as classes, sendo a principal métrica utilizada para avaliar algoritmos de detecção (Equação 2.2).

$$\textit{mAP} (\alpha = 0,5) = \frac{1}{N} \sum_{i=1}^N \textit{AP}_i \quad (2.2)$$

^{††} Do inglês, *Average Precision*

2.4.2.1 Algoritmo YOLO

Assim como citado na Seção 2.4.2, o YOLO é um algoritmo que realiza as etapas de detecção e classificação em apenas uma etapa. A arquitetura do YOLO unificou os componentes separados de algoritmos de detecção em uma única rede neural convolucional capaz de prever as *bounding boxes* e as probabilidades das classes diretamente das imagens em apenas uma avaliação, sendo esta a inspiração para o acrônimo "*You Only Look Once*" que deu nome ao algoritmo (68). Basicamente, o algoritmo divide a imagem de entrada em grades de tamanho $S \times S$ *pixels*, por exemplo. Se o centro de um objeto estiver dentro de uma célula da grade, esta célula será responsável pela detecção deste objeto. Dentro de cada célula da grade, B *bounding boxes* são previstas em conjunto com o valor de confiança de cada, representando o quão confiante o modelo acredita que existe um objeto dentro de cada *bounding box*. Cada célula também prediz um valor C de probabilidades do objeto pertencer à uma das C classes presentes no modelo estudado. Por fim, as predições são codificadas em um tensor de dimensões $S \times S \times (B * 5 + C)$. Para avaliar o algoritmo desenvolvido no banco de imagens PASCAL VOC, os desenvolvedores do YOLO utilizaram $S = 7$, $B = 2$ e $C = 20$ (20 classes presentes no banco de imagens) e obtiveram um tensor de $7 \times 7 \times 30$ na predição final (68).

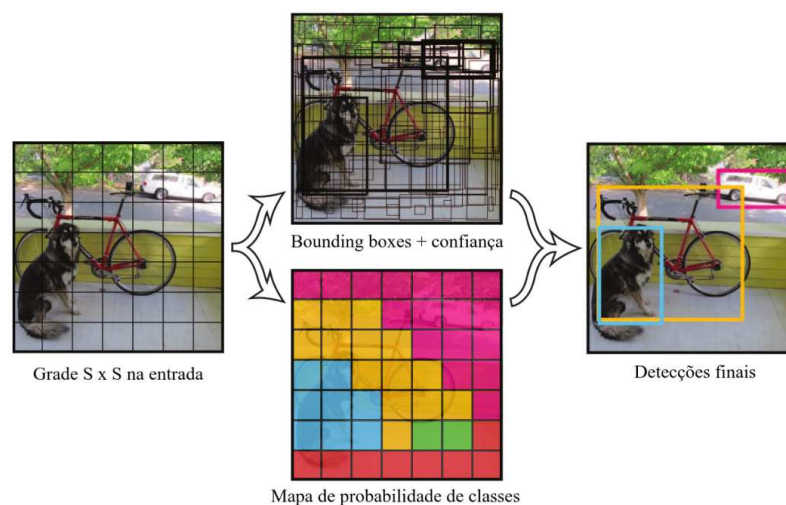


Figura 10 – Modelagem da detecção no algoritmo YOLO. O algoritmo divide a imagem em grades de tamanho $S \times S$ e para cada célula gerada prediz B *bounding boxes* e os respectivos valores de confiança, assim como as classes C previstas.

Fonte: Adaptada de REDMON (68).

Devido à alta velocidade nas etapas de treinamento e detecção e boa acurácia no processo, o algoritmo YOLO tem sido considerado estado-da-arte nas tarefas de detecção e classificação em tempo real (69), sendo constantemente melhorado ao longo dos anos com o surgimento de novas versões (v1, v2, v3, v4, v5...)(70,71). Por essas razões, o YOLO em suas diferentes versões tem sido utilizado para aplicações de detecção de faces (72,73),

detecção de pedestres (74) e automóveis (75), detecção de incêndios florestais (76), entre outras (77).

2.5 Trabalhos relacionados

Wang *et al.*(18) treinou uma rede utilizando o algoritmo YOLO utilizando um banco de imagens RGB com indivíduos de uma espécie de planta daninha chamada *Solanum rostratum* Dunal. Os autores obtiveram o valor de 0,8032 para a métrica *Precision* e 0,8625 para a métrica *Recall* utilizando apenas 413 imagens no treinamento da rede. Hu *et al.*(78) detectou 12 tipos de plantas daninhas encontradas em lavouras de arroz utilizando o algoritmo YOLO treinado com um banco de imagens contendo 27.177 imagens de plantas daninhas em ambiente natural. Os valores de *Precision* e *Recall* obtidos foram 0,97 e 0,81, respectivamente, sugerindo que quanto maior o número de imagens para treinamento, maiores tendem a ser os incrementos na acurácia do modelo. Os autores compararam a performance das versões v3 e v4 do YOLO nas mesmas tarefas e identificaram que o YOLO v4 não é apenas melhor na acurácia média (aumento de 11,6%), mas também apresenta menor tempo total de detecção (diminuição de 11 ms).

Treinando uma rede com o YOLO utilizando um banco contendo 866 imagens RGB de plantas de gergelim (*Sesamum indicum* L.), Chen *et al.*(21) conseguiram valores de *Precision* de 0,869 e 0,907 para as plantas da lavoura e plantas daninhas, respectivamente, e valores de *Recall* de 0,756 e 0,914. O valor de mAP ($\alpha = 0,5$) reportado pelos autores foi de 0,901. Também utilizando o YOLO, Ying *et al.*(20) utilizaram um banco de imagens contendo 750 imagens coletadas em campos de cenoura para realizar detecção de plantas daninhas em diferentes condições climáticas. Os autores obtiveram um valor de 0,8906 para a métrica mAP (0,5) e um tempo médio de inferência de 18,66 ms. Para a detecção de plantas daninhas entre plantas de soja, Barnhart *et al.*(22) utilizaram o algoritmo YOLO e um banco contendo 1.500 imagens RGB de plantas de soja e plantas da espécie *Amaranthus palmeri*, uma das espécies conhecida por ser a mais problemática nos Estados Unidos, e obtiveram o valor de 0,77 para a métrica mAP (0,5).

Osorio *et al.*(19) utilizaram o algoritmo YOLO e imagens multiespectrais para realizar detecção de plantas daninhas em plantações de alface. O banco de imagens dos autores foi construído utilizando um UAV com uma câmera multiespectral contendo as bandas verde, vermelho, vermelho distante e infravermelho próximo. As tarefas de detecção e classificação foram realizadas utilizando imagens NDVI e o resultado para a métrica *Precision* foi 0,91, reforçando a importância de capturar imagens de plantas nos comprimentos de onda do infravermelho. O NDVI é um índice comumente utilizado na área de sensoriamento remoto para AP para destacar a vegetação em uma determinada área e pode ser obtido através da aplicação de operações matemáticas dos valores obtidos pelas diferentes bandas espectrais do sensor. O cálculo do NDVI é realizado através da

diferença entre as refletâncias nas bandas correspondentes ao vermelho e infravermelho próximo (79), de acordo com a Equação 2.3:

$$NDVI = \frac{R_{800} - R_{630}}{R_{800} + R_{630}} \quad (2.3)$$

em que R_{800} e R_{630} são as refletâncias medidas em 800 e 630 nm e correspondem aos comprimentos de onda centrais no espectro visível e na região do infravermelho, respectivamente. A Figura 11 ilustra um exemplo de uma imagem NDVI, elaborada à partir de imagens obtidas pelo satélite Sentinel-2, em que é possível observar a vegetação destacada em uma coloração diferente de áreas não plantadas.




Figura 11 – Imagem NDVI elaborada através de imagens do satélite Sentinel-2.

Fonte: ENGESAT (80).

Também utilizando imagens multiespectrais de UAV, Sa *et al.*(81) construíram um banco de imagens em campos de batata doce utilizando uma câmera Parrot Sequoia[®] contendo quatro bandas e concluíram que as imagens NDVI ajudaram significativamente a distinção de plantas da lavoura e plantas daninhas através da segmentação da vegetação, após atingirem valores de 0,863 (plantas de batata doce) e 0,782 (plantas daninhas) para a métrica AUC^{‡‡} de uma curva *Precision-Recall*. Uma rede neural do tipo *encoder-decoder* foi utilizada por Sa *et al.*(27) para classificação de plantas daninhas utilizando imagens multiespectrais de plantas de batata doce e plantas daninhas. O valor da métrica F1 para a detecção de plantas daninhas, calculada pela média harmônica das métricas *Precision* e *Recall*, foi mantido em aproximadamente 0,8 após a realização das tarefas de treinamento com seis modelos diferentes, uma performance considerada aceitável pelos autores devido às limitações do banco de imagens utilizado. Os autores também destacaram a relevância das imagens NDVI e imagens multiespectrais para a detecção de plantas daninhas entre plantas da lavoura, principalmente no processo de diferenciação da vegetação.

^{‡‡} Do inglês, Area Under the Curve

Focando em uma abordagem mais individualizada como a proposta pelo trabalho, Fawakherji *et al.*(82) utilizaram um robô agrícola BoniRob® (BOSCH, Alemanha) para capturar imagens multiespectrais de plantas daninhas em ambiente natural para treinar diferentes redes e identificaram que o uso de imagens NIR como um quarto canal das imagens RGB aumentou os valores da maioria das métricas avaliadas. Essa é uma forma interessante de incorporar os comprimentos de onda do infravermelho próximo em imagens RGB comuns para aumentar a acurácia nas tarefas de detecção e classificação. Também utilizando o BoniRob® e imagens multiespectrais, Lottes *et al.*(83) desenvolveram a arquitetura de uma rede capaz de utilizar imagens RGB e NIR de caules de plantas como *input* para detectar plantas da lavoura e plantas daninhas. Utilizando esse método, os autores obtiveram um valor de mAP (0,5) de 0,792, demonstrando que essa abordagem pode ser promissora futuramente.

Capturando imagens seguindo uma única direção e com uma altura pré-determinada como a proposta neste trabalho, Olsen *et al.*(84) utilizaram o AutoWeed®, um protótipo para controle de plantas daninhas através da pulverização foliar seletiva, para capturar imagens RGB com câmeras posicionadas um metro acima do solo. Como resultados principais, os autores obtiveram uma acurácia de 95,1% com o modelo Inception v3 e 95,7% com o modelo ResNet-50 CNN utilizando um banco de imagens com diversas espécies de plantas daninhas, e o tempo de inferência para a segunda rede foi de 53,4 ms. Um pulverizador seletivo em pequena escala foi desenvolvido por Partel, Kakarla e Ampatzidis(85) utilizando Visão Computacional para distinguir objetos alvo de não-alvos. O protótipo foi instalado em um veículo ATV junto com 12 pontas de pulverização, um GPS-RTK, três câmeras RGB e uma unidade computacional. Após o treinamento com o algoritmo YOLO utilizando 1.000 imagens coletadas com esse sistema, os autores obtiveram os valores de 0,71 e 0,78 para as métricas *Precision* e *Recall*, respectivamente, para as tarefas de detecção e pulverização localizada de herbicidas em plantas daninhas.

2.6 Manejo convencional de plantas daninhas

Plantas daninhas, no geral, são plantas invasoras, capazes de crescer e se reproduzir em condições adversas, apresentam resistência a pragas e doenças e são capazes de produzir uma grande quantidade de sementes viáveis, assim como mecanismos para dispersão destas sementes em campo (86). Interferem diretamente na produção agrícola pela competição com as plantas da lavoura por recursos naturais, causando quedas expressivas na produtividade que podem chegar até a 30% quando o manejo não é realizado de maneira adequada (86,87). Diversos autores relatam a existência de um período crítico de competição, chamado Período Crítico de Prevenção da Interferência (PCPI), em que deve ser realizado o manejo adequado de plantas daninhas para que as plantas da cultura não sejam prejudicadas a ponto de gerar reduções significativas na produtividade da lavoura (88). No caso da

cultura da soja, por exemplo, os períodos reportados são, em média, de 34 aos 76 dias após a emergência da cultura em campo, dependendo de diversos fatores como as espécies e densidade das plantas daninhas, clima e espaçamento da cultura (89). Os danos causados pelas plantas daninhas influenciam até na colheita, dificultando ou até mesmo impedindo o processo (90), ou reduzindo a qualidade dos grãos através do aumento da umidade destes quando colhidos na presença destas plantas (86).

Uma classificação muito utilizada, mas não inteiramente correta, é a divisão das espécies de plantas daninhas em duas grandes classes: as plantas daninhas de folha estreita e as plantas daninhas de folha larga. As plantas daninhas de folha estreita ou gramíneas são monocotiledôneas, com nervação do tipo uninérvia e paralelinérvia e alguns exemplos são as plantas das espécies *Eleusine indica* ("Capim-pé-de-galinha") e *Digitaria sanguinalis* L. Scop. ("Capim-colchão") (91). As plantas daninhas de folha larga são dicotiledôneas, com limbo foliar largo, com nervação, no geral, do tipo palminérvia, peltinérvia e peninérvia e alguns exemplos são as plantas das espécies *Ipomoea sp* ("Corda-de-viola") e *Bidens pilosa* L. ("Picão-preto") (92). A Figura 12 ilustra um exemplo de uma planta daninha de folha estreita da espécie *Eleusine indica* e uma planta daninha de folha larga da espécie *Amaranthus viridis* L. ("Caruru-de-mancha") (93).




Figura 12 – Classificação de plantas daninhas. a) Exemplo de uma planta daninha de folha estreita; b) Exemplo de uma planta daninha de folha larga.

Fonte: AEGRO (93).

O manejo de plantas daninhas é feito através da aplicação de herbicidas em área total, ou seja, ao longo de toda a extensão do campo. Herbicidas são moléculas químicas sintetizadas em laboratório e comercializadas com objetivo de matar plantas daninhas. De acordo com OLIVEIRA JUNIOR, Constantin e Inoue (94), os herbicidas podem ser classificados de diferentes formas, seja pela seletividade, translocação, época de aplicação, estrutura química ou mecanismo de ação. Com relação a seletividade, herbicidas considerados seletivos são aqueles que impedem o crescimento de plantas daninhas numa cultura sem prejudicar espécies de interesse, enquanto que herbicidas não seletivos, também

chamados de amplo espectro, são capazes de prejudicar seriamente o crescimento da maioria das plantas. Com relação à translocação, herbicidas com ação de contato causam danos apenas nos tecidos das plantas em que entraram em contato com a substância, enquanto que herbicidas com ação sistêmica são translocados pelo floema e/ou xilema para outras partes das plantas, apresentando um efeito crônico. Por fim, uma das classificações mais utilizadas é a com relação ao mecanismo de ação, podendo atuar como inibidores na síntese de parede celular, síntese de lipídeos, síntese de aminoácidos aromáticos, entre diversos outros (94).

Um dos herbicidas mais conhecidos ao redor do mundo é o glifosato. O glifosato (N-(fosfometil)glicina) é um herbicida não-seletivo, sistêmico e pós-emergente que atua, resumidamente, através da inibição da enzima a 5-enolpiruvilshikimate-3-fosfato sintase (EPSPs) e, conseqüentemente, inibição da síntese de aminoácidos aromáticos essenciais para o desenvolvimento das plantas (95). Por ser um herbicida de amplo espectro, o glifosato tem sido amplamente utilizado para o controle de plantas daninhas monocotiledôneas e dicotiledôneas em diversas culturas desde que foi introduzido no mercado. A soja, por exemplo, obteve grandes avanços através do desenvolvimento da tecnologia *RoundUp Ready* pela Monsanto, em que um gene que codifica uma variante da EPSP tolerante à inibição por glifosato foi inserido em uma cultivar da cultura, permitindo a aplicação deste herbicida sem causar grandes danos à lavoura (96). Entretanto, um grande problema que vem sendo reportado pelos especialistas é o desenvolvimento de resistência nas plantas daninhas aos herbicidas amplamente utilizados (97). Estudos comprovam que a aplicação frequente do herbicida glifosato, por exemplo, podem favorecer o desenvolvimento de plantas daninhas resistentes em lavouras com plantas transgênicas (98, 99) e também favorecer a predominância de espécies tolerantes, tornando imprescindível que o controle químico seja realizado de forma adequada para que apresente eficácia (100).

De acordo com o Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA), o Brasil é, em volume, o maior consumidor de agrotóxicos do mundo. Dados do boletim anual de produção, importação, exportação e vendas de agrotóxicos no Brasil publicados por esse instituto reportam que a venda total de produtos formulados como "Químicos e Bioquímicos" no ano de 2021 foi de 719,5 mil toneladas de ingredientes ativos, representando um crescimento de 4,92% das vendas quando comparadas com o ano anterior (101). Apesar de o Brasil não ser o maior consumidor de agrotóxicos quando considerada a área cultivada, ou seja, volume de produto por área, a implementação de tecnologias capazes de realizar o manejo adequado dessas substâncias através de aplicações localizadas (apenas onde de fato existe a ocorrência de plantas daninhas) reduziria drasticamente a utilização das mesmas, contribuindo para que futuramente o país se torne um dos países com menor volume de agrotóxicos por área cultivada, proporcione alimentos de melhor qualidade para o consumidor e reduza enormes gastos com a compra desses insumos por parte do produtor. De acordo com a empresa BlueRiver Technology

(Califórnia, EUA), a aplicação inteligente de herbicidas resulta em uma economia de 90% no gasto com essas substâncias, com uma potencial redução global de aproximadamente 1,13 milhões de toneladas de herbicidas utilizados para o combate dessas plantas (102).

3 DESENVOLVIMENTO EM ILUMINAÇÃO ARTIFICIAL

Neste capítulo, é apresentada a metodologia e os resultados da abordagem do projeto realizada em ambiente com iluminação artificial, e são descritas em detalhes, o laboratório estufa *indoor* utilizado para realização dos experimentos, a metodologia da construção do sistema de trilhos, do experimento de campo para coleta de sementes, do cultivo *indoor* de plantas, da construção dos módulos das câmeras multiespectrais, da construção dos bancos de imagens espectrais, da aplicação do algoritmo YOLO e dos resultados obtidos em duas abordagens diferentes do projeto.

3.1 Metodologia

3.1.1 Laboratório estufa *indoor*

A abordagem em iluminação artificial desenvolvida no projeto foi realizada em um laboratório estufa *indoor* vinculado ao Laboratório de Inovações Optrônicas para Oftalmologia e Agricultura (LIO²A) do Grupo de Óptica do Instituto de Física de São Carlos (USP-IFSC). O laboratório estufa *indoor* possui controle de temperatura e monitoramento de temperatura e umidade através de um sensor BME280, assim como uma bancada com iluminação artificial para o cultivo de plantas e captura de imagens. A iluminação artificial utilizada para o cultivo foi feita utilizando dois plafons de LED brancos, dez lâmpadas *Full Spectrum* comercializadas para o crescimento de plantas e dez lâmpadas halógenas para fornecer luz nos comprimentos de onda do infravermelho, e o espectro resultante (Figura 13) da iluminação foi medido com um espectrômetro Ocean Optics, abrangendo o espectro eletromagnético visível e parte do infravermelho próximo.

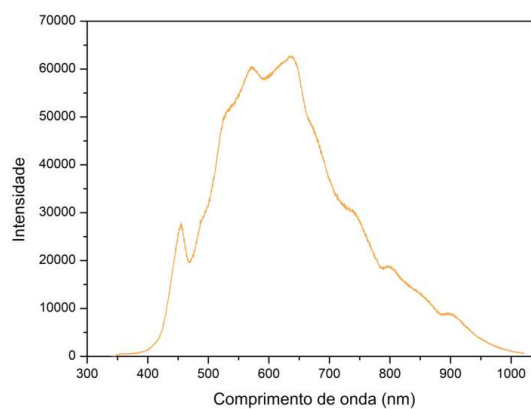


Figura 13 – Espectro da iluminação da bancada de cultivo e de captura de imagens na estufa *indoor*.

Fonte: Elaborada pelo autor.

3.1.2 Sistema de trilhos *v-slot*

Para automatizar o processo de construção do banco de imagens, foi construído um sistema de trilhos para movimentação das câmeras multiespectrais, permitindo que estas percorressem um determinado caminho ao mesmo tempo em que capturavam imagens de plantas crescendo em bandejas com substrato no chão. A estrutura de captura foi construída em madeira (Figura 14a) e o sistema de trilhos foi construído com perfis *v-slot* (20 x 20 mm), um motor de passo NEMA17, polias e correias GT2, um microcontrolador Arduino Nano com uma placa *shield* CNC e peças manufaturadas em uma impressora 3D Ender 3 (Ender, China). O motor NEMA17 e o conjunto Arduino Nano com a placa *shield* CNC foram posicionados na extremidade esquerda da estrutura, uma polia foi posicionada na extremidade direita e a correia GT2 foi responsável por tensionar o sistema, movimentando as câmeras (Figura 14b). A comunicação entre o Arduino e um computador *desktop* foi feita via serial, e o motor de passo recebeu os comandos de movimento através da *shield* CNC.




Figura 14 – Estrutura de cultivo e captura de imagens de plantas. a) Esqueleto da estrutura de madeira construída para comportar o sistema de trilhos; b) Sistema de trilhos *v-slot* com motor de passo NEMA17 e Arduino Nano com placa *shield* CNC instalados.

Fonte: Elaborada pelo autor.

À cada processo de coleta de imagens, o sistema de câmeras percorria o trilho e capturava 46 imagens de plantas de soja e plantas daninhas crescendo nas bandejas no chão. Para evitar a captura de imagens desfocadas ou borradas devido ao movimento do sistema, optou-se pela captura estática em que o sistema de câmeras avançava um passo, capturava as imagens e em seguida avançava mais um passo, repetindo o procedimento até que o final do percurso imposto pelos trilhos.

3.1.3 Experimento de campo para coleta de sementes

Para a replicação em laboratório de plantas daninhas presentes nas lavouras, foi realizado um experimento de campo em uma lavoura de café (Figura 15a) para coleta de sementes de plantas de diferentes espécies, construção de um banco de sementes e posterior cultivo na estufa *indoor*. A estrutura reprodutiva de plantas de algumas espécies foi coletada para a obtenção de sementes, assim como alguns indivíduos de plantas para posterior identificação das espécies em laboratório (Figura 15b). O material coletado foi acondicionado em sacos plásticos e armazenado para o transporte para a cidade de São Carlos - SP.



Figura 15 – Experimento de campo para coleta de sementes de plantas daninhas. a) Lavoura de café na cidade de Jeriquara - SP utilizada para coleta de sementes; b) Exemplo de uma espécie de planta daninha coletada para identificação e coleta de sementes.

Fonte: Elaborada pelo autor.

As plantas coletadas foram levadas para o laboratório e identificadas utilizando a 7ª edição do livro **Manual de Identificação e Controle de Plantas Daninhas** do autor Harry Lorenzi (103). Esse manual facilita muito as etapas de identificação de espécies pois apresenta imagens das plantas em estágio inicial de crescimento, imagens das plantas adultas e das sementes produzidas por elas. Dessa forma, a estrutura completa das plantas e principalmente, folhas e sementes, foram utilizadas para identificação e documentação das espécies obtidas (Figura 16a). Em seguida, as sementes foram coletadas das estruturas reprodutivas das plantas, armazenadas em caixas do tipo *gerbox* e acondicionadas em ambiente com iluminação e temperatura adequada. Na Figura 16, é possível observar dois exemplos de plantas que foram coletadas no experimento de campo e submetidas ao processo de identificação e coleta de sementes. Para documentação, algumas folhas e sementes foram destacadas e posicionadas ao lado da estrutura completa das plantas.



Figura 16 – Processo de identificação de plantas daninhas em laboratório. a) Planta da espécie *Amaranthus viridis* L.; b) Planta da espécie *Digitaria horizontalis* Willd.

Fonte: Elaborada pelo autor.

3.1.4 Cultivo *indoor* de plantas

As sementes obtidas em campo e armazenadas em laboratório foram plantadas em bandejas de cultivo de 64 poços contendo substrato comercial BioPlant[®] e colocadas para crescimento em uma bancada com iluminação artificial da estufa *indoor* com fotoperíodo 12h luz/12h escuro à temperatura de 30 °C (Figura 17). Das espécies cultivadas, as que apresentaram maior número de plantas após o período de germinação foram: *Amaranthus viridis* L. (caruru-de-mancha, Figura 17a), *Bidens pilosa* L. (picão-preto) e *Digitaria horizontalis* Willd. (capim-colchão, Figura 17b) e, portanto, foram escolhidas para serem utilizadas no primeiro experimento de captura de imagens.




Figura 17 – Cultivo *indoor* de sementes de plantas daninhas. a) Plântulas da espécie *Amaranthus viridis* L.; b) Plântulas da espécie *Digitaria horizontalis* Willd..

Fonte: Elaborada pelo autor.

3.1.5 Módulo com quatro câmeras CMOS monocromáticas, quatro filtros espectrais e uma câmera CMOS RGB

Para a captura de imagens de plantas de soja e plantas daninhas crescidas na estufa *indoor*, a primeira abordagem proposta visou a construção de uma câmera multiespectral composta por quatro câmeras espectrais e uma câmera colorida (RGB). O módulo da câmera multiespectral consiste em quatro câmeras com sensor CMOS monocromático e uma câmera colorida com sensor CMOS RGB, todas equipadas com lentes de 6 mm de distância focal. Ambos os modelos de câmera capturam imagens utilizando um sensor OV2710 com 2.0 *megapixels* de resolução (1920 x 1080 *pixels*). A comunicação entre as câmeras e o computador utilizado para captura foi feito através do protocolo USB 2.0.

Para converter as câmeras monocromáticas em câmeras espectrais, filtros monocromáticos passa-banda foram posicionados em frente o sistema óptico das câmeras, assim como mostrado no diagrama da Figura 18. Três filtros passa-banda correspondentes aos comprimentos de onda da cor verde (G: 501-525 nm), vermelho (R: 654-674 nm) e infravermelho próximo (NIR: 761-829 nm) foram posicionados cobrindo as lentes de três das quatro câmeras monocromáticas, permitindo a passagem de luz para cada um dos sensores apenas nos comprimentos de onda determinados por cada filtro. Para a quarta câmera monocromática, foi utilizado um filtro passa-alta no infravermelho (IR: >780 nm) cobrindo a lente da câmera.




Figura 18 – Diagrama de posicionamento dos filtros espectrais nas câmeras CMOS monocromáticas.

Fonte: Elaborada pelo autor.

O suporte das câmeras foi planejado para manter as cinco câmeras CMOS alinhadas na mesma direção de movimento do sistema e projetado no *software* 3D SolidWorks® (SolidWorks Corporation, Estados Unidos) (Figura 19a). Em seguida, o suporte foi impresso em PLA em uma impressora 3D Ender 3® (Ender, China) e as câmeras foram posicionadas mantendo a câmera RGB no topo da estrutura (Figura 19b).




Figura 19 – Construção da câmera multiespectral da primeira abordagem do projeto. a) Projeto do módulo da câmera multiespectral no SolidWorks®; b) Suporte impresso em PLA com as câmeras instaladas.

Fonte: Elaborada pelo autor.

O módulo contendo as câmeras espectrais e a câmera RGB foi instalado no sistema de trilhos para início da construção do primeiro banco de imagens do projeto (Figura 20).



Figura 20 – Módulo contendo as quatro câmeras espectrais e a câmera RGB instalados no sistema de trilhos.

Fonte: Elaborada pelo autor.

3.1.5.1 Construção do banco de imagens

Para facilitar o processo de captura e construção do banco de imagens, foi desenvolvida uma interface para o usuário no *software Qt Framework*. A interface desenvolvida mostra as imagens nas diferentes bandas espectrais e a imagem colorida, controla o motor NEMA17 e conseqüentemente o movimento do sistema, captura e salva automaticamente as imagens com indexação adequada e nome correspondente à inicial da banda espectral de cada câmera.

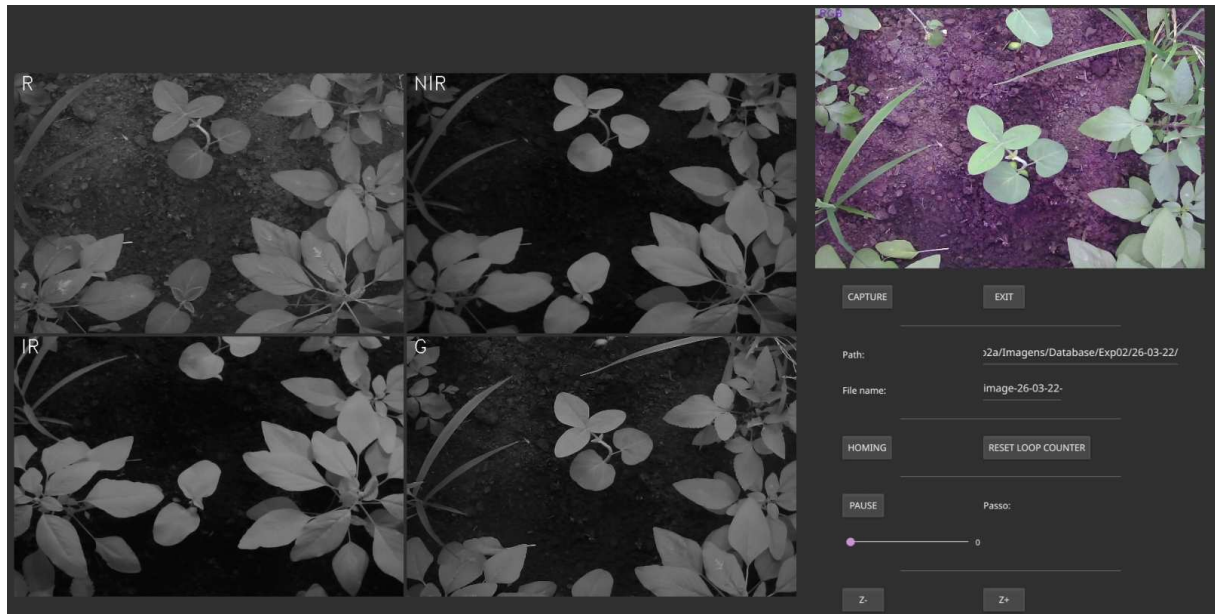


Figura 21 – Interface desenvolvida para automatizar o processo de captura de imagens.

Fonte: Elaborada pelo autor.

A interface disponibiliza as imagens das cinco câmeras em tempo real e permite que o usuário selecione o nome e a pasta que as imagens devem ser salvas. Em seguida, o usuário deve apertar a tecla *homing* para que o sistema de câmeras retorne para a posição inicial, colida com um interruptor fim-de-curso e se localize espacialmente. Após todos os parâmetros ajustados, o sistema começa a captura de imagens após o usuário apertar a tecla *Capture*. Assim como melhor descrito na Seção 3.1.2, o sistema de câmeras avança ao longo do trajeto imposto pelo trilho através de 46 passos do motor, gerando 46 imagens capturadas estaticamente para cada uma das câmeras visando evitar a captura de imagens desfocadas e/ou borradas.

Para a construção do banco de imagens, as plantas de soja foram posicionadas no centro das bandejas de substrato (simulando as linhas de plantio na lavoura) e as plantas daninhas foram posicionadas aleatoriamente ao longo das bandejas. Foram coletadas 8.020 imagens, sendo 1.604 imagens para cada uma das cinco câmeras. Exemplos das imagens obtidas durante a construção do banco podem ser observados na Figura 22.




Figura 22 – Construção do banco de imagens na primeira abordagem do projeto. Imagens obtidas nas bandas a) G, b) R, d) NIR, c) IR e e) imagem RGB.

Fonte: Elaborada pelo autor.

Essas imagens foram submetidas ao processo de rotulação necessário para aplicação do algoritmo YOLO, assim como melhor descrito na Seção 3.1.5.2.

3.1.5.2 Aplicação do algoritmo YOLO

Para a utilização de algoritmos de detecção e classificação como o YOLO, é necessário localizar os objetos nas imagens de treinamento através de arquivos de coordenadas e, por isso, foi utilizada a ferramenta CVAT* para enquadrar cada planta individualmente dentro de um retângulo chamado de *bounding box*, informando a classe da mesma e gerando um arquivo de coordenadas para cada imagem (Figura 23).




Figura 23 – Ilustração do processo de rotulação das imagens utilizando o *software* CVAT.

Fonte: Elaborada pelo autor.

Para o treinamento das redes, foram atribuídas três classes aos indivíduos do banco de imagens:

- SOJA: plantas da espécie *Glycine max* L.
- FE: plantas daninhas de folha estreita da espécie *Digitaria horizontalis* Willd.
- FL: plantas daninhas de folha larga das espécies *Amaranthus viridis* L. e *Bidens pilosa* L.

O processo de rotulação é trabalhoso, uma vez que cada imagem pode conter diversos indivíduos de plantas que devem ser enquadrados dentro de *bounding boxes* individuais e, por isso, depende de uma grande quantidade de tempo. As 1.604 imagens de cada uma das cinco câmeras foram rotuladas e divididas na proporção 60:20:20 (treino, validação e teste) para aplicação do algoritmo YOLO nas tarefas de detecção e classificação. Nessas 1.604 imagens rotuladas, encontram-se presentes aproximadamente 282 instâncias da classe SOJA, 476 instâncias da classe FE e 1468 instâncias da classe FL. Apesar da

* Do inglês, *Computer Vision Annotation Tool*

pequena quantidade de imagens utilizadas para o treinamento, o algoritmo YOLO possui etapas de *data augmentation* para aumentar a quantidade de imagens através da criação de cópias das imagens existentes com algumas modificações como, por exemplo, rotações, espelhamentos e mudanças na iluminação.

O algoritmo YOLO em sua versão v5, sem mudanças em sua arquitetura básica, foi utilizado para treinar cinco redes, uma para cada tipo de imagem obtido durante o processo de construção do banco de imagens. Para realizar o treinamento, as imagens e seus respectivos arquivos de coordenadas foram utilizados. Todas as redes foram treinadas individualmente e com os mesmos parâmetros: 1.000 *epochs* e *early stopping* com valor de *patience* igual a 100, ou seja, as redes deveriam ser treinadas até atingirem 1.000 ciclos completos de treinamento, mas caso não apresentassem melhorias nos resultados durante 100 ciclos consecutivos, os treinamentos cessariam.

As métricas utilizadas para análise dos resultados obtidos foram *Precision*, *Recall*, $mAP_{(0,5)}$ e $mAP_{(0,5:0,95)}$ e uma descrição detalhada de cada uma dessas métricas pode ser encontrada na Seção 2.4.2. Além disso, também foi feita uma análise com relação ao tempo médio necessário para o processo de detecção/classificação nas imagens de cada banda. Os resultados desta primeira abordagem do projeto podem ser encontrados na Seção 3.2.1.

3.1.6 Módulo com uma câmera CMOS RGB, uma câmera CMOS monocromática e uma roda de filtros contendo dez bandas espectrais

A segunda abordagem do projeto em iluminação artificial na estufa *indoor* envolve um sistema contendo uma câmera com sensor CMOS monocromático de 6 *megapixels*, uma câmera com sensor CMOS colorido de 16 *megapixels* e uma roda de filtros contendo dez filtros cobrindo a lente da câmera monocromática. A motivação da construção desse sistema é utilizar dez comprimentos de onda para estudar as bandas que apresentam os melhores resultados nas tarefas de detecção e classificação, e também pelo fato de que com esse sistema é possível garantir que todas as dez imagens obtidas são do mesmo local, eliminando técnicas de alinhamento que seriam necessárias posteriormente no sistema da Seção 3.1.5 caso fosse desejado combinar as imagens obtidas para gerar outras imagens multiespectrais. Além disso, a câmera monocromática utilizada possui resolução maior do que as câmeras utilizadas na primeira abordagem, permitindo a obtenção de imagens mais detalhadas das plantas. A carenagem desenvolvida contém duas câmeras, um motor de passo NEMA17 para girar a roda de filtros posicionando os filtros, um após o outro, em frente à lente da câmera monocromática e compatibilidade para instalação no sistema de trilhos (Figura 24).




Figura 24 – Projeto do módulo do sistema de captura contendo a roda de filtros no SolidWorks®.

Fonte: Elaborada pelo autor.

Foram utilizados cinco filtros na região do infravermelho próximo no sistema, sendo dois deles utilizados na primeira abordagem (NIR-02: 761-829 nm e IR: >780 nm). Os filtros utilizados foram os à seguir: UV+B (380-445 nm), B+G (392-535 nm), G (501-525 nm), Y (567-585 nm), R (654-674 nm), R+IR (610-670 e 790-1020 nm), NIR-01 (690-750 nm), NIR-02 (761-829 nm), IR-780 (>780 nm) e IR-850 (>850 nm). Os espectros correspondentes foram medidos por um espectrômetro da Ocean Optics e podem ser vistos na Figura 25.

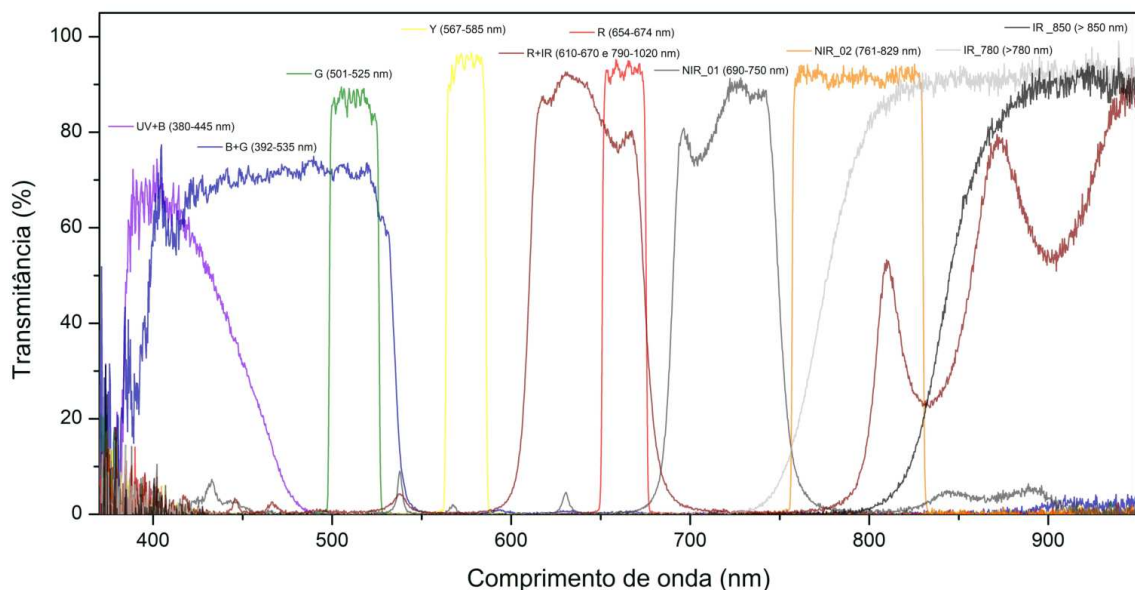


Figura 25 – Espectros dos dez filtros utilizados na segunda abordagem do projeto medidos por um espectrômetro da Ocean Optics.

Fonte: Elaborada pelo autor.

Para essa terceira e última abordagem em iluminação natural, foi realizado um novo plantio de plantas de soja e plantas daninhas das espécies *Amaranthus viridis* L., *Bidens pilosa* L. e *Digitaria horizontalis* Willd. para construção de um banco de imagens nos dez comprimentos de onda disponíveis e nas imagens RGB, conforme melhor descrito na Seção 3.1.6.1.

3.1.6.1 Construção do banco de imagens

A interface de captura foi adaptada para capturar uma imagem, girar o motor de passo e posicionar o próximo filtro em frente à lente da câmera, repetir o processo até que as imagens de todos os filtros sejam capturadas e avançar um passo no sentido do trilho, repetindo o processo até que o sistema tenha percorrido todo o caminho. As plantas foram posicionadas no solo e as capturas foram realizadas a cada dois dias. Em cada etapa de captura, 46 imagens de cada uma das dez bandas foram obtidas, assim como imagens de solo para compor os exemplos de *background* do algoritmo YOLO. Além disso, também foram realizadas capturas com a câmera RGB em duas condições diferentes: com todas as lâmpadas da bancada de cultivo ligadas (FS) e apenas com os LEDs brancos ligados (LB).

Foi construído um banco de imagens contendo 16.080 imagens, sendo 1.340 para cada uma das dez bandas, 1.340 imagens para a câmera RGB na condição FS e 1.340 imagens para a câmera RGB na condição LB. Na Figura 26, é possível observar que a imagem obtida na banda UV+B apresenta coloração mais escura uma vez que as plantas não refletem estes comprimentos de onda de maneira significativa (Figura 26a). Apesar de a banda B+G apresentar uma banda larga que engloba grande parte de uma banda verde, essas imagens também apresentaram coloração um pouco mais escura quando comparadas com as demais, muito provavelmente devido à presença da banda azul (Figura 26b). Nas bandas G e Y (Figuras 26c e 26d), as plantas presentes nas imagens apareceram com coloração mais clara devido ao fato de estas refletirem esses comprimentos de onda. Nas imagens da banda R (Figura 26e), as plantas aparecem com coloração escura pois as moléculas de clorofila absorvem grande parte dos comprimentos de onda da banda correspondente ao vermelho. Nas imagens das bandas no infravermelho próximo (Figuras 26f a 26j), as assinaturas espectrais desempenham um papel importante na segmentação natural das plantas no solo, uma vez que o solo quase não reflete estes comprimentos de onda e, portanto, aparece com coloração escura nas imagens, enquanto as plantas refletem bastante estes comprimentos de onda devido à estrutura do mesofilo das folhas e, portanto, aparecem com coloração clara nas imagens.



(a)



(b)



(c)



(d)




(e)




(f)

(Continua)

(Continuação)




(g)




(h)




(i)



(j)



(k)



(l)

Figura 26 – Exemplos das imagens obtidas com a roda de filtros e a câmera RGB em duas condições de iluminação diferentes. a) UV+B; b) B+G, c) G, d) Y, e) R, f) R+IR, g) NIR-01, h) NIR-02, i) IR-780, j) IR-850, k) RGB-FS e l) RGB-LB.

Fonte: Elaborada pelo autor.

3.1.6.2 Aplicação do algoritmo YOLO

Para a utilização do algoritmo de detecção e classificação YOLO, cada planta presente nas imagens foi enquadrada dentro de uma *bounding box* utilizando a ferramenta CVAT. Na etapa de rotulação das imagens da câmera monocromática, somente as imagens da banda NIR-01 foram carregadas no *software* e as *bounding boxes* foram desenhadas para todas as plantas presentes no banco de imagens dessa banda, classificando os indivíduos presentes nas imagens nas seguintes classes:

- SOJA: plantas da espécie *Glycine max* L.
- FE: plantas daninhas de folha estreita da espécie *Digitaria horizontalis* Willd.
- FL: plantas daninhas de folha larga das espécies *Amaranthus viridis* L. e *Bidens pilosa* L.

O sistema da roda de filtros da câmera monocromática permite o posicionamento sequencial de filtros espectrais em frente o sistema óptico da câmera, de maneira com que as imagens obtidas em cada passo do motor correspondam à mesma localização nas diferentes bandas espectrais. Dessa forma, os arquivos de coordenadas foram extraídos para a banda NIR-01 e renomeados para as demais bandas, permitindo a generalização do processo de rotulação nas nove bandas restantes com base na rotulação das imagens de apenas uma banda. Devido às diferenças de posicionamento físico entre o sensor da câmera monocromática e o sensor da câmera RGB, as imagens coloridas precisaram passar pelo processo de rotulação individualmente. Portanto, os arquivos de coordenadas obtidos para as imagens da câmera monocromática não puderam ser aproveitados neste caso. Na Figura 27, é possível observar o processo de rotulação das imagens da banda NIR-01 e das imagens da câmera RGB utilizando o *software* CVAT em que estão presentes algumas plantas da classe FE e algumas plantas da classe FL.

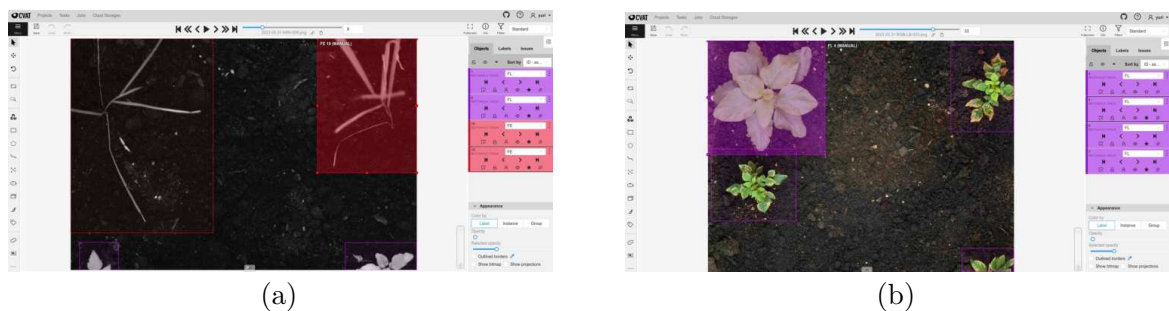


Figura 27 – Processo de rotulação das imagens da banda NIR-01 da câmera monocromática e das imagens RGB no *software* CVAT. a) Rotulação das imagens NIR-01; b) Rotulação das imagens RGB.

Fonte: Elaborada pelo autor.

Após as etapas de rotulação do banco de imagens, foi realizada a estruturação de pastas exigida pelo algoritmo YOLO, em que as imagens e os arquivos de coordenadas correspondentes foram divididos nos subconjuntos treino, validação e teste, nas proporções 60:20:20. Foi utilizado o algoritmo YOLO em sua versão v5, sem mudanças na arquitetura, por 1.000 *epochs* e com valor de *patience* igual a 100, em todas as bandas estudadas. Uma vez que as imagens obtidas nas dez bandas espectrais foram obtidas com a mesma câmera monocromática em conjunto com a roda de filtros e representam imagens do mesmo local, é possível garantir que a única variável neste experimento foi a informação espectral presente em cada imagem devido aos filtros. Assim como no experimento da Seção 3.1.5.2, as métricas utilizadas para análise dos resultados foram *Precision*, *Recall*, $mAP_{(0,5)}$, $mAP_{(0,5;0,95)}$ e tempo de inferência.

3.2 Resultados e discussão

Nesta Seção são apresentados os resultados obtidos após a aplicação do algoritmo YOLO nos bancos de imagens em iluminação artificial nas duas primeiras abordagens do projeto. A Seção 3.2.1 aborda os resultados obtidos com as imagens obtidas com o módulo com quatro câmeras CMOS monocromáticas, quatro filtros espectrais e uma câmera CMOS RGB, enquanto que a Seção 3.2.2 aborda os resultados obtidos com as imagens do módulo contendo uma câmera CMOS RGB e uma câmera CMOS monocromática com uma roda de filtros contendo dez bandas espectrais.

3.2.1 Módulo com quatro câmeras CMOS monocromáticas, quatro filtros espectrais e uma câmera CMOS RGB

A Tabela 2 resume os resultados das métricas analisadas para os modelos treinados em cada um dos cinco tipos de imagens. Apesar de os resultados para as métricas *Precision* e *Recall* não terem apresentado grandes diferenças entre as diferentes imagens, é possível observar que os modelos treinados nas imagens das bandas IR e NIR apresentaram bons resultados. Os resultados obtidos para a banda R foram inferiores e condizentes com o esperado devido à absorção deste comprimento de onda pela clorofila.

Tabela 2 – Resultados obtidos para as principais métricas após a aplicação do YOLO nos modelos treinados nos cinco tipos de imagens.


Imagem	<i>Precision</i>	<i>Recall</i>	$mAP (0,5)$	$mAP (0,5;0,95)$	Tempo de inferência (ms)
G	0,744	0,694	0,728	0,488	60,1
R	0,683	0,639	0,653	0,331	60,1
IR	0,778	0,733	0,746	0,527	59,5
NIR	0,731	0,718	0,712	0,495	59,5
RGB	0,796	0,758	0,798	0,532	62,0

Fonte: Elaborada pelo autor.


Para a métrica *Precision*, os melhores resultados foram obtidos para os modelos das seguintes bandas: RGB, IR e G, respectivamente. Para a métrica *Recall*, os melhores resultados foram obtidos para os modelos das seguintes bandas: RGB, IR e NIR, respectivamente. A métrica *Recall* desempenha um papel importante em tarefas de detecção, de forma com que se o *Recall* é alto, o número de falsos negativos é baixo e consequentemente poucas plantas deixarão de ser detectadas. Uma vez que as aplicações de herbicidas são realizadas pulverizando essas substâncias ao longo de toda a extensão do campo (6), algoritmos de detecção e classificação para reconhecimento de plantas daninhas devem priorizar a otimização da métrica *Recall* em relação à *Precision*, devido ao fato de que é preferível aplicar herbicida erroneamente em uma planta da lavoura (caso FP) do que não detectar e consequentemente não aplicar herbicida em uma planta daninha (caso FN). A Figura 28 mostra os resultados das detecções nas cinco bandas após o treinamento das redes.



(a)



(b)




(c)



(d)

(Continua)

(Continuação)




(e)

Figura 28 – Resultados obtidos com o algoritmo YOLO nas imagens teste. Detecções nas imagens a) G; b) R; c) IR; d) NIR e e) RGB.

Fonte: Elaborada pelo autor.


Na Figura 29, é possível observar as curvas *Precision-Recall* obtidas durante a validação das redes utilizando o valor de confiança 0,5 para o *threshold* da métrica IoU.




(a)

(Continua)

(Continuação)




(b)




(c)

(Continua)

(Continuação)



(d)



(e)

Figura 29 – Curvas *Precision-Recall* obtidas nas imagens teste das bandas a) G, b) R, c) IR, d) NIR e e) RGB.

Fonte: Elaborada pelo autor.

Nas curvas *Precision-Recall* da Figura 29, as bandas cujos modelos apresentaram maior AUC[†] para todas as classes com $\alpha = 0,5$ foram as das imagens RGB, IR e G. Para a métrica mAP_(0,5), as imagens RGB, seguidas das imagens da banda IR e da banda G apresentaram os melhores resultados, respectivamente, e em todos esses casos apresentaram valores maiores do que 0,7, o que significa que para classificações menos rígidas, quando o valor de confiança para o *threshold* da IoU é de $\alpha = 0,5$, todas as aplicações do algoritmo YOLO apresentaram bons resultados nas tarefas de detecção e classificação. Esses valores caíram aproximadamente de 0,3 em todos os casos quando considerou-se a média de dez valores de confiança diferentes para o *threshold* da IoU (α variando de 0,5 até 0,95 com passo de 0,05), sugerindo que os modelos não foram bons o suficiente para tarefas de detecção de plantas daninhas entre plantas de soja quando detecções mais precisas (mAP_(0,5:0,95)) são levadas em consideração. Os melhores resultados obtidos para essa métrica foram com as imagens RGB (0,532), IR (0,527) e NIR (0,495), respectivamente.


Apesar de os resultados ainda não serem satisfatórios, valores inferiores para a maioria das métricas eram esperados, uma vez que foram utilizadas apenas 1.604 imagens para a aplicação do algoritmo em cada banda, uma quantidade ínfima quando comparada com as milhares de imagens esperadas para que um algoritmo de IA performe um bom treinamento (24). Uma vez que as aplicações de herbicidas são realizadas ao longo de toda extensão do campo, como citado na Seção 2, valores de confiança para o *threshold* da IoU mais baixos ($\alpha = 0,5$) podem ser adotados para as etapas de detecção, classificação e pulverização localizada, uma vez que a prioridade do processo é não deixar de detectar todas as plantas no campo.

Outro problema encontrado no processo de rotulação e treinamento foi com as plantas gramíneas da classe FE. Isso aconteceu porque a arquitetura dessas plantas apresenta folhas estreitas e compridas, e uma vez que a aquisição das imagens foi realizada movendo as câmeras em uma linha reta, essas folhas (mas não a estrutura completa da planta) apareceram em imagens consecutivas, foram rotuladas e muito provavelmente atrapalharam o aprendizado do algoritmo. A Figura 30 ilustra as matrizes de confusão dos resultados obtidos para todas as bandas, no qual é possível observar que a rotulação das plantas daninhas da classe FE gerou uma grande quantidade de casos falso positivos e falso negativos quando comparadas com o solo (*background*), prejudicando o processo de reconhecimento de plantas daninhas. Todos os modelos treinados apresentaram diversos casos de classificações erradas entre plantas (exemplo, SOJA classificada como FL) e apresentaram confusão entre plantas e solo. Os piores resultados foram obtidos com o modelo treinado com as imagens da banda R (Figura 30b), em que existem casos de confusão entre classes para todas as classes de plantas presentes. Além disso, apenas 34% das plantas da classe FE foram classificadas corretamente no modelo R.

[†] Do inglês, Area Under the Curve

Também foram observados casos de detecção de plantas onde de fato existia *background*, o que aconteceu principalmente com as classes FE e FL nas matrizes de confusão da Figura 30. Novamente, este problema pode ter sido causado pela rotulação de folhas pequenas das plantas de todas as classes que apareceram apenas nas bordas das imagens, mas cujas arquiteturas de planta não estavam visíveis. Dessa forma, é possível que o algoritmo tenha confundido essas folhas com elementos físicos presentes na composição do substrato utilizado para o crescimento das plantas.


O pior caso de classificação errada é o caso falso negativo, que acontece quando plantas presentes nas imagens não foram detectadas e classificadas pelo algoritmo. Nesse caso, os modelos de todas as bandas apresentaram casos de plantas que não foram detectadas, resultado que precisa ser melhorado para que, em aplicações reais, nenhuma planta daninha deixe de ser detectada e pulverizada com o herbicida adequado. O pior caso de FNs obtido foi para o modelo treinado na banda R, em que 51% das plantas da classe FE não foram detectadas. Dessa forma, fica evidente que os modelos devem ser aprimorados para melhorar os resultados obtidos na *Recall* e que, eventualmente, métricas para avaliação dos modelos que dêem um peso maior para essa métrica devem ser adotadas.




(a)

(Continua)

(Continuação)




(b)




(c)

(Continua)

(Continuação)



(d)



(e)

Figura 30 – Matrizes de confusão obtidas com os modelos treinados nas diferentes imagens. Matrizes de confusão das bandas a) G, b) R, c) IR, d) NIR e e) RGB.

Fonte: Elaborada pelo autor.

No modelo treinado na banda G, 70% das plantas da classe SOJA, 57% das plantas da classe FE e 87% das plantas da classe FL foram detectadas e classificadas corretamente. No modelo treinado na banda R, 83% das plantas da classe SOJA, 34% das plantas da classe FE e 84% das plantas da classe FL foram detectadas e classificadas corretamente. No modelo treinado na banda IR, 86% das plantas da classe SOJA, 59% das plantas da classe FE e 89% das plantas da classe FL foram detectadas e classificadas corretamente. No modelo treinado na banda NIR, 84% das plantas da classe SOJA, 58% das plantas da classe FE e 81% das plantas da classe FL foram detectadas e classificadas corretamente. No modelo treinado nas imagens RGB, 78% das plantas da classe SOJA, 71% das plantas da classe FE e 92% das plantas da classe FL foram detectadas e classificadas corretamente.

O melhor tempo de inferência, ou seja, o tempo necessário para que o algoritmo detecte e classifique todas as plantas presentes nas imagens, foi obtido com os modelos treinados nas imagens das bandas IR (59,5 ms) e NIR (59,5 ms), e o pior tempo de inferência foi obtido com o modelo treinado nas imagens da câmera RGB (62 ms). Entretanto, é importante salientar que a diferença entre o melhor e o pior resultado foi de apenas 2,5 ms, não apresentando diferenças significativas que possam favorecer a escolha de uma banda em detrimento de outra. Em todos os casos, o tempo de inferência foi compatível com aplicações em tempo real.

Conclusões parciais:

No geral, os melhores resultados obtidos nessa abordagem foram para o modelo treinado com as imagens da câmera RGB, seguido dos modelos treinados com as imagens das câmeras monocromáticas contendo o filtro passa-alta IR (>780 nm) e o filtro passa-banda NIR (762-829 nm), sugerindo que os comprimentos de onda do infravermelho próximo desempenham um papel importante no processo de detecção e classificação de plantas, o que já era esperado pelas características das assinaturas espectrais destes indivíduos e do solo. A arquitetura de planta das gramíneas da classe FE (folha estreita), em conjunto com o processo de rotulação adotado, prejudicou o processo de detecção e classificação do algoritmo, gerando detecções e classificação de plantas dessa classe onde não existiam, assim como ausência de detecção dessas plantas nas imagens. O tempo de inferência necessário para que o algoritmo detectasse e classificasse todas as plantas em uma imagem não variou significativamente entre os modelos nas diferentes bandas, sendo, em média, da ordem de 60,2 ms e ideal para aplicações em tempo real, principalmente em condições de iluminação e densidade de plantas padronizadas como as encontradas no experimento da captura de imagens na estufa *indoor* do LIO²A. Nessa primeira abordagem, as câmeras estavam defasadas fisicamente em uma direção, o que impossibilitou o alinhamento de bandas espectrais para compor novas imagens multiespectrais e culminou no desenvolvimento de uma segunda abordagem em iluminação artificial, através da utilização de uma câmera monocromática com uma roda de filtros contendo dez bandas espectrais.

3.2.2 Módulo com uma câmera CMOS RGB, uma câmera CMOS monocromática e uma roda de filtros contendo dez bandas espectrais

A Tabela 3 resume os resultados das métricas analisadas para todas as bandas utilizadas, assim como para as duas condições de luz utilizadas com a câmera RGB.

Tabela 3 – Resultados obtidos para as principais métricas após a aplicação do YOLO nas imagens das dez bandas e nas imagens RGB nos modelos multi-classe.

Imagem	<i>Precision</i>	<i>Recall</i>	mAP (0,5)	mAP (0,5:0,95)	Tempo de inferência (ms)
UV+B	0,839	0,853	0,896	0,670	53,1
B+G	0,817	0,833	0,893	0,667	53,2
G	0,956	0,885	0,960	0,748	54,9
Y	0,824	0,788	0,842	0,654	54,0
R	0,836	0,802	0,868	0,631	52,3
R+IR	0,773	0,825	0,897	0,702	53,9
NIR-01	0,841	0,788	0,902	0,714	53,4
NIR-02	0,821	0,874	0,897	0,690	53,7
IR-780	0,819	0,846	0,919	0,700	53,4
IR-850	0,822	0,779	0,829	0,649	54,1
RGB-FS	0,935	0,790	0,872	0,619	70,3
RGB-LB	0,952	0,811	0,902	0,684	70,9

Fonte: Elaborada pelo autor.

Os melhores resultados para a métrica *Precision* foram obtidos para os modelos treinados nas bandas G (0,956), RGB-LB (0,952), RGB-FS (0,935) e NIR-01 (0,841), respectivamente. Para a métrica *Recall*, os melhores resultados foram obtidos para os modelos treinados nas bandas G (0,885), NIR-02 (0,874), UV+B (0,853) e IR-780 (0,846). Resultados elevados para as métricas *Precision* e *Recall* eram esperados para a banda verde, uma vez as plantas refletem esse comprimento de onda que, por sua vez, é capturado pelo sensor da câmera utilizada. Entretanto, não era esperado que o modelo da banda UV+B apresentasse um bom resultado para a métrica *Recall*, uma vez que as plantas não refletem muito estes comprimentos de onda, tornando a imagem um pouco mais escura do que o comum. Os modelos treinados com a câmera colorida nas duas condições de iluminação diferentes, apenas luz LED brancos (LB) e lâmpadas *Full Spectrum* e halógenas ligadas (FS), apresentaram bons resultados para a métrica *Precision*, mas não para a métrica *Recall*, sugerindo que as informações de cor contidas nos canais R, G e B dessas imagens, quando combinadas, destacam características relevantes para as tarefas de classificação da rede. O modelo treinado na banda NIR-01 apresentou um bom resultado para a métrica *Precision* e os modelos treinados nas bandas NIR-02 e IR-780 apresentaram bons resultados para a métrica *Recall*, destacando alguns dos comprimentos de onda do infravermelho próximo nos resultados positivos obtidos. Em contrapartida, o pior resultado obtido para a métrica *Precision* foi obtido para o modelo treinado na banda R+IR (0,773) e para a métrica *Recall* para o modelo treinado na banda IR-850 (0,779), o que pode ter sido

causado pelo fato de que a região do espectro infravermelho que ambos os filtros permitem a passagem de luz (Figura 25) não é fornecida com intensidade suficiente pela bancada de iluminação de acordo com o espectro da Figura 13, o que tornou as imagens escuras e pode ter prejudicado os processos de detecção e classificação multi-classe. Na Figura 31, é possível observar o gráfico dos resultados obtidos para as métricas *Precision* e *Recall* nos modelos treinados nas imagens obtidas com o sistema da roda de filtros e com a câmera RGB.




Figura 31 – Resultados obtidos para as métricas *Precision* e *Recall* nos modelos multi-classe treinados nas dez bandas espectrais e nas imagens RGB.


Fonte: Elaborada pelo autor.

De acordo com o gráfico da Figura 31, é possível observar que a métrica *Precision* apresenta valores inferiores para as bandas do visível, exceto por um pico na banda G destacando-se das demais bandas visíveis, diminui drasticamente para a banda R+IR, volta a crescer nas bandas infravermelho próximo em patamares similares aos das bandas visíveis e aumenta significativamente para as imagens coloridas. Para a métrica *Recall*, é possível observar novamente um pico na banda G, seguido de um decréscimo para as bandas visíveis Y e R, um aumento significativo para as bandas NIR-02 e IR-780, novamente um decréscimo para a banda IR-850 e, mais notavelmente, um decréscimo significativo para as imagens coloridas que apresentaram os piores resultados juntos com as bandas Y, R e IR-850. Apesar dos gráficos das métricas *Precision* e *Recall* nas diferentes bandas estudadas não seguirem um padrão bem definido de aumento ou diminuição, vale salientar que ambas as métricas são calculadas independentemente e que, quando associadas em conjunto através da métrica mAP extraída das curvas *Precision-Recall*, representam melhor o desempenho dos modelos de Inteligência Artificial nas tarefas de detecção e classificação.

A Figura 32 ilustra o processo de detecção e classificação de plantas de soja e de plantas daninhas após aplicação do YOLO. Nas figuras da esquerda, é possível observar o processo de detecção de plantas daninhas de folha larga das espécies *Amaranthus viridis* L. e *Bidens pilosa* L. e de plantas daninhas de folha estreita da espécie *Digitaria horizontalis* Willd. Nas figuras da direita, é possível observar o processo de detecção de plantas de soja.




(a)



(b)



(c)



(d)



(e)




(f)

(Continua)

(Continuação)




(g)



(h)




(i)




(j)




(k)



(l)



(m)




(n)

(Continua)

(Continuação)




(o)



(p)




(q)



(r)



(s)



(t)



(u)



(v)

(Continua)

(Continuação)




Figura 32 – Resultados obtidos com o algoritmo YOLO nas imagens teste na abordagem da roda de filtros com os modelos multi-classe. Detecções de plantas daninhas e de plantas de soja, respectivamente, nas imagens a) e b) UV; c) e d) B+G; e) e f) G; g) e h) Y; i) e j) R; k) e l) R+IR; m) e n) NIR-01; o) e p) NIR-02; q) e r) IR-780; s) e t) IR-850, u) e v) RGB-FS e w) e x) RGB-LB.

Fonte: Elaborada pelo autor.


Nas imagens analisadas, é possível observar que as plantas aparecem naturalmente segmentadas do solo nas imagens obtidas nos comprimentos de onda do infravermelho próximo (Figuras 32k à 32t). Entretanto, algumas plantas daninhas da classe FL foram simultaneamente classificadas como plantas de SOJA e plantas FL nesses comprimentos de onda, representando casos de detecções duplas. Em todos os casos apresentados na Figura 32, nenhuma planta deixou de ser detectada pelos modelos treinados utilizando o algoritmo YOLO. Nas bandas UV, BG, Y, R+IR, NIR-02, IR-780 e IR-850, duas plantas daninhas da classe FL foram classificadas como plantas da classe SOJA. Apesar de não ser um resultado desejado, a confusão entre plantas daninhas da classe FL e plantas de soja era esperada devido ao fato de as plantas de soja serem consideradas plantas de folha larga, apresentando mais semelhanças com as plantas da espécie *Bidens pilosa* L. e *Amaranthus viridis* L. do que com as plantas *Digitaria horizontalis* Willd.

Com relação à detecção de plantas da classe FE, as *bounding boxes* detectadas pelo algoritmo variam de acordo com os modelos de cada banda, apesar do fato de que as imagens do sistema da roda de filtros foram rotuladas de maneira exatamente igual, assim como explicado na Seção 3.1.6.2. Na maioria dos casos, a *bounding box* detectada pelo modelo se restringe à região que engloba a maior parte da planta, evitando superposições com *bounding boxes* detectadas de plantas vizinhas, como na Figura 32e, por exemplo. Entretanto, existem casos em que a *bounding box* detectada da planta da classe FE presente na imagem não engloba completamente a planta (Figura 32k), e casos em que a

bounding box detectada da mesma planta se superpõe a *bounding box* detectada da planta da classe FL posicionada logo acima na imagem (Figura 32u). Todas as plantas de soja da Figura 32 foram detectadas corretamente pelos modelos. A Figura 33 ilustra as curvas *Precision-Recall* obtidas na validação dos modelos nas imagens do conjunto teste.




(a)




(b)

(Continua)

(Continuação)




(c)




(d)

(Continua)

(Continuação)




(e)




(f)

(Continua)

(Continuação)




(g)




(h)

(Continua)

(Continuação)




(i)




(j)

(Continua)

(Continuação)



(k)



(l)

Figura 33 – Curvas *Precision-Recall* obtidas nas imagens teste com os modelos multi-classe treinados nas bandas a) UV; b) B+G; c) G; d) Y; e) R; f) R+IR; g) NIR-01; h) NIR-02; i) IR-780; j) IR-850, k) RGB-FS e l) RGB-LB.

Fonte: Elaborada pelo autor.

Nas curvas *Precision-Recall* da Figura 33, é possível observar que os modelos que apresentaram maior valor de $mAP_{(0,5)}$ para todas as classes analisadas foram os modelos treinados nas imagens das bandas G (0,960), IR-780 (0,919), NIR-01 (0,902), RGB-LB (0,902) e NIR-02 (0,897), respectivamente. Analisando os resultados individualmente para cada classe, é possível observar que, com exceção do modelo treinado na banda R, a classe FL apresentou maior valor de $mAP_{(0,5)}$ para os modelos treinados em todas as outras bandas. Os quatro melhores resultados obtidos para essa métrica apresentaram valores acima de 0,9, demonstrando que para classificações menos rígidas em que o valor de confiança da IoU é 0,5, a aplicação do algoritmo YOLO proporcionou resultados satisfatórios nas etapas de detecção e classificação. Aumentando a rigidez do processo de detecção, ou seja, variando o valor de confiança da IoU de 0,5 até 0,95 em passos de 0,05 e tomando a média dos valores obtidos, os valores da métrica mAP diminuíram de aproximadamente 0,2 em todos os modelos treinados. Dessa forma, os melhores resultados obtidos para a métrica foram para os modelos treinados nas bandas G (0,748), NIR-01 (0,714), R+IR (0,702), IR-780 (0,700) e NIR-02 (0,690), destacando junto com a banda verde uma série de bandas no infravermelho próximo que apresentaram bons resultados para a métrica mais importante em algoritmos de detecção e classificação.

Na Figura 34, é possível observar o gráfico dos resultados obtidos para as métricas $mAP_{(0,5)}$ e $mAP_{(0,5;0,95)}$ nos modelos treinados nas imagens obtidas com o sistema da roda de filtros e com a câmera RGB nas duas condições de iluminação utilizadas na segunda abordagem do projeto.





Figura 34 – Resultados obtidos para as métricas $mAP_{(0,5)}$ e $mAP_{(0,5;0,95)}$ nos modelos multi-classe treinados nas dez bandas espectrais e nas imagens RGB.

Fonte: Elaborada pelo autor.


De acordo com a análise da Figura 34, é possível observar que ambas as curvas apresentam um padrão similar, apresentando picos bem destacados nos valores das métricas para a banda G, resultados inferiores para as bandas Y, R e IR-850, e o surgimento de um platô em que os valores das métricas para os modelos treinados nos comprimentos de onda R+IR, NIR-01, NIR-02 e IR-780 se destacam, apresentando resultados melhores do que os obtidos com as imagens coloridas em ambas as condições de iluminação artificial. A presença de uma região no gráfico destacando quatro dos cinco comprimentos de onda do infravermelho próximo utilizados nas métricas $mAP_{(0,5)}$ e $mAP_{(0,5;0,95)}$, consideradas as métricas mais importantes para avaliar algoritmos de detecção e classificação, reforçam a importância do comprimento de onda do infravermelho próximo no processo de detecção e classificação de plantas daninhas e plantas de soja utilizando técnicas de Visão Computacional. A banda G, por sua vez, apresenta uma importância considerável e poderia ser utilizada, eventualmente, para aplicações de herbicidas pré-emergência da cultura, onde a tarefa principal é detectar toda e qualquer planta daninha presente no campo, ou seja, detectar verde sobre palhada. A Figura 35 ilustra as matrizes de confusão dos modelos treinados com as imagens obtidas no sistema da roda de filtros.



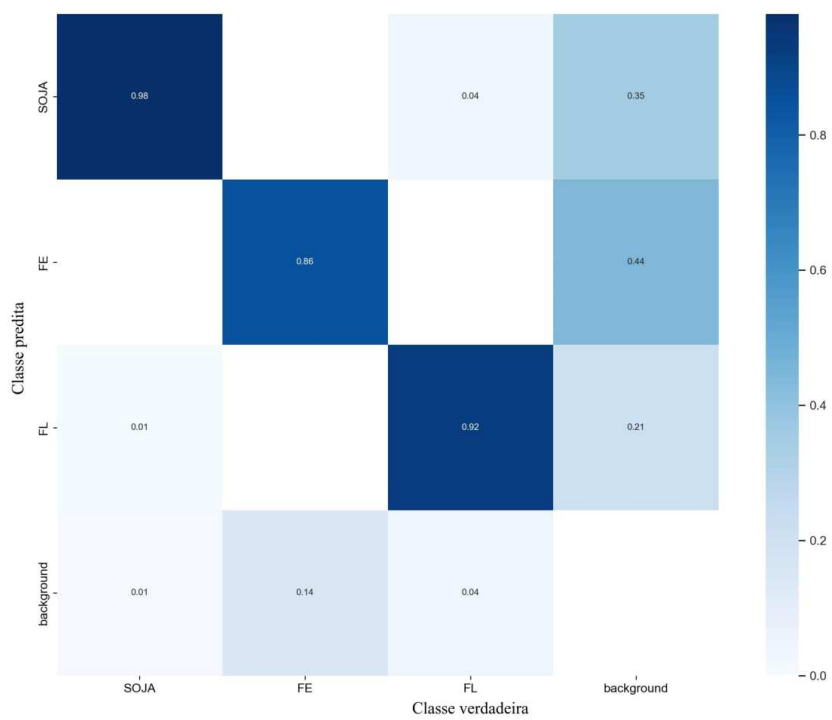
(a)

(Continua)

(Continuação)




(b)




(c)

(Continua)

(Continuação)




(d)




(e)

(Continua)

(Continuação)




(f)




(g)

(Continua)

(Continuação)




(h)




(i)

(Continua)

(Continuação)




(j)



(k)

(Continua)

(Continuação)



(1)

Figura 35 – Matrizes de confusão obtidas nos modelos multi-classe treinados nas imagens a) UV; b) B+G; c) G; d) Y; e) R; f) R+IR; g) NIR-01; h) NIR-02; i) IR-780; j) IR-850, k) RGB-FS e l) RGB-LB.

Fonte: Elaborada pelo autor.

Analisando os resultados obtidos nas matrizes de confusão apresentadas na Figura 35, é possível observar que o processo de rotulação adotado para a classe FE resultou em uma quantidade significativa de falso negativos (FN), ou seja, ausência de detecções de plantas daninhas de folha estreita, o que pode ser atribuído às características físicas da arquitetura específica de plantas dessa classe. Plantas daninhas de folha estreita apresentam folhas estreitas e compridas que, devido à trajetória linear de captura das imagens no sistema de trilhos, apareceram novamente em diversas imagens consecutivas isoladas da estrutura principal da planta, foram rotuladas e muito provavelmente interferiram no processo de aprendizado do algoritmo.

Com exceção dos modelos treinados nas imagens coloridas nas duas iluminações diferentes, todos os modelos treinados nas bandas espectrais do sistema da roda de filtros classificaram corretamente mais de 95% das plantas da classe SOJA. Na maioria dos modelos, os piores resultados de classificação foram obtidos para a classe FE. Em todos os modelos, foram obtidos casos de ausência de detecção (caso FN) e casos de detecção que não deveriam existir (caso FP, plantas detectadas no *background*).

Analisando a matriz de confusão do modelo da banda UV+B (Figura 35a), é possível observar que 97% das plantas da classe SOJA foram classificadas corretamente, enquanto 3% foram erroneamente classificadas como *background* (sem detecção). O modelo apresentou resultados inferiores para a classificação de plantas da classe FE, com apenas 58% das plantas classificadas corretamente e 42% das plantas não detectadas pelo algoritmo. Cerca de 11% das plantas da classe FL foram classificadas como plantas da classe SOJA. Para o modelo da banda B+G (Figura 35b), 98% das plantas da classe SOJA, 60% das plantas da classe FE e 86% das plantas da classe FL foram classificadas corretamente. Cerca de 10% das plantas da classe FL foram classificadas como plantas da classe SOJA.

Na matriz de confusão do modelo da banda G (Figura 35c), 98% das plantas da classe SOJA, 86% das plantas da classe FE e 92% das plantas da classe FL foram classificadas corretamente, enquanto 4% das plantas da classe FL foram classificadas como da classe SOJA. Os resultados de classificação obtidos pela banda verde foram superiores com relação aos resultados obtidos em qualquer outra banda. Para a banda Y, 99% das plantas da classe SOJA, 80% das plantas da classe FE e 53% das plantas da classe FL foram classificadas corretamente (Figura 35d). Cerca de 1% das plantas da classe FL não foram detectadas e 46% foram classificadas como plantas da classe soja, o que já esperado pelo fato de ambas as espécies de plantas se tratarem de plantas de folha larga. Esse mesmo problema poderia ser encontrado, por exemplo, em classificações de plantas da cultura que se enquadrem no grupo de plantas de folha estreita como o milho, com plantas daninhas de folha estreita, como as plantas da espécie *Digitaria horizontalis* Willd. aqui utilizadas, pela semelhança na estrutura e na arquitetura das plantas.

O modelo da banda R (Figura 35e) apresentou 99% das plantas da classe SOJA, 65% das plantas da classe FE e 74% das plantas da classe FL classificadas corretamente. Cerca de 33% das plantas da classe FE não foram detectadas e 22% das plantas da classe FL foram confundidas com plantas da classe SOJA. Apesar de se esperar resultados inferiores para a banda R devido à absorção desta banda pelas moléculas de clorofila, os resultados obtidos no experimento não diferiram notavelmente dos resultados obtidos com outras bandas no visível.

No caso do modelo treinado nas imagens da banda R+IR (Figura 35f), 99% das plantas da classe SOJA, 70% das plantas da classe FE e 54% das plantas da classe FL foram classificadas corretamente, enquanto 26% das plantas da classe FE não foram detectadas. Cerca de 46% das plantas da classe FL foram classificadas como plantas da classe SOJA e 5% das plantas da classe FE foram classificadas como plantas da classe SOJA, o que é uma classificação incomum por tratar-se de plantas com arquitetura de planta diferentes.

Para os modelos das bandas NIR-01 e NIR-02 (Figuras 35g e 35h), respectivamente, 99% e 94% das plantas da classe SOJA, 66% e 81% das plantas da classe FE e 62% e 82% foram classificadas corretamente. A banda NIR-01, compreendendo os comprimentos

de onda do infravermelho próximo na banda 690-750 nm, apareceu entre os melhores resultados para a maioria das métricas utilizadas, mesmo com a banda NIR-02 apresentando resultados melhores na classificação correta das plantas da classe FE e FL.

Quanto aos modelos treinados nas imagens das bandas IR-780 e IR-850 (Figuras 35i e 35j), respectivamente, 97% e 97% das plantas da classe SOJA, 68% e 64% das plantas da classe FE e 69% e 62% das plantas da classe FL foram classificadas corretamente. Em ambos os casos, uma quantidade significativa de plantas da classe FE não foram detectadas, plantas da classe FL foram classificadas como plantas da classe SOJA e uma grande quantidade de plantas de soja foram detectadas no *background*.

O modelo treinado nas imagens RGB-LB (Figura 35l) conseguiu classificar corretamente 83% das plantas da classe SOJA, 72% das plantas da classe FE e 92% das plantas da classe FL, com apenas 26% das plantas da classe FE não detectadas. Utilizando uma iluminação diferente para a captura das imagens coloridas, o modelo treinado nas imagens RGB-FS (Figura 33k) conseguiu classificar corretamente 71% das plantas da classe SOJA, 80% das plantas da classe FE e 92% das plantas da classe FL. Estes modelos apresentaram mais casos verdadeiro positivos (VP) para a detecção de plantas daninhas do que de plantas de soja e uma quantidade significativa de plantas de soja não detectadas.

O melhor tempo de inferência foi obtido com o modelo treinado nas imagens da banda R (52,3 ms), e o pior foi obtido com o modelo treinado nas imagens RGB-LB (70,9 ms). Apesar da diferença de 18,6 ms entre o melhor e o pior resultado, vale salientar que o valor médio do tempo de inferência comparando os resultados obtidos pelos doze modelos foi de 56,5 ms, se aproximando do valor médio calculado para as dez bandas espectrais (53,6 ms) e se distanciando do valor médio obtido para ambas as configurações de iluminação das imagens RGB (70,6 ms). Apesar da diferença observar, é importante ressaltar que as imagens coloridas foram obtidas por uma câmera diferente, com sensor de dimensões físicas e resolução diferentes e que estava fisicamente defasada de alguns milímetros da câmera monocromática.

3.2.2.1 Classificação uni-classe: planta vs solo

Ainda visando estudar a influência dos diferentes comprimentos de onda e das imagens RGB no processo de detecção e classificação de plantas pelo algoritmo YOLO, os mesmos treinamentos foram realizados novamente para todas as imagens incluindo o parâmetro *single class* do YOLO, responsável por colapsar todas as três classes dos treinamentos anteriores em apenas uma. Dessa forma, os novos modelos treinados realizaram tarefas mais simples, aprendendo a detectar plantas no solo e sendo ideais, por exemplo, para tarefas de detecções de plantas daninhas em aplicações de dessecação em campo ("verde-sobre-palhada"). A Tabela 4 resume os resultados obtidos nessa abordagem para as métricas utilizadas para análise dos modelos:

Tabela 4 – Resultados obtidos para as principais métricas após a aplicação do YOLO nas imagens das dez bandas e nas imagens RGB nos modelos uni-classe.

Imagem	<i>Precision</i>	<i>Recall</i>	mAP (0,5)	mAP (0,5:0,95)	Tempo de inferência (ms)
UV+B	0,933	0,897	0,957	0,746	53,0
B+G	0,950	0,913	0,963	0,740	53,1
G	0,942	0,896	0,959	0,768	53,0
Y	0,945	0,922	0,969	0,783	53,1
R	0,916	0,889	0,946	0,742	56,4
R+IR	0,955	0,891	0,959	0,780	55,8
NIR-01	0,937	0,929	0,960	0,785	56,0
NIR-02	0,930	0,913	0,959	0,762	55,4
IR-780	0,929	0,950	0,975	0,806	53,1
IR-850	0,901	0,945	0,966	0,793	53,6
RGB-FS	0,926	0,898	0,951	0,656	65,7
RGB-LB	0,960	0,941	0,982	0,785	64,6

Fonte: Elaborada pelo autor.

Nessa abordagem, os melhores resultados para a métrica *Precision* foram obtidos para os modelos treinados nas imagens RGB-LB (0,960), R+IR (0,955), B+G (0,950), Y (0,945), G (0,942). Para a métrica *Recall*, os melhores resultados obtidos foram obtidos para os modelos treinados nas bandas IR-780 (0,950), IR-850 (0,945), RGB-LB (0,941), NIR-01 (0,929) e Y (0,922). Novamente, as imagens RGB-LB e as imagens da banda G apareceram entre os cinco melhores resultados obtidos para a métrica *Precision* só que, desta vez, o melhor resultado foi obtido para a câmera colorida. O modelo treinado na banda R+IR se destacou no processo de classificação quando apenas uma classe foi levada em consideração, sugerindo que a presença de uma banda no infravermelho neste filtro pode ter auxiliado o processo de detecção de plantas. No caso da métrica *Recall*, apenas os modelos treinados nas imagens da banda IR-780 aparecem entre os cinco melhores resultados em ambos os casos. Através da análise dos resultados obtidos para essa métrica, é possível observar que três bandas do infravermelho (IR-780, IR-850 e NIR-01) se destacaram no processo de detecção de plantas no geral, o que pode ter sido influenciado pela segmentação natural importa pelas assinaturas espectrais das plantas e do solo. Diferente dos resultados obtidos para as métricas *Precision* e *Recall* nos modelos multi-classes (FE, FL e SOJA) no início da Seção 3.2.2, o modelo treinado na banda Y ficou entre os cinco melhores resultados para ambas as métricas, demonstrando que para classificações uni-classe essa banda no visível pode gerar bons resultados. O modelo treinado nas imagens RGB-LB também apresentou bons resultados para a métrica *Recall*, uma vez que as plantas ficam destacadas de verde em um substrato de coloração marrom.

Na Figura 36, é possível observar o gráfico dos resultados obtidos para as métricas *Precision* e *Recall* nos modelos uni-classe treinados nas imagens obtidas com o sistema da roda de filtros e com a câmera RGB.




Figura 36 – Resultados obtidos para as métricas *Precision* e *Recall* nos modelos uni-classe treinados nas dez bandas espectrais e nas imagens RGB.


Fonte: Elaborada pelo autor.

De acordo com o gráfico da Figura 36, é possível observar que os modelos treinados em algumas bandas do visível (B+G, G e Y) apresentaram resultados melhores para a métrica *Precision* do que alguns modelos treinados em bandas do infravermelho próximo (NIR-01, NIR-02, IR-780 e IR-850), sugerindo que, nesse caso de classificação uni-classe apenas de plantas, as bandas verde e amarelo desempenharam um papel importante. Novamente, a informação de cor presente nos canais R, G e B da câmera colorida em conjunto com a iluminação branca dos *plafons* de LEDs podem ter auxiliado o processo de classificação, uma vez que a banda RGB-LB destacou-se no gráfico apresentando o maior valor de *Precision*. Para a métrica *Recall*, é possível observar pelo gráfico da Figura 36 que a situação se inverte e os modelos treinados nas bandas do infravermelho próximo geram uma região em destaque com valores elevados para a métrica quando comparada com a região das bandas no visível. Além disso, é possível observar que o modelo treinado nas imagens coloridas com iluminação contendo as lâmpadas *Full Spectrum* ligadas (RGB-FS) prejudicou o processo de detecção assim como no caso do modelo de classificação multi-classe, sugerindo que a coloração rosa/roxa do solo gerada por essas lâmpadas prejudicou o processo de detecção do verde das plantas no substrato. Dentre os piores resultados obtidos para ambas as métricas, o modelo treinado nas imagens R destacou-se negativamente por apresentar o pior valor de *Recall*, e o segundo pior valor de *Precision*, perdendo apenas para o modelo da banda IR-850.

A Figura 37 ilustra o processo de detecção e classificação de plantas após aplicação do algoritmo YOLO. Uma vez que as três antigas classes, plantas de soja (SOJA) e plantas daninhas de folha estreita (FE) e folha larga (FL), foram colapsadas em apenas uma classe plantas através da inserção do parâmetro *single class* no treinamento do YOLO, o algoritmo converte todos os rótulos para uma classe chamada **item**.




(a)



(b)




(c)



(d)



(e)




(f)

(Continua)

(Continuação)




(g)



(h)



(i)



(j)




(k)



(l)



(m)




(n)

(Continua)

(Continuação)




(o)



(p)




(q)



(r)



(s)



(t)



(u)



(v)

(Continua)

(Continuação)




Figura 37 – Resultados obtidos com o algoritmo YOLO as imagens teste na abordagem da roda de filtros com a classificação uni-classe. Detecções de plantas nas imagens a) e b) UV; c) e d) B+G; e) e f) G; g) e h) Y; i) e j) R; k) e l) R+IR; m) e n) NIR-01; o) e p) NIR-02; q) e r) IR-780; s) e t) IR-850, u) e v) RGB-FS e w) e x) RGB-LB.


Fonte: Elaborada pelo autor.

Analisando a Figura 37, é possível observar que todas as plantas dos modelos analisados nas dez bandas espectrais e das imagens RGB foram detectadas, demonstrando que todos os modelos foram capazes de detectar plantas no geral. Em diversos casos, a confiança da detecção na planta antes pertencente à classe FE (extremidade inferior esquerda das imagens) foi muito menor do que nas demais plantas presentes nas imagens. Esse fato pode ser justificado pelo fato de que plantas de folha larga como as plantas de soja e as plantas das espécies *Amaranthus viridis* L. e *Bidens pilosa* L. foram agrupadas na mesma classe que plantas de folha estreita da espécie *Digitaria horizontalis* Willd., desbalanceando ainda mais o banco de imagens à favor das plantas de folha larga e fazendo com que o modelo aprendesse que as plantas da nova classe planta (ou **item**) deveriam ser parecidas em estrutura com plantas de folha larga.

Em resumo, pelo gráfico das métricas *Precision* e *Recall* da Figura 36 e pelas imagens de detecção da Figura 37, é possível observar que o processo de detecção em si foi bem mais eficiente na abordagem uni-classe do que na abordagem multi-classe, o que já era esperado pelo fato de que a complexidade do processo diminui ao colapsar as três antigas classes em uma classe que visa a detecção apenas de plantas. Uma vez que os resultados foram melhores nesse caso, essa abordagem poderia ser utilizada em aplicações de herbicida para o manejo de plantas daninhas antes da emergência de plantas da cultura, aumentando a acurácia do processo. A Figura 38 ilustra as curvas *Precision-Recall* obtidas na validação dos modelos nas imagens do conjunto teste com a abordagem de uni-classe.




(a)




(b)

(Continua)

(Continuação)




(c)




(d)

(Continua)

(Continuação)




(e)




(f)

(Continua)

(Continuação)




(g)




(h)

(Continua)

(Continuação)




(i)




(j)

(Continua)

(Continuação)



(k)



(l)

Figura 38 – Curvas *Precision-Recall* obtidas nas imagens teste com os modelos uni-classe treinados nas bandas a) UV; b) B+G; c) G; d) Y; e) R; f) R+IR; g) NIR-01; h) NIR-02; i) IR-780; j) IR-850, k) RGB-FS e l) RGB-LB.

Fonte: Elaborada pelo autor.

Nas curvas *Precision-Recall* da Figura 38, é possível observar que os modelos que apresentaram maior valor de $mAP_{(0,5)}$ foram os modelos treinados nas imagens RGB-LB (0,980), IR-780 (0,975), Y (0,969), IR-850 (0,966), B+G (0,963), respectivamente. O melhor resultado foi obtido para o modelo treinado nas imagens coloridas (RGB-LB), demonstrando que a utilização de uma câmera colorida é essencial no processo de detecção e classificação de plantas, seguido de dois modelos treinados em bandas do infravermelho próximo. Novamente, os modelos treinados nas bandas B+G e Y se destacaram apresentando bons resultados na detecção de uma classe, o que já era esperado pelos valores elevados obtidos na métrica *Precision*. Aumentando a rigidez do processo de detecção, os melhores resultados obtidos para a métrica $mAP_{(0,5;0,95)}$ foram para os modelos treinados nas bandas IR-780 (0,806), IR-850 (0,793), RGB-LB (0,785), NIR-01 (0,785) e Y (0,783), destacando os modelos de quatro bandas no infravermelho próximo nos cinco melhores resultados obtidos e reforçando a importância dessas bandas na detecção de plantas quando essas estão agrupadas em apenas uma classe. Além disso, os modelos treinados nas imagens coloridas na iluminação branca (RGB-LB) e na banda Y apresentaram bons resultados.

Na Figura 39, é possível observar o gráfico dos resultados obtidos para as métricas $mAP_{(0,5)}$ e $mAP_{(0,5;0,95)}$ nos modelos uni-classe treinados nas imagens obtidas com o sistema da roda de filtros e com a câmera RGB nas duas condições de iluminação utilizadas na segunda abordagem do projeto.





Figura 39 – Resultados obtidos para as métricas $mAP_{(0,5)}$ e $mAP_{(0,5;0,95)}$ nos modelos uni-classe treinados nas dez bandas espectrais e nas imagens RGB.

Fonte: Elaborada pelo autor.


De acordo com o gráfico da Figura 39, é possível observar que as curvas $mAP_{(0,5)}$ e $mAP_{(0,5;0,95)}$ apresentaram um padrão similar, com exceção do valor de $mAP_{(0,5;0,95)}$ do modelo treinado nas imagens coloridas RGB-FS que apresentou um decréscimo inesperado após a validação dos modelos. Na curva $mAP_{(0,5)}$, é possível observar um platô constante dos valores da métrica para a maioria dos casos, apresentando um leve acréscimo no modelo das imagens RGB-LB. A curva $mAP_{(0,5;0,95)}$ apresenta diferenças maiores entre os modelos treinados nas diferentes bandas, um platô mais elevado em algumas bandas do infravermelho próximo (IR-780 e IR-850) comparado com as bandas visíveis e uma queda na imagem RGB-FS. Novamente, esses resultados reafirmam a importância de uma câmera multispectral composta por uma câmera RGB e uma câmera que capture nos comprimentos de onda do infravermelho próximo. Mais especificamente, é possível observar que a incorporação dos filtros passa-alta >780 nm e >850 nm e passa-banda 690-750 nm em uma câmera com sensor monocromático auxilia consideravelmente o processo de detecção de plantas. A Figura 40 ilustra as matrizes de confusão dos modelos uni-classe treinados.




(a)

(Continua)

(Continuação)




(b)




(c)

(Continua)

(Continuação)




(d)




(e)

(Continua)

(Continuação)




(f)




(g)

(Continua)

(Continuação)




(h)




(i)

(Continua)

(Continuação)




(j)



(k)

(Continua)

(Continuação)



(1)

Figura 40 – Matrizes de confusão obtidas nos modelos treinados nas imagens a) UV; b) B+G; c) G; d) Y; e) R; f) R+IR; g) NIR-01; h) NIR-02; i) IR-780; j) IR-850, k) RGB-FS e l) RGB-LB.

Fonte: Elaborada pelo autor.

Através da análise dos resultados obtidos nas matrizes de confusão da Figura 40, é possível concluir que o processo de classificação é muito mais eficaz quando as três antigas classes (FE, FL e SOJA) são colapsadas em uma classe, e o processo em si torna-se um processo mais simples de apenas detecção de plantas no solo. Nesse caso, apenas o modelo treinado na banda R apresentou menos do que 90% das plantas detectadas corretamente (87%), enquanto os outros modelos apresentaram acima de 92% de detecções corretas.

Os melhores resultados foram obtidos para os modelos treinados nas imagens RGB-LB e imagens da banda IR-780, cujas porcentagens de acertos na detecção de plantas foram de 96% em ambos os casos, seguido do modelo treinado na banda NIR-01 (95%). Em todos os modelos, sem exceção, 100% dos casos de *background* foram classificados como plantas, ou seja, os modelos treinados apresentaram casos de detecções falso positivas nos modelos uni-classe o que, em aplicações reais, resultaria no desperdício de herbicidas através da aplicação desses defensivos no solo, assim como é feito no manejo convencional

de plantas daninhas. Entretanto, é importante salientar que os resultados obtidos para a detecção e classificação de plantas nos modelos uni-classe são promissores para a futura implementação destes modelos em aplicações de herbicidas antes da emergência da cultura em campo através do desenvolvimento de um equipamento de pulverização localizada de herbicidas, uma vez que a quantidade de falso negativos, ou seja, a porcentagem de plantas não detectadas foi muito pequena em praticamente todos os modelos.

3.2.2.2 Classificação uni-classe e multi-classe em imagens NDVI

Visando explorar o processo de detecção e classificação utilizando o algoritmo YOLO em imagens multiespectrais provenientes das imagens espectrais obtidas com o sistema da roda de filtros, imagens multiespectrais representando o importante índice vegetativo NDVI foram construídas através da fusão de imagens das bandas R e NIR-01. Para a geração de imagens NDVI à partir das imagens das bandas R e NIR-01, foi utilizado um código em *python* capaz de acessar as pastas onde as imagens de cada banda estavam armazenadas, aplicar a equação do NDVI (Equação 2.3) *pixel a pixel* utilizando os valores de intensidade de refletância armazenados em cada *pixel* de ambas as imagens, aplicar o mapa de cor *Deep Green* da biblioteca *OpenCV*, normalizar e salvar as imagens em uma nova pasta. Dessa forma, as imagens NDVI geradas artificialmente pela mescla das bandas foram utilizadas para treinar modelos de detecção e classificação uni-classe e multi-classe assim como os treinamentos realizados para as outras bandas espectrais.

A Figura 41 ilustra dois exemplos de imagens nas bandas R e NIR-01 utilizadas para compor as imagens NDVI e dois exemplos de detecções pelo algoritmo YOLO nas imagens NDVI nos modelos multi-classe e uni-classe. Nessas imagens, é possível observar o quanto a fusão de duas bandas com características espectrais opostas, tanto para as plantas quanto para o solo, foi capaz de segmentar as plantas do solo, eliminando diversos vestígios de matéria orgânica presente no substrato e destacando as plantas em verde no solo branco após a aplicação do modelo de cor *Deep Green*. Entretanto, a composição dessas imagens foi feita de maneira simplificada, apenas através da aplicação da Equação 2.3 *pixel a pixel* e normalização dos valores obtidos, não sendo realizada nenhuma outra operação à nível de *pixel*. Dessa forma, pequenos desalinhamentos nas imagens R e NIR-01 podem ter sido responsáveis por segmentar o contorno de várias plantas, mas manter o interior (ou parte dele) em branco, o que não prejudicou o processo de detecção.

No geral, processos naturais baseados em assinaturas espectrais para segmentação de objetos no fundo da imagem tendem a melhorar o *Recall* dos modelos sem a necessidade de técnicas mais robustas de pré-processamento de imagens para destacar objetos de interesse, o que pode ser uma grande vantagem para aplicações que devem acontecer em tempo real. Uma vez que o processo de detecção aconteceria em tempo real com o trator se movimentando em altas velocidades, qualquer otimização do tempo de processamento

para realizar o processo de inferência de plantas daninhas desejadas é necessária.

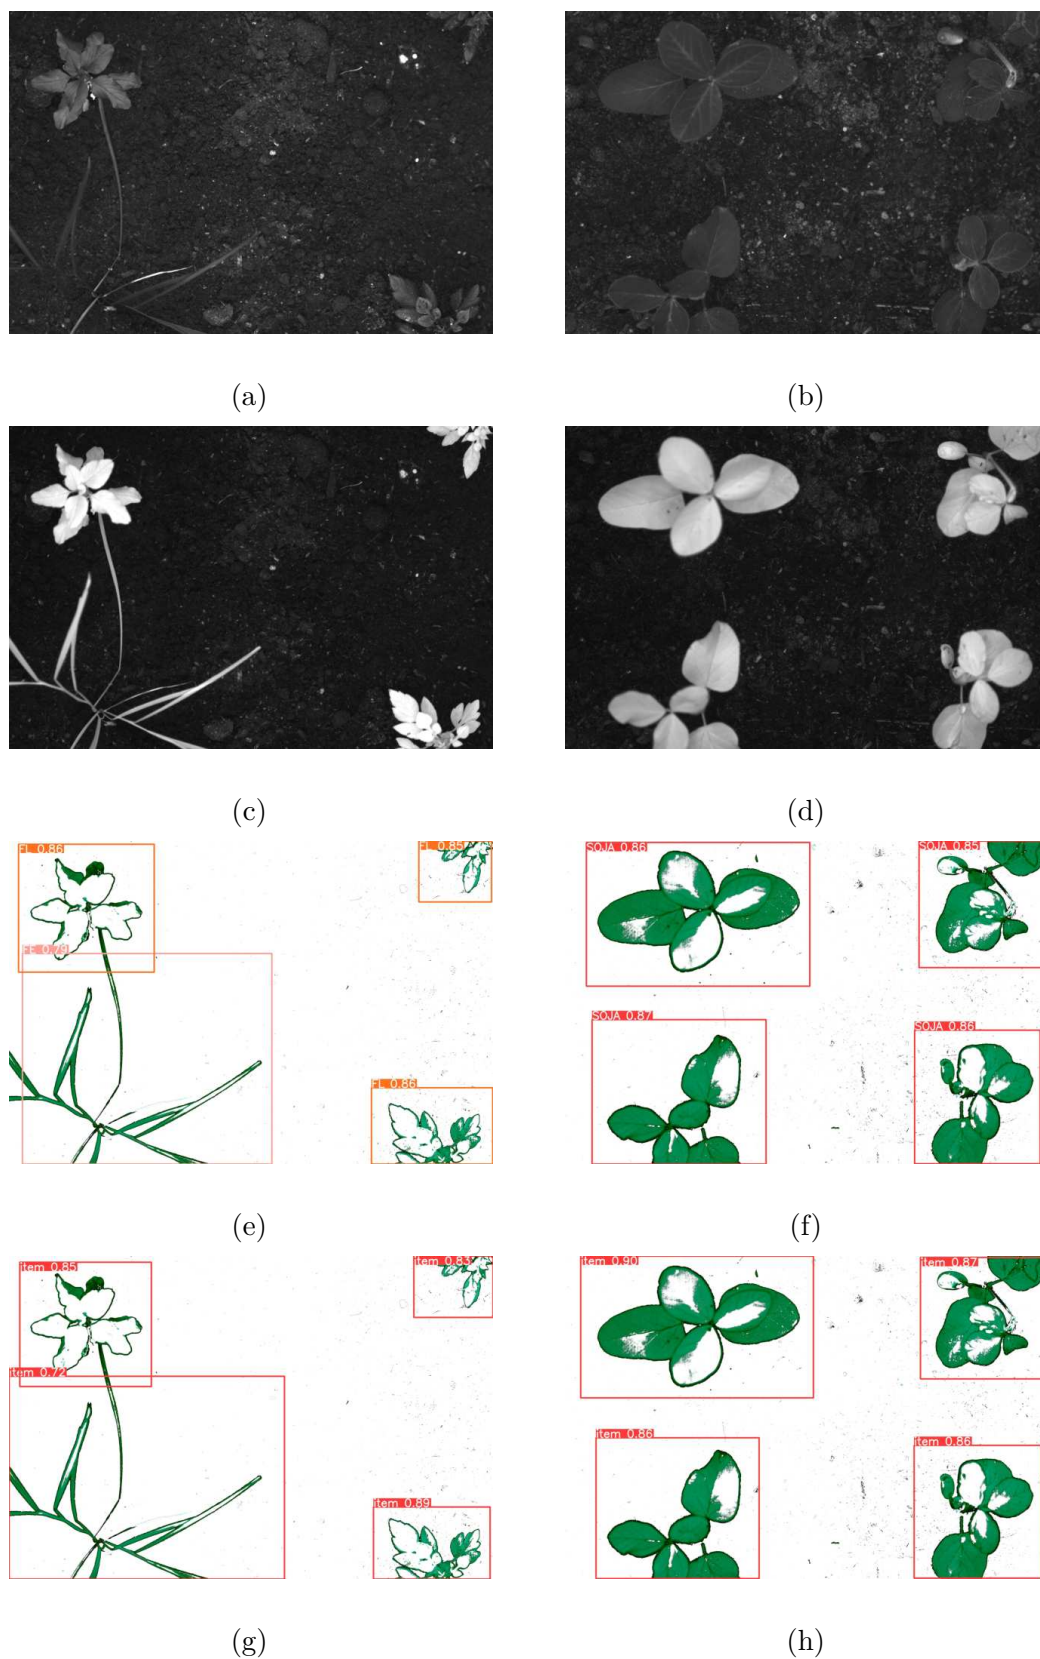



Figura 41 – a) e b) Imagens das bandas R e c) e d) NIR-01 e detecção nas imagens NDVI nos modelos e) e f) multi-classe e g) e h) uni-classe.

Fonte: Elaborada pelo autor


Os resultados obtidos para a métrica *Precision* foram, respectivamente, 0,892 e 0,964 para os modelos multi-classe e uni-classe, com aumento de 8,18% na métrica quando o modelo é simplificado e passa a detectar apenas uma classe (planta) ao invés de três. Calculando a média dos valores de *Precision* obtidos com os modelos de todos os outros doze tipos de imagens (dez bandas espectrais e duas configurações de iluminação para as imagens RGB) nos modelos multi-classe e uni-classe, foi possível observar que os modelos treinados nas imagens NDVI apresentaram aumentos de 4,57 e 3,10%, respectivamente, quando comparados com os valores médios. Para a métrica *Recall*, os resultados foram, respectivamente, 0,893 e 0,909 para os modelos multi-classe e uni-classe, demonstrando que a redução do número de classes nesse caso não melhorou significativamente o processo de detecção. Entretanto, quando esses valores foram comparados com os valores médios obtidos para os respectivos modelos das outras bandas, é possível observar que o modelo multi-classe NDVI apresentou valor de *Recall* 8,50% maior do que a média das outras bandas, enquanto que o modelo uni-classe NDVI apresentou decréscimo de apenas 0,76% com relação à média. O aumento de 8,50% obtido evidencia que as imagens NDVI contribuíram com o processo de detecção de diferentes classes, sugerindo que o contorno das plantas destacados pelo cálculo do NDVI e pela coloração verde imposta pelo mapa de cor influenciaram no processo de aprendizagem do algoritmo. A Figura 42 ilustra as curvas *Precision-Recall* obtidas com os modelos treinados nas imagens NDVI.



(a)

(Continua)

(Continuação)




(b)

Figura 42 – Curvas *Precision-Recall* obtidas nas imagens teste NDVI com os modelos a) multi-classe e b) uni-classe.


Fonte: Elaborada pelo autor.

Na curva *Precision-Recall* do modelo multi-classe NDVI (Figura 42a), é possível observar que as classes que apresentaram maior valor de AP foram, respectivamente, FL, SOJA e FE, e que o valor obtido para a métrica $mAP_{(0,5)}$ foi 0,918, representando um bom resultado no processo de detecção e classificação. A Figura 42b ilustra a curva *Precision-Recall* do modelo uni-classe NDVI, onde é possível observar que o valor de $mAP_{(0,5)}$ foi de 0,968. Quando comparados com os valores médios dos respectivos modelos multi-classe e uni-classe para todas as bandas, os incrementos obtidos com os modelos NDVI foram de, respectivamente, 3,14% e 0,62%. Aumentando novamente a rigidez do processo de detecção, os resultados obtidos para a métrica $mAP_{(0,5;0,95)}$ para os modelos multi-classe e uni-classe foram, respectivamente, 5,90 e 1,31% superiores aos resultados obtidos pelos valores médios dos doze tipos de imagens nos respectivos modelos.

No geral, os modelos NDVI geraram ótimos resultados para a métrica mAP, uma vez que esses modelos apresentaram o segundo melhor resultado para a métrica $mAP_{(0,5;0,95)}$ no modelo multi-classe comparado com os modelos das outras bandas e o sexto melhor resultado no modelo uni-classe, sugerindo que a utilização de imagens multiespectrais construídas através do alinhamento de diferentes bandas espectrais pode apresentar resultados promissores na detecção de plantas daninhas. A Figura 43 ilustra as matrizes de confusão obtidas com os modelos treinados com as imagens NDVI.



(a)



(b)

Figura 43 – Matrizes de confusão obtidas nos modelos a) multi-classe e b) uni-classe.

Fonte: Elaborada pelo autor.

Analisando as matrizes de confusão da Figura 43, é possível observar que no modelo multi-classe NDVI (Figura 43a) cerca de 93% das plantas da classe SOJA, 83% das plantas da classe FE e 94% das plantas da classe FL foram classificadas corretamente. Aproximadamente 17% das plantas da classe FE e 3% das plantas da classe FL não foram detectadas, enquanto que nenhuma planta da classe SOJA deixou de ser detectada. Com relação às plantas da classe SOJA, 7% das plantas foram classificadas como plantas da classe FE, resultado não esperado pelas diferenças das características físicas entre as classes. No modelo uni-classe NDVI (Figura 43b), 95% das plantas presentes no banco de imagens foram detectadas corretamente, enquanto 5% das plantas não foram detectadas. Novamente, foram detectadas plantas no *background*, representando casos falso positivos que devem ser tratados em melhorias futuras do algoritmo para evitar aplicações de herbicidas no solo.

Conclusões parciais:

No geral, os melhores resultados obtidos nessa abordagem utilizando a métrica $mAP_{(0,5;0,95)}$ foram para os modelos multi-classe (FE, FL e SOJA) treinados nas bandas G (0,748), NIR-01 (0,714), R+IR (0,702), IR-780 (0,700) e NIR-02 (0,690), respectivamente, destacando a importância da banda verde no processo de detecção e classificação de plantas daninhas e plantas de soja, assim como de alguns comprimentos de onda do infravermelho próximo e de câmeras com sensor CMOS colorido. Os resultados obtidos nesta abordagem corroboram com os resultados obtidos na primeira abordagem e sugerem a viabilidade de um sistema de detecção composto por uma câmera de sensor CMOS colorido e uma câmera CMOS monocromática contendo um filtro passa banda no comprimento de onda do verde ou do infravermelho próximo para a detecção de plantas. Uma vez que o canal G encontra-se presente na câmera RGB através do filtro de Bayer e poderia ser utilizado individualmente, caso desejado, a incorporação de uma câmera CMOS monocromática contendo um filtro NIR com banda larga e otimizada torna-se uma alternativa promissora. Novamente, a arquitetura de plantas das gramíneas da classe FE (folha estreita), em conjunto com o processo de rotulação adotado, gerou uma grande quantidade de casos falso negativos (ausência de detecção) em praticamente todos os modelos das bandas estudadas. O tempo de inferência necessário para que o algoritmo detectasse e classificasse todas as plantas em uma imagem foi, em média, de 56,5 ms, cerca de 6,1% menor do que a média obtida na primeira abordagem do projeto.

Reduzindo a complexidade do problema, foram testados modelos uni-classe, ou seja, o número de classes reduziu de três para uma, de forma com que a principal tarefa do algoritmo passou a ser apenas a detecção de plantas no substrato, independente se as plantas eram de folha estreita ou folha larga. Nesse caso, os melhores resultados obtidos para a métrica $mAP_{(0,5;0,95)}$ foram para os modelos uni-classe treinados nas bandas IR-780 (0,806), IR-850 (0,793), RGB-LB (0,785), NIR-01 (0,785) e Y (0,783), destacando

quatro bandas do infravermelho próximo entre os cinco melhores resultados no processo de detecção de plantas, fator que pode ser justificado pela segmentação natural das plantas no solo pelas características da assinatura espectral desses indivíduos. O tempo de inferência necessário para que o algoritmo detectasse todas as plantas presentes em uma imagem foi, em média, de 56,1 ms, e não variou significativamente quando comparado com os modelos multi-classe, mesmo após a simplificação da tarefa de classificação do modelo através da redução do número de classes.

Nessa segunda abordagem, a utilização de apenas uma câmera CMOS monocromática em conjunto com a roda de filtros permitiu que as imagens das bandas espectrais fossem capturadas exatamente no mesmo local, permitindo o alinhamento de bandas desejadas. Dessa forma, imagens do índice vegetativo NDVI foram geradas através da fusão das bandas espectrais R e NIR-01 e utilizadas para o treinamento de dois modelos: um modelo multi-classe e um modelo uni-classe. Para o modelo multi-classe, o valor obtido para a métrica $mAP_{(0,5;0,95)}$ foi 0,717, sendo o segundo melhor resultado quando comparado com os outros modelos treinados com as imagens obtidas do sistema da roda de filtros. No caso do modelo uni-classe, o valor obtido para a métrica $mAP_{(0,5;0,95)}$ foi 0,772, sendo o sexto melhor resultado quando comparado com os outros modelos treinados nas demais bandas espectrais. Em ambos os casos, os modelos NDVI apresentaram resultados melhores para a métrica mAP do que a média dos resultados obtidos nos outros doze tipos de imagens (dez bandas espectrais e imagens coloridas com duas configurações de iluminação diferentes). O tempo de inferência nos modelos NDVI se manteve na mesma ordem de grandeza dos tempos obtidos para os outros modelos treinados nessa abordagem, sendo compatível com aplicações em tempo real.

A Tabela 5 resume os melhores resultados obtidos, tanto nos modelos multi-classe, quanto nos modelos uni-classe, para as métricas *Precision*, *Recall*, $mAP_{(0,5)}$ e $mAP_{(0,5;0,95)}$ após aplicação do algoritmo YOLO nas imagens obtidas no sistema da roda de filtros, nas imagens coloridas em duas condições de iluminação e nas imagens NDVI.

Tabela 5 – Resumo dos melhores resultados obtidos para cada métrica nos modelos multi-classe e uni-classe na segunda abordagem do projeto.

Métrica	modelos multi-classe	modelos uni-classe
<i>Precision</i>	RGB-LB (0,952)	NDVI (0,964)
<i>Recall</i>	NDVI (0,893)	IR-780 (0,950)
$mAP_{(0,5)}$	G (0,960)	RGB-LB (0,982)
$mAP_{(0,5;0,95)}$	G (0,748)	IR-780 (0,806)

Fonte: Elaborada pelo autor.

4 DESENVOLVIMENTO EM ILUMINAÇÃO NATURAL

Neste capítulo, é apresentada a metodologia e os resultados da abordagem do projeto realizada em ambiente com iluminação natural, ou seja, em condições de campo, e são descritos em detalhes, o local onde foi realizada a coleta das imagens, a construção do equipamento de campo para coleta de imagens, a construção do banco de imagens propriamente dita, a aplicação do algoritmo YOLO e os resultados obtidos nesta abordagem do projeto.

4.1 Metodologia

4.1.1 Lavoura de soja

O experimento para construção do banco de imagens espectrais contendo indivíduos de plantas de soja e plantas daninhas em iluminação natural foi realizado em uma lavoura de soja na Safra 2022/23 na região de São Carlos - SP. Mais especificamente, a coleta de imagens foi realizada em uma lavoura na região do Santuário da Babilônia, coordenadas $22^{\circ}00'50.2''S$ $47^{\circ}47'27.0''W$, entre o fim do mês de Outubro e início do mês de Novembro de 2022 (Figura 44). A cultura colhida antes da semeadura da soja foi a do sorgo, com a presença de palhada de sorgo em algumas regiões do campo (Figura 44a).



Figura 44 – Lavoura de soja onde foi construído o banco de imagens espectrais em iluminação natural na Safra 2022/23 a) Campo de coleta de imagens após a colheita do sorgo; b) Linhas contendo plantas de soja e plantas daninhas nas entrelinhas.

Fonte: Elaborada pelo autor.

Na Figura 44b, é possível observar as linhas onde foi realizado o plantio de soja com plantas no estágio vegetativo V4 e diversas plantas daninhas nas entrelinhas. Muito provavelmente devido à um manejo inadequado das plantas daninhas presentes no campo, estas estavam presentes desde o início do processo de emergência das plântulas de soja

no campo e aparecem em praticamente todas as imagens coletadas, como poderá ser observado na Seção 4.1.3.

4.1.2 Módulo contendo uma câmera CMOS RGB e uma câmera CMOS monocromática com filtro NIR

O equipamento de campo para captura de imagens (Figura 45a) consiste de um computador embarcado Advantech modelo MIO2360 (Advantech, Estados Unidos), um SSD Kingston com 256 GB de espaço de armazenamento (Kingston, Estados Unidos) e uma câmera multiespectral, em que um sensor CMOS monocromático contendo um filtro passa-banda no infravermelho próximo (NIR: 800-900 nm) acoplado em sua lente está posicionado a uma distância horizontal de 3,6 mm de um sensor CMOS RGB (Figura 45b). Ambas as câmeras possuem sensor ARO0230 com 2,0 *megapixels* de resolução (1920 x 1080 *pixels*). Uma vez que detecções em tempo real utilizando técnicas de IA demandam tempo para as tarefas de captura, processamento, detecção e classificação, optou-se por desenvolver o equipamento de captura e o banco de imagens com uma angulação de 45° com relação a um eixo vertical imaginário (Figura 45c). Dessa forma, em aplicações futuras onde pretende-se instalar esses módulos em tratores, serão detectadas plantas que estão em uma determinada distância à frente do trator, fornecendo tempo suficiente para os processos exigidos pela rede neural nas tarefas de detecção e classificação, e posterior abertura das pontas das pulverização quando a barra de pulverização passar acima do alvo.




Figura 45 – Desenvolvimento do equipamento para construção do banco de imagens em campo. a) Visão geral do módulo de captura de imagens desenvolvido no SolidWorks®; b) Visão interna do módulo de captura de imagens; c) Visão lateral do módulo de captura de imagens evidenciando angulação de 45°.

Fonte: Elaborada pelo autor.

Na Figura 46a, é possível observar a carenagem do equipamento impressa em uma impressora 3D, a câmera multiespectral instalada com lentes de 25 mm de distância focal, a Advantech e os respectivos cabos e conectores necessários para o funcionamento do sistema. Para facilitar e estabilizar o sistema durante o processo de captura, o módulo de captura foi acoplado a um monopé de altura ajustável e à um *display touchscreen* (Figura 46b). O

sistema foi alimentado com uma bateria 12 V comumente utilizada em sistemas de *nobreak*. Foi desenvolvido um *software* em *Docker* que permite com que os parâmetros das câmeras sejam ajustados em tempo real e que as capturas com ambos os sensores sejam realizadas simultaneamente. A Figura 46c ilustra o sistema em funcionamento em campo.




Figura 46 – Equipamento para captura de imagens em campo desenvolvido. a) Equipamento com a câmera multiespectral, sistema embarcado Advantech instalado e com todas as conexões realizadas; b) Visão lateral do equipamento contendo o *display touchscreen* e bateria 12 V de *nobreak*; c) Exemplo do equipamento em pleno funcionamento em campo.

Fonte: Elaborada pelo autor.

4.1.3 Construção do banco de imagens

Foi realizado um experimento de campo em uma lavoura de soja na Safra 2022/23 entre os meses de Outubro e Novembro de 2022 na região de São Carlos - SP para a construção do banco de imagens em iluminação natural. As capturas foram realizadas posicionando-se o equipamento de campo paralelo à linha de plantio de soja e em uma altura de um metro em relação ao solo. Dessa forma, as imagens possuem plantas de soja ao centro e plantas daninhas que estavam presentes ao redor na ocasião. Ao todo, foram capturadas 20.000 imagens contendo indivíduos de plantas de soja e plantas daninhas de diversas espécies. Dessas 20.000 imagens, 10.000 imagens são do tipo RGB e 10.000 são do tipo NIR, e a intersecção entre as imagens é de aproximadamente 97% devido às restrições físicas impostas pelo módulo câmera dupla da câmera multiespectral descrita na Seção 4.1.2. Foram capturadas imagens de plantas de soja entre os estádios vegetativos V1 e V5. A Figura 47 mostra alguns exemplos das imagens RGB e NIR coletadas em campo. O banco de imagens possui imagens com diferentes condições de iluminação natural e apresenta diversos casos de sombra e oclusão, aumentando a representatividade do banco e permitindo que o algoritmo tenha como *inputs* imagens mais complexas.




Figura 47 – Construção do banco de imagens em campo. a), c), e) e g) Exemplos de imagens do tipo RGB coletadas em campo; b), d), f), e h) Exemplos das imagens NIR correspondentes.

Fonte: Elaborada pelo autor.

4.1.4 Aplicação do algoritmo YOLO

Para aplicação do algoritmo de detecção e classificação YOLO, foi realizado o processo de rotulação do banco de imagens no *software* CVAT e as 10.000 imagens de cada câmera foram rotuladas (Figura 48). Assim como no banco de imagens construído na estufa *indoor*, as plantas presentes nas imagens foram divididos em três classes. Entretanto, devido a enorme quantidade de espécies diferentes pertencentes às classes FE (folha estreita) e FL (folha larga) na lavoura, a escolha das classes foi realizada da seguinte maneira:

- SOJA: plantas da espécie *Glycine max* L.
- FE: qualquer espécie de planta daninha de folha estreita presente na lavoura
- FL: qualquer espécie de planta daninha de folha larga presente na lavoura



Figura 48 – Processo de rotulação das imagens em iluminação natural utilizando o *software* CVAT.

Fonte: Elaborada pelo autor.

Durante a etapa de rotulação, optou-se por rotular plantas pequenas presentes nas imagens, desde que as *bounding boxes* necessárias para enquadrá-las não apresentassem tamanho menor do que 150 x 150 *pixels*. As imagens rotuladas, assim como os arquivos de coordenadas correspondentes, foram divididos nos subconjuntos treino, validação e teste, nas proporções 60:20:10, respectivamente. O algoritmo YOLO foi utilizado em sua versão v5, sem mudanças na arquitetura, por 1.000 *epochs* e com valor de *patience* igual a 100, tanto nas imagens RGB obtidas em campo, quanto nas imagens NIR. As métricas utilizadas para análise dos resultados foram *Precision*, *Recall*, $mAP_{(0,5)}$, $mAP_{(0,5;0,95)}$ e tempo de inferência.

4.2 Resultados e discussão

Nesta Seção são apresentados os resultados obtidos após a aplicação do algoritmo YOLO no banco de imagens construído em iluminação natural em uma lavoura de soja na região de São Carlos na Safra 2022/23. A Seção 4.2.1 aborda os resultados obtidos com as imagens do equipamento de campo desenvolvido.

4.2.1 Módulo contendo uma câmera CMOS RGB e uma câmera CMOS monocromática com filtro NIR

A Tabela 6 resume os resultados das principais métricas analisadas para os modelos treinados nas imagens RGB e NIR obtidas em campo.

Tabela 6 – Resultados obtidos para as principais métricas após a aplicação do YOLO v5 nas imagens RGB e NIR de campo.


Imagem	<i>Precision</i>	<i>Recall</i>	mAP (0,5)	mAP (0,5:0,95)	Tempo de inferência (ms)
RGB	0,772	0,726	0,800	0,470	60,1
NIR	0,733	0,735	0,742	0,387	60,3

Fonte: Elaborada pelo autor.


Após a aplicação do algoritmo YOLO v5 nas imagens obtidas em campo, os valores obtidos para a métrica *Precision* foram 0,772 e 0,733, respectivamente, para os modelos treinados nas imagens RGB e NIR. Para a métrica *Recall*, os valores obtidos foram 0,726 e 0,735 para os modelos RGB e NIR, respectivamente. Apesar de os resultados obtidos para as métricas analisadas não terem sido elevados, vale salientar que as imagens de campo apresentam uma grande quantidade de indivíduos e um nível maior de superposição e oclusão, aumentando consideravelmente a complexidade das imagens. A Figura 49 ilustra imagens RGB e NIR do subconjunto teste exemplificando o processo de detecção de plantas de soja e plantas daninhas na lavoura, onde é possível observar a detecção de plantas em diferentes estágios de crescimento.

Uma vez que o experimento de coleta de imagens em campo foi realizado ao longo de um mês, desde os dias que sucederam a emergência de plantas de soja até aproximadamente o estágio vegetativo V5, o banco de imagens contém imagens de plantas daninhas em diferentes estágios de crescimento. As imagens iniciais contém apenas plantas daninhas pequenas, nos estágios iniciais após a emergência em campo e que se replicaram após a aplicação de herbicidas pré-emergentes, e as imagens intermediárias/finais apresentam plantas de maior tamanho e maior quantidade de folhas. Dessa forma, também foram observados problemas encontrados com a rotulação de folhas isoladas de plantas gramíneas da classe FE citado na Seção 3.2.1, assim como problemas gerados pela decisão de rotular plantas daninhas pequenas o suficiente para não aparecerem com boa resolução nas imagens

(exemplo FE 0,56 na Figura 49a). Para elucidar essa questão, será necessária uma revisão do processo de rotulação das plantas presentes nas imagens em trabalhos futuros.



(a)



(b)




(c)




(d)



(e)



(f)



(g)




(h)

(Continua)

(Continuação)



(i)



(j)


Figura 49 – Resultados obtidos com o algoritmo YOLO nas imagens obtidas em uma lavoura de soja. Detecção nas imagens a), c), e) e g) RGB e b), d), f) e h) NIR.

Fonte: Elaborada pelo autor.


O modelo treinado nas imagens RGB apresentou maior valor de *Precision* (0,772) quando comparado com o treinado nas imagens NIR (0,733), sugerindo que as informações de cor presentes nos canais R, G e B da câmera CMOS colorida podem influenciar especificamente o processo de classificação. No caso da métrica *Recall*, o melhor valor foi obtido para o modelo treinado com as imagens NIR (0,735) e foi ligeiramente maior do que aquele obtido para o modelo treinado com as imagens RGB (0,726), demonstrando que comprimentos de onda do infravermelho próximo, mais especificamente em uma banda larga que compreende os comprimentos de onda entre 800 e 900 nm, também desempenha um papel importante no processo de detecção de plantas em condição de campo. Em uma aplicação diurna de verde sobre palhada, ou seja, uma aplicação de dessecação de plantas daninhas presentes em campo antes do plantio da cultura, a cor verde das plantas capturada pela câmera RGB se destaca entre a palhada de coloração predominantemente bege. Em contrapartida, em uma aplicação noturna de verde sobre palhada, a incorporação de um sistema de iluminação contendo LEDs infravermelhos com comprimento de onda entre 800 e 900 nm será responsável por destacar a planta em branco em um fundo escuro.

Apesar de os resultados obtidos para as imagens RGB e NIR obtidas em campo terem apresentado resultados inferiores aos obtidos nas imagens RGB e NIR em laboratório na abordagem da roda de filtros, vale salientar que as imagens de campo apresentam uma complexidade muito maior devido às variações de iluminação, sobreposição de plantas, sombras ocasionadas pela posição do sol principalmente nas imagens coletadas no período da manhã e aglomeração de plantas em determinadas regiões. Além disso, a angulação de 45° imposta pelo equipamento de captura pode ter influenciado o processo de aprendizagem do algoritmo, uma vez que as imagens obtidas focam mais na arquitetura completa das plantas do que nas folhas, como na visão superior (0°) das imagens obtidas em iluminação

artificial. Entretanto, como citado na Seção 4.1.2, a inclinação de 45° junto com a otimização do tempo de inferência da rede desempenharão um papel importante em tarefas futuras de detecção, classificação e pulverização localizada em campo quando um futuro protótipo desenvolvido à partir do equipamento for instalado na barra de pulverização de um trator pulverizador se movendo em velocidades de até 25 km/h. Na Figura 50, é possível observar as curvas *Precision-Recall* dos obtidas com os modelos treinados nas imagens de campo.



(a)




(b)

Figura 50 – Curvas *Precision-Recall* obtidas nas imagens teste a) RGB e da banda b) NIR.

Fonte: Elaborada pelo autor.

Os valores para $mAP_{(0,5)}$ e $mAP_{(0,5;0,95)}$ para todas as classes foram de 0,800 e 0,470, respectivamente, para o modelo RGB e 0,742 e 0,387 para o modelo NIR. Novamente, o modelo treinado com as imagens RGB apresentou resultados ligeiramente melhores quando comparado com os resultados do modelo treinado nas imagens NIR. Comparando individualmente, o maior valor de $mAP_{(0,50)}$ obtido com o modelo RGB foi para a classe FL, enquanto que para o modelo NIR foi para a classe SOJA. A Figura 51 ilustra as matrizes de confusão obtidas nas imagens teste.

Assim como esperado, foram obtidos diversos casos FP e FN de classificações entre plantas e *background* (solo). Além dos fatores supracitados de superposição e oclusão, uma das possíveis causas dessa confusão pode ter sido causada durante o processo de rotulação. Devido às características do sistema óptico utilizado para captura de imagens, a rotulação de plantas muito pequenas que acabaram de emergir do solo e que não apareceram com resolução o suficiente nas imagens pode ter sido responsável por essas classificações equivocadas. Entretanto, vale salientar que em aplicações futuras utilizando um sistema de pulverização localizada baseado em Visão Computacional validado nos modelos treinados com o banco de imagens construído em iluminação natural, a detecção de plantas que acabaram de emergir do solo seriam um possível empecilho para o equipamento, de forma com que essas plantas precisariam ser detectadas em uma posterior aplicação de herbicidas.



(a)

(Continua)

(Continuação)

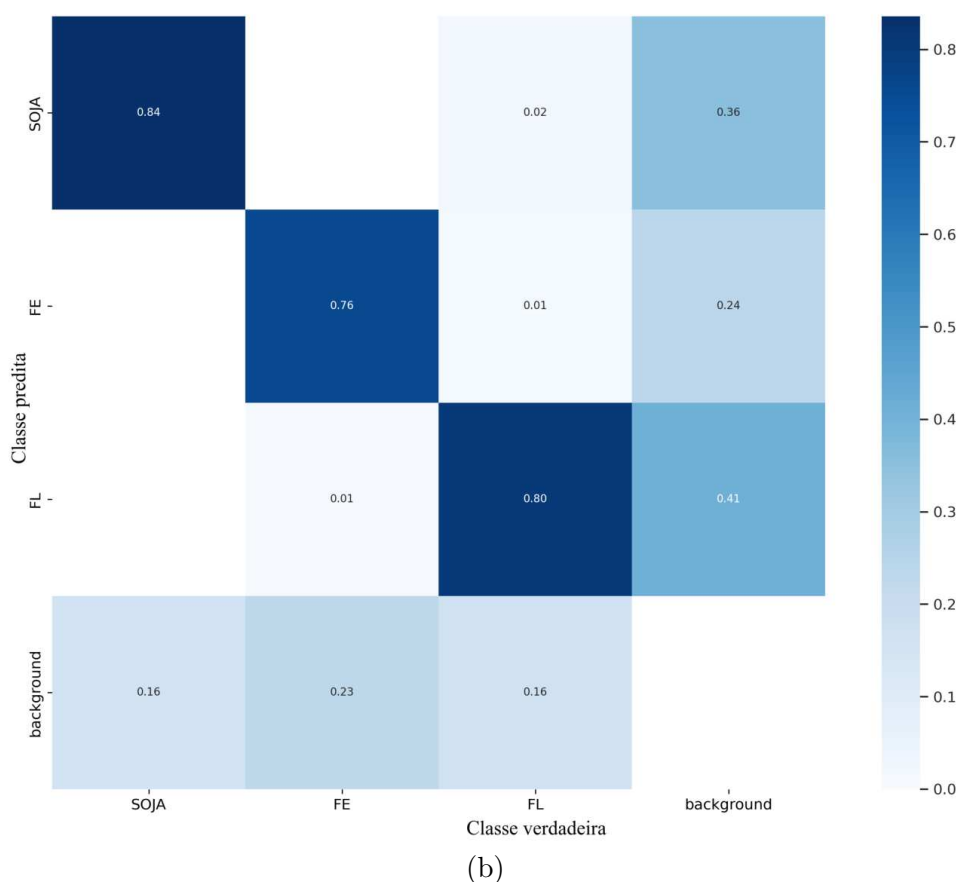


Figura 51 – Matrizes de confusão das imagens teste dos modelos a) RGB e b) NIR.

Fonte: Elaborada pelo autor.

A matriz de confusão mostra que 83% das plantas da classe SOJA, 81% das plantas gramíneas da classe FE e 84% das plantas de folha larga da classe FL foram classificadas corretamente nas respectivas classes no modelo RGB (Figura 51a). Cerca de 1% das plantas da classe FE foram classificadas como FL e 18% das plantas da classe FE foram classificadas como *background* (solo). Com relação à classe FL, 1% das plantas foram classificadas como da classe FE, enquanto 15% das plantas foram classificadas como *background*. Cerca de 17% das plantas da classe SOJA foram classificadas como *background*. Para todas as classes, foi possível observar a existência de detecções que não deveriam existir, ou seja, casos em que plantas foram detectadas onde de fato era *background*.

Para o modelo treinado com as imagens NIR, a matriz de confusão (Figura 51b) mostra que 84% das plantas da classe SOJA, 76% das plantas gramíneas da classe FE e 80% das plantas de folha larga da classe FL foram classificadas corretamente nas respectivas classes. Cerca de 1% das plantas da classe FE foram classificadas como FL e 16% das plantas da classe FE foram classificadas como *background*. Com relação à classe FL, 1%

das plantas foram classificadas como da classe FE, 2% foram classificadas como da classe SOJA e 16% foram classificadas como *background*. Cerca de 16% das plantas da classe SOJA foram classificadas como *background* e nenhuma planta de soja foi classificada erroneamente como uma planta de outra classe. No modelo NIR, também foi possível observar a existência de detecções que não deveriam existir.

O valor médio obtido para o tempo de inferência com os modelos treinados nas imagens RGB e NIR de campo foi de 60,2 ms. Visando entender se o tempo de inferência obtido nos resultados seria suficiente para a detecção e classificação de plantas daninhas pelo algoritmo em tempo real e com o pulverizador se movendo em altas velocidades, o equipamento de captura foi equipado com lentes de 6 mm e posicionado em uma altura de 1,0 m com relação ao chão e angulação de 45 ° com relação à um eixo vertical imaginário, gerando um campo imageado de comprimento 1,0 m e área de 1,4 m² no solo. Considerando o pulverizador se movimentando na velocidade de 25 km/h (6,94 m/s), levaria aproximadamente 144 ms para que a área de 1,4 m² fosse percorrida nas imagens obtidas pelas câmeras, possibilitando que o algoritmo realizasse o processo de detecção e classificação em pelo menos dois *frames* (120,4 ms). Uma vez que a aquisição das imagens é realizada com câmeras que capturam imagens à 30 *frames* por segundo (30 FPS), uma mesma planta irá aparecer em quatro *frames* consecutivos no intervalo de 144 ms. Dessa forma, o algoritmo terá a possibilidade de detectar as plantas desejadas em 50% dos *frames* disponíveis, o que pode ser suficiente para as aplicações localizadas de herbicidas caso o modelo apresente bons valores para as métricas *Precision*, *Recall* e mAPs. Como alternativas, a melhoria dos modelos de detecção, assim como a aquisição de uma câmera multispectral capaz de adquirir dados em uma taxa de FPS maior, possivelmente trariam resultados melhores e ainda mais compatíveis com aplicações em tempo real e, principalmente, com sistemas em movimento.

Conclusões parciais:

No geral, os resultados obtidos comprovam a importância da incorporação de uma câmera que capture imagens no comprimento de onda do infravermelho próximo (NIR) em conjunto com uma câmera colorida (RGB) para tarefas de detecção e classificação de plantas de soja e plantas daninhas em condições de campo através da utilização de técnicas de Visão Computacional. Como próximos passos para projetos futuros, novos algoritmos de detecção em um estágio e/ou novas versões do algoritmo YOLO podem ser implementadas visando aumentar os valores de *Precision*, *Recall* e mAP obtidos neste trabalho e focando, principalmente, na diminuição de casos falso negativos (FN) em que plantas daninhas não são detectadas e conseqüentemente não receberiam a aplicação de herbicidas em um aplicação real em campo. O tempo de inferência se manteve por volta dos 60,2 ms, sendo compatível com aplicações em tempo real utilizando *hardwares* embarcados adequados

e com GPU* dedicada. Entretanto, esses resultados podem ser aperfeiçoados através de melhorias nos modelos de Inteligência Artificial empregados para as tarefas de detecção e classificação, assim como através de melhorias de *hardware*, mais especificamente na utilização de câmeras capazes de adquirir imagens acima em taxas acima de 30 *frames* por segundo.

Comparando os resultados para as imagens RGB-LB obtidas em iluminação artificial na abordagem da roda de filtros com as imagens RGB obtidas em iluminação natural, o segundo caso apresentou valores menores para quase todas as métricas analisadas. No caso das métricas *Precision* e *Recall*, os decréscimos foram de 18,9% e 10,5%, respectivamente, o que já era esperado uma vez que as imagens obtidas em iluminação artificial são mais padronizadas e apresentam pouca sobreposição. Além disso, essas imagens não possuem exemplos de plantas em áreas sombreadas, uma vez que a iluminação utilizada na estufa *indoor* fica logo acima do equipamento de captura e manteve-se padronizada. As métricas $mAP_{(0,5)}$ e $mAP_{(0,5;0,95)}$ para as imagens RGB em iluminação natural obtiveram decréscimos de 11,3% e 31,3%, respectivamente, com relação às imagens RGB-LB em iluminação artificial, demonstrando que o algoritmo YOLO precisa ser aperfeiçoado para lidar com tarefas de detecção e classificação em imagens mais complexas.

Com relação à banda no infravermelho próximo, comparando os resultados obtidos com o modelo treinado nas imagens da banda NIR em campo (800-900 nm) com o modelo treinado nas imagens do filtro passa-alta IR-780 na abordagem da roda de filtros, devido à proximidade da banda compreendida em ambos os casos, os decréscimos nos resultados obtidos para as métricas *Precision* e *Recall* foram, respectivamente, 10,5% e 13,1% para o modelo treinado nas imagens NIR em iluminação natural. As métricas $mAP_{(0,5)}$ e $mAP_{(0,5;0,95)}$ para as imagens NIR em iluminação natural obtiveram decréscimos de 19,2% e 44,7%, respectivamente, com relação às imagens do filtro IR-780 em iluminação artificial, resultados que precisam ser aprimorados para que a câmera infravermelha desempenhe um papel importante nas detecções e classificações em campo.

O valor médio obtido para o tempo de inferência do algoritmo para as imagens de campo (60,2 ms) foi 6,5% maior do que aquele obtido em iluminação artificial (56,5 ms), o que poderia ser considerado um resultado positivo devido ao fato de que a maioria das imagens de campo apresentam uma quantidade de plantas por imagem muito superior do que as imagens de laboratório.

Para melhorias na generalização do processo de detecção de plantas daninhas e plantas da lavoura em condições de campo, é imprescindível que, em projetos futuros, o banco de imagens multiespectrais construído em uma lavoura de soja neste projeto seja ampliado, englobando imagens de plantas de soja em diversos estádios vegetativos, assim como imagens de dezenas de outras espécies de plantas daninhas, variando as condições

* Do inglês, *Graphics Processing Unit*

de iluminação (sol, nublado, penumbra, período noturno) e eventualmente a angulação do sistema de captura. Além disso, a criação de bancos de imagens multiespectrais de outras culturas como a do milho, por exemplo, faz-se necessária em um futuro próximo, onde almeja-se o desenvolvimento de um equipamento de pulverização localizada para atuar principalmente nas lavouras brasileiras, país onde é bem difundido o plantio de duas Safras por ano agrícola.

5 DESENVOLVIMENTO TECNOLÓGICO

O presente projeto de pesquisa foi incorporado pelo autor no departamento de Pesquisa e Desenvolvimento da *startup* Agrio Tecnologia LTDA, criada em 2021 para o desenvolvimento de tecnologias voltadas para a Agricultura de Precisão utilizando técnicas de Visão Computacional, Inteligência Artificial, Óptica e Eletrônica, e as metodologias e resultados que aqui aparecem foram desenvolvidas na *startup* pelo autor desta tes. A Agrio está situada na cidade de São Carlos - SP e seu time de desenvolvedores é composto por técnicos, engenheiros de diversas áreas, mestrandos, doutorandos e doutores em física, física computacional e física biomolecular e um consultor na área de engenharia agrônoma.



Figura 52 – Logo da *startup* Agrio Tecnologia LTDA.

Fonte: Elaborada pelo autor.

A *startup* participou da rodada PIPE-SIMPLES lançada pela FAPESP em 2022 através do envio de um projeto para desenvolvimento da prova de conceito de um equipamento de pulverização localizada de herbicidas utilizando imagens multiespectrais e Visão Computacional (Processo FAPESP - 2022/06153-2). O projeto evoluiu do nível de maturidade tecnológica TRL 1 até o nível TRL 4. No nível de maturidade tecnológica TRL 1, foi realizada uma revisão bibliográfica do estado da arte científico em detecção de plantas daninhas e também do estado da arte tecnológico em pulverização localizada, elencando os principais avanços científicos ao redor do mundo e os principais equipamentos desenvolvidos e comercializados. Dessa forma, os princípios básicos foram observados, reportados, e o projeto foi elaborado visando buscar características inovativas nas vertentes científica e tecnológica. No nível TRL 2, o conceito de um sistema detector baseado em Visão Computacional e imagens multiespectrais foi formulado e as aplicações da tecnologia foram sondadas. No nível TRL 3, foi realizada a prova de conceito das funções críticas de forma experimental, através da construção dos bancos de imagens multiespectrais e da utilização de técnicas de Visão Computacional e algoritmos de Inteligência Artificial para detectar e classificar as plantas presentes nas imagens, tanto em ambiente com iluminação artificial, quanto em condições de campo, observando as possíveis limitações do projeto. No nível TRL 4, foi realizada a validação em ambiente de laboratório, utilizando o sistema de trilhos para movimentar o sistema de detecção, simulando o movimento do trator, para realizar as tarefas de detecção e classificação de plantas de soja e plantas daninhas, assim como uma versão prévia do sistema de pulverização em funcionamento. Nessa etapa,

destacam-se a construção de um sistema de trilhos contendo nove metros de barra *v-slot* para o movimento do sistema, o desenvolvimento preliminar do sistema de pulverização contendo uma barra úmida e quatro conjuntos válvula PWM + corpo de bico + ponta de pulverização espaçados de 25 cm, assim como uma interface com o usuário preliminar para o controle da operação. A Figura 53 ilustra o sistema de trilhos, o sistema de pulverização e o equipamento instalado para o processo de validação em ambiente de laboratório.

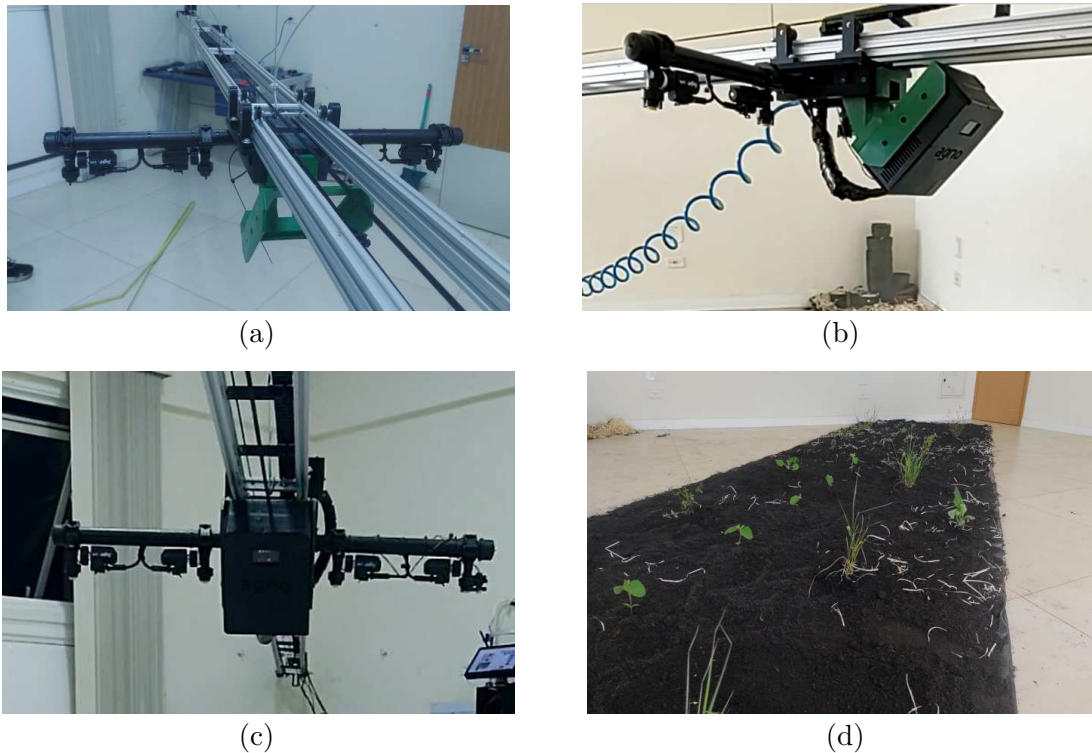


Figura 53 – Desenvolvimento do nível de maturidade tecnológica TRL 4. a) Sistema de trilhos com nove metros de barras *v-slot*; b) Visão lateral do equipamento instalado com a barra de pulverização no sistema de trilhos; c) Visão frontal do equipamento evidenciando barra de pulverização e válvulas PWM; d) *Design* experimental com plantas de soja e daninhas utilizado para validação.

Fonte: Elaborada pelo autor.

Na Figura 53a, é possível observar o sistema de trilhos construído através da união de duas barras *v-slot* de nove metros de comprimento, assim como o suporte para o módulo detector (em verde) e o início do desenvolvimento da barra de pulverização. Na Figura 53b, é possível observar a visão lateral do módulo de detecção instalado no suporte. A Figura 53c ilustra a visão frontal do sistema, onde é possível observar a miniatura de uma barra de pulverização desenvolvida, assim como os conjuntos válvula PWM + corpo de bico + ponta de pulverização igualmente espaçados de 25 cm. Na Figura 53d, é possível observar a versão do *design* experimental implementado na validação do sistema, com plantas daninhas espalhadas aleatoriamente e plantas de soja posicionadas em um canteiro central seguindo o espaçamento praticado entre plantas praticado em campo.

Atualmente, a *startup* Agrio Tecnologia encontra-se no processo de finalização do PIPE - SIMPLES (2022/06153-2) e com projeto de continuação PIPE FASE II submetido à FAPESP, cujo objetivo principal é desenvolver um sistema de pulverização localizada de herbicidas para instalação em tratores pulverizadores agrícolas utilizando Visão Computacional e imagens multiespectrais. A detecção e classificação das imagens multiespectrais de plantas de soja e plantas daninhas utilizando algoritmos de Inteligência Artificial será responsável por aumentar a precisão do processo decisório tanto nas aplicações de dessecação, quanto nas aplicações pós-emergência da cultura em campo, uma vez que os comprimentos de onda do infravermelho próximo desempenham um papel fundamental na assinatura espectral das plantas. Com o desenvolvimento desta tecnologia para instalação em maquinários agrícolas, espera-se uma redução considerável na utilização de herbicidas, uma vez que essas substâncias serão aplicadas de forma localizada, ou seja, apenas nas plantas daninhas detectadas pelo sistema, contribuindo com a redução dos custos do produtor na compra de defensivos, redução do impacto ambiental causado pela aplicação dessas substâncias em área total, redução do surgimento de casos de plantas daninhas resistentes aos herbicidas amplamente utilizados em campo e aumento da qualidade dos alimentos produzidos.

Com a eventual aprovação do PIPE FASE II, o projeto iniciará no nível de maturidade tecnológica TRL 4 e pretende-se alcançar o nível TRL 6 ao final de 24 meses de desenvolvimento. A evolução do sistema do nível TRL 4 para o nível TRL 5 envolverá adaptações e incrementos necessários para validar o sistema em ambiente relevante através de testes que serão realizados com o módulo detector em condições reais de campo, visando a detecção e classificação em tempo real de plantas de soja e plantas daninhas encontradas em lavouras na região de São Carlos na Safra 2024/25. A transição para o nível de maturidade TRL 6 envolve a instalação do protótipo funcional em um veículo automotor contendo uma barra de pulverização para demonstração em ambiente relevante. Nessa última etapa, o protótipo será instalado na barra de pulverização do veículo e deverá detectar as plantas presentes na lavoura utilizando as imagens multiespectrais obtidas, classificar entre plantas de soja e plantas daninhas utilizando os algoritmos de IA, realizar os cálculos necessários e aplicar os herbicidas apenas nas plantas daninhas detectadas, de forma com que tudo ocorra em tempo real com o veículo se movendo em velocidades de até 25 km/h. Durante a validação em campo, espera-se que a acurácia do processo de detecção e classificação efetuada pelo protótipo seja acima de 99% para aplicações de dessecação e no mínimo 95% nas aplicações após a emergência da cultura da soja.

5.1 Metodologia

A eletrônica do sistema de pulverização será composta por um módulo na cabine do trator, aqui chamado de CONTROLADOR e diversos módulos independentes posici-

onados a cada um metro nas barras de pulverização, aqui chamado de UNIDADE DE PULVERIZAÇÃO. Todas as UNIDADE DE PULVERIZAÇÃO serão conectadas com o CONTROLADOR através de uma rede ISOBUS, que irá comandar cada unidade de forma independente permitindo ativá-la, desativá-la, além de receber dados relacionados a aplicação do herbicida.

Cada UNIDADE DE PULVERIZAÇÃO será um sistema fechado composto por uma câmera multiespectral que faz a captação da imagem do solo, um processador especializado em Inteligência Artificial que recebe as imagens e decide se há plantas daninhas a serem pulverizadas e quatro pontas de pulverização ligados a barra do herbicida pressurizado. Cada ponta de pulverização pode ser acionada independentemente a uma taxa de até 20 Hz, permitindo modulação na aplicação. A cada 10 ms, uma foto é tirada e enviada ao processador que a segmenta em quatro faixas. Se a rede neural implementada pela IA identificar que nessa faixa existe uma planta daninha, ela irá enviar um comando para o acionamento da ponta de pulverização correspondente.

O CONTROLADOR possuirá um sistema de GPS que será responsável pelo sincronismo entre a captação da imagem, o processamento e a aplicação do herbicida com o trator em movimento. Sua precisão média será de 5 cm e irá informar a todos os módulos de UNIDADE DE PULVERIZAÇÃO a velocidade real do trator. Ela também possuirá um ecrã que mostrará o mapa de aplicação, taxa de pulverização e demais informações relevantes ao controle. Visando possibilitar aplicações noturnas, cada UNIDADE DE PULVERIZAÇÃO terá um módulo de iluminação composto por LEDs brancos e infravermelhos. Esses LEDs serão comandados pela unidade CONTROLADORA quando necessário.

5.1.1 Unidade de pulverização

A unidade de pulverização será composta por um computador embarcado, uma placa de circuito impresso, uma placa de LEDs e uma câmera multiespectral. A câmera multiespectral é composta por um módulo contendo uma câmera CMOS RGB e uma câmera CMOS monocromática com filtro passa-banda no infravermelho próximo (NIR: 800 - 900 nm). O computador embarcado será responsável por controlar a aquisição das imagens multiespectrais com a câmera multiespectral via protocolo USB, processamento das imagens, aplicação da rede de Inteligência Artificial para as tarefas de detecção e classificação de plantas de soja e plantas daninhas, cálculo das posições das plantas daninhas detectadas nas imagens e envio dos comandos de abertura de pontas de pulverização para a placa de circuito impresso. A placa de circuito impresso, por sua vez, receberá esses comandos e, através deles, controlará as válvulas PWM responsáveis por modular a abertura/fechamento das pontas de pulverização de acordo com o tempo necessário para que a aplicação forneça cobertura suficiente das plantas daninhas detectadas com o herbicida aplicado. Além disso, a placa de circuito impresso também será responsável por controlar uma placa de LEDs

contendo LEDs branco e LEDs no infravermelho próximo (800-900 nm), permitindo que o equipamento seja utilizado em aplicações noturnas ou em condições desfavoráveis de iluminação presentes principalmente no fim do dia (penumbra). A Figura 54 ilustra o desenvolvimento do conceito da UNIDADE DE PULVERIZAÇÃO.




Figura 54 – Desenvolvimento 3D do conceito da UNIDADE DE PULVERIZAÇÃO no *software* Solid Works®. a) Visão frontal, b) interna, c) traseira; d) e lateral.

Fonte: Elaborada pelo autor.

Na Figura 54a, é possível observar a visão frontal do conceito 3D da UNIDADE DE PULVERIZAÇÃO. A carenagem do protótipo será, inicialmente, usinada com material ainda em estudo para auxiliar no processo de dissipação de calor gerado pelo computador

embarcado. Assim como é possível observar na Figura 54a, duas janelas de vidro estarão presentes na parte frontal da carenagem, a primeira alinhada com o conjunto de lentes da câmera multiespectral e a segunda posicionada em frente o sistema de iluminação. Na Figura 54b, é possível observar o módulo da câmera multiespectral posicionado no topo, a placa de circuito impresso de iluminação contendo LEDs branco frios e LEDs infravermelho próximo (800-900 nm), a placa de circuito impresso que será desenvolvida para controle das válvulas PWM representado em verde e a placa do computador embarcado que será utilizado também representado em verde. Na Figura 54c, é possível observar a parte traseira da carenagem que será desenvolvida, onde estão presentes haletas responsáveis por auxiliar no processo de dissipação do calor gerado pela eletrônica do sistema. Por fim, na Figura 54d é possível observar a visão lateral da carenagem e um dos conectores que será utilizado para conectar o cabeamento de alimentação das placas, alimentação das válvulas PWM e da conexão ISOBUS.

5.1.2 Controlador

O CONTROLADOR será composto por um computador embarcado, um *display touchscreen* e um *gateway* ISOBUS. O objetivo do CONTROLADOR é coordenar todas as UNIDADES DE PULVERIZAÇÃO instaladas na barra de pulverização via *gateway* ISOBUS através de uma interface com o usuário e, portanto, deverá ser instalado dentro da cabine do trator pulverizador, permitindo a alternância entre três modos de pulverização: modo convencional, modo taxa mínima e modo pulverização localizada. No modo convencional, a UNIDADE DE PULVERIZAÇÃO não será utilizada para detecção de plantas daninhas e sim apenas para controle das válvulas PWM visando aplicações em área total, caso desejado pelo produtor. No módulo taxa mínima, a UNIDADE DE PULVERIZAÇÃO modula o processo de abertura/fechamento das válvulas PWM e, conseqüentemente, das pontas de pulverização, visando a aplicação de doses reduzidas de herbicida em área total, de forma com que a dose completa é aplicada apenas nas plantas daninhas detectadas pela UNIDADE DE PULVERIZAÇÃO. No modo pulverização localizada, as válvulas PWM e as pontas de pulverização permanecerão fechadas durante todo o percurso, abrindo para aplicação de herbicida apenas quando uma planta daninha é detectada pela UNIDADE DE PULVERIZAÇÃO. Através do CONTROLADOR, também será possível ajustar parâmetros importantes como, por exemplo, o tamanho da área de pulverização ao redor de cada planta daninha detectada.

5.1.3 Barra de pulverização

Durante o projeto, será desenvolvida uma versão em menor escala de uma barra de pulverização para instalação em um veículo automotor. A barra de pulverização possuirá quatro metros de comprimento em cada lado e permitirá a instalação de até três

UNIDADES DE PULVERIZAÇÃO igualmente espaçadas de um metro em cada lado. A Figura 55 ilustra o conceito 3D da barra de pulverização.




Figura 55 – Desenvolvimento 3D do conceito da barra de pulverização que será instalada em veículo automotor projetada no *software* Solid Works®. a) Visão completa; b) Visão frontal com duas UNIDADES DE PULVERIZAÇÃO; c) Visão lateral com duas UNIDADES DE PULVERIZAÇÃO.

Fonte: Elaborada pelo autor.

Dentro do veículo automotor, será instalado um conjunto contendo um galão de 50 L com água e uma bomba pressurizadora 12 V desenvolvida especialmente para processos de pulverização. A água pressurizada, simulando os herbicidas utilizados em campo, passará por uma barra úmida que será acoplada na estrutura da barra de pulverização a ser desenvolvida. Serão instalados quatro conjuntos porta bico + válvula PWM + ponta de pulverização igualmente espaçados de 25 cm para cada uma das UNIDADES DE PULVERIZAÇÃO. O espaçamento de 25 cm entre as pontas de pulverização é de extrema importância para as aplicações de pulverização localizada, uma vez que é necessário uma precisão da ordem de centímetros para que as plantas detectadas recebam a aplicação do

herbicida de maneira adequada. Cada UNIDADE DE PULVERIZAÇÃO será responsável por controlar quatro conjuntos porta bico + válvula PWM + ponta de pulverização através de conexões realizadas entre o cabeamento das válvulas PWM e os conectores de 12 pinos que estarão presentes na carenagem do protótipo. A instalação das UNIDADES DE PULVERIZAÇÃO na barra de pulverização será realizada utilizando suportes de aço que, a princípio, permitirão modificações na altura e no ângulo de inclinação dos módulos, permitindo a realização de ajustes para otimização do sistema em campo, caso necessário.

Na Figura 55a, é possível observar a estrutura completa da barra de pulverização que será desenvolvida ao decorrer do projeto, com duas hastes e suportes ajustáveis para instalação das UNIDADES DE PULVERIZAÇÃO. A barra úmida responsável por movimentar a água pressurizada proveniente do galão de 50 L, assim como os conjuntos porta bico + válvula PWM + pontas de pulverização não foram representadas no conceito apresentado na Figura 55a. Nas Figuras 55b e 55c, é possível observar as visões frontal e lateral de duas UNIDADES DE PULVERIZAÇÃO instaladas na barra de pulverização.

A construção da barra para instalação das UNIDADES DE PULVERIZAÇÃO e do sistema de pulverização com água pressurizada tem como principais objetivos: 1) a retroalimentação do banco de dados e 2) a validação do sistema em condições de campo.

1. Atualmente o banco de dados utilizado conta com aproximadamente 20.000 imagens capturadas em campo, sendo por volta de 10.000 imagens RGB e 10.000 na banda NIR. Por se tratar do desenvolvimento de modelos de Inteligência Artificial, é muito importante que a quantidade de imagens seja suficientemente grande, de forma a permitir a criação de modelos robustos, com boa capacidade de generalização. Para a continuidade da aquisição de imagens, a fim de aumentar o banco de dados, tanto com imagens RGB quanto com NIR, a instalação das UNIDADES DE PULVERIZAÇÃO na barra de pulverização do veículo automotor auxiliará na captura de imagens, simulando as condições encontradas em campo. Esta estrutura permite a variação de parâmetros como ângulo de inclinação e altura da câmera, que podem impactar diretamente na qualidade e complexidade das imagens para o treinamento do modelo preditivo. Além disso, serão obtidas imagens em diferentes horários do dia, incluindo o período da noite, para que o banco de imagens possua condições suficientemente variadas e mais próximas ao ambiente real de aplicação.
2. O nível de maturidade tecnológica TRL 6 almejado envolve a validação de um protótipo funcional em ambiente relevante. Dessa forma, a unificação dos sistemas (veículo automotor, barra de pulverização, sistema de pulverização, CONTROLADOR e seis UNIDADES DE PULVERIZAÇÃO) é de extrema importância para validação do sistema em condições de campo. Espera-se que, nestes testes, o processo de detecção, classificação e pulverização de água seja realizado em tempo real com o

veículo automotor se movendo em velocidades de até 25 km/h. Para as aplicações de dessecação, espera-se que a acurácia atingida no processo seja acima de 99%, enquanto que para aplicações após a emergência da cultura da soja, espera-se que a acurácia do processo seja de no mínimo 95%.

Visando o desenvolvimento do protótipo de um equipamento de pulverização localizada, a equipe de P&D da Agrio conseguiu firmar três parcerias importantes que serão indispensáveis no decorrer do projeto:

1. Considerando a fase de validação em ambiente real, destaca-se a parceria com uma grande produtora rural da região de Boa Esperança do Sul - SP, a Anna Paula Nunes, que além de ser uma grande produtora de grãos de soja, tem em seu quadro de funcionários um tecnólogo em mecanização agrícola de precisão, profissional que se responsabiliza pelo uso adequado de máquinas e implementos agrícolas voltados a Agricultura de Precisão. A parceria tem como objetivo permitir, por parte da equipe de P&D da Agrio Tecnologia, o acesso às terras produtivas durante a etapa de pré-dessecação, dessecação e fases iniciais do plantio de soja, visando testes e validações do sistema em uso real nos pretendidos momentos do plantio. Ainda contaremos com o apoio dos funcionários da produtora para discussões sobre o processo de cultivo e pulverização nas Safras 2023/24 e 2024/25, sempre visando melhorias e avanços da tecnologia.
2. Fazenda Jangada Brava, também de propriedade de Anna Paula Nunes, a qual consta de 1.030 alqueires e um amplo parque de máquinas de última geração para o manejo do solo, plantio, tratos culturais e colheita dos grãos. Esta parceria tem como objetivo permitir o acesso da equipe de P&D da Agrio Tecnologia ao parque de máquinas para estudos do processo de pulverização e projetos de instalação em pulverizadores autopropelidos, futura instalação das UNIDADES DE PULVERIZAÇÃO nos pulverizadores e o apoio de funcionários da fazenda no processo de pulverização localizada durante a safra 2024/2025 com equipamento já embarcado.
3. MP Agro Máquinas Agrícolas LTDA, empresa concebida com o propósito de trazer soluções tecnológicas a baixo custo ao mercado agrícola a partir da necessidade de aproveitamento de autopropelidos e tratores utilizados para outras funções na fazenda, tornando-os mais eficientes e produtivos no campo. A empresa desenvolve máquinas e implementos de alta qualidade, tecnologia e robustez ao produtor, sendo a primeira empresa brasileira a manufaturar implementos agrícolas com estrutura 100% em aço inoxidável, especialmente voltados para adubação e fertilização do solo, se tornando referência no segmento. A parceria firmada entre a empresa MP Agro e a *startup* Agrio Tecnologia tem por objetivo a transferência de conhecimento

de instalações em maquinários agrícolas de grande porte, o auxílio nas etapas de comunicação do equipamento de pulverização localizada a ser desenvolvido com o sistema operacional dos tratores via comunicação ISOBUS, assim como indicações de fornecedores consagrados na área. A parceria firmada ainda considera o apoio no desenvolvimento da rede de distribuição comercial e colocação do produto no mercado.

As parcerias aqui apresentadas têm como objetivo, além do desenvolvimento do protótipo e produto em questão, colocar a tecnologia brasileira em destaque em uma área de extrema importância e benéfica para o desenvolvimento mundial, que é a Agricultura de Precisão.

5.2 Resultados e discussão

Atualmente, algumas entregas propostas foram atingidas pela equipe de P&D da Agrio Tecnologia no desenvolvimento do protótipo de um equipamento para pulverização localizada de herbicidas utilizando imagens multiespectrais e Visão Computacional. Como avanços, é possível citar a usinagem de uma UNIDADE DE PULVERIZAÇÃO para instalação dos componentes ópticos e eletrônicos e realizar os primeiros testes em campo. Inicialmente, a carenagem foi usinada em alumínio com objetivo de atuar como dissipador de calor para a eletrônica e o computador embarcado presente no interior. Serão realizados testes em diversas condições de temperatura em campo, com e sem a placa de iluminação ligada, visando monitorar a temperatura da GPU do computador embarcado.

A Figura 56 ilustra o desenvolvimento inicial proposto para a UNIDADE DE PULVERIZAÇÃO. Na Figura 56a, é possível observar a carenagem da UNIDADE DE PULVERIZAÇÃO usinada em alumínio, com a câmera multiespectral instalada na extremidade superior e com a placa de LEDs na extremidade inferior. A carenagem foi anodizada para proteção do equipamento contra processos de oxidação e corrosão. A proteção das lentes das câmeras e da placa de LEDs foi feita com vidro de espessura 2 mm, proporcionando duas janelas transparentes necessárias para a passagem de luz. Na Figura 56b, é possível observar a UNIDADE DE PULVERIZAÇÃO instalada na haste de fixação do equipamento na barra de pulverização do pulverizador. Essa haste permite ajustes na altura do módulo e futuramente permitirá mudanças no ângulo, caso necessário. A Figura 56c ilustra o interior da carenagem da UNIDADE DE PULVERIZAÇÃO, onde é possível observar o computador embarcado em conjunto com a placa eletrônica de controle, o módulo da câmera multiespectral instalado e a placa de iluminação contendo LEDs brancos e infravermelhos próximo.




Figura 56 – Desenvolvimento inicial da UNIDADE DE PULVERIZAÇÃO. a) Carenagem desenvolvida em alumínio, anodizada e fechada; b) Instalação na haste de fixação no trator; c) Carenagem aberta com componentes ópticos e eletrônicos instalados.

Fonte: Elaborada pelo autor.

Outra entrega concluída foi a construção de uma das barras de pulverização para instalação em veículo automotor (Figura 57). A estrutura da barra foi feita com chapas de aço dobradas na forma de U e soldadas seguindo os desenhos desenvolvidos anteriormente.



Figura 57 – Barra de pulverização em menor escala desenvolvida para instalação em veículo automotor visando a construção de novos bancos de imagens multispectrais em campo e validação do sistema. a) Barra aberta; b) Barra fechada.

Fonte: Elaborada pelo autor.

Na Figura 57a, é possível observar a barra de pulverização aberta instalada em um veículo automotor para posterior instalação de três UNIDADES DE PULVERIZAÇÃO visando a retroalimentação do banco de imagens e os processos de validação da tecnologia. Após desenvolvido, o CONTROLADOR será instalado dentro do veículo, simulando a instalação dentro da cabine do trator para que o operador consiga ativar/desativar o

equipamento. O conjunto galão de 50 L + bomba pressurizadora para pulverização também serão instalados no interior do veículo. Na Figura 57b, é possível observar a barra fechada, possibilitando que o equipamento seja transportado para lavouras presentes em diferentes localidades ao redor do estado.

Através da parceria com a empresa MP Agro, a *startup* Agrio Tecnologia conseguiu recentemente acesso à um pulverizador autopropelido da Jacto com 22 metros de barra presente nas instalações de teste da primeira empresa, permitindo com que os colaboradores da Agrio recebessem treinamento técnico para pilotar e controlar as barras de pulverização do trator. Dessa forma, foi realizado um teste em campo para instalação de um módulo detector na extremidade da barra de pulverização visando a gravação de vídeos com o trator se movimentando em diferentes velocidades. A escolha da instalação do equipamento na extremidade da barra foi para estudar o efeito da movimentação desta (tanto no sentido vertical, quanto no sentido horizontal) nas imagens obtidas pela câmera multiespectral, uma vez que o efeito causado pelo grande comprimento da barra é mais acentuado nas extremidades. Além disso, o peso da UNIDADE DE PULVERIZAÇÃO é um fator a ser considerado e eventualmente otimizado, uma vez, no produto final, uma unidade será instalada à cada metro de barra.

O objetivo deste primeiro teste em campo foi testar como a captura de imagens em diferentes velocidades e com a barra de pulverização se movimentando afetaria as imagens obtidas. Para isso, foram gravados diferentes vídeos com o módulo da câmera multiespectral nas seguintes velocidades: 7,5, 10,0, 15,0, 20,0 e 25,0 km/h, sendo a velocidade de 25,0 km/h a velocidade máxima em que os equipamentos dos concorrentes conseguem atuar com eficácia. Os vídeos capturados foram separados em milhares de *frames* e estão sendo analisados para comprovar se as imagens foram obtidas com boa qualidade e sem a presença do efeito *blur*, em que imagens ficam desfocadas quando capturadas em movimento. Apesar de o campo de testes da empresa MP Agro não representar o local ideal para teste do algoritmo, uma vez que o chão é recoberto de grama com poucas plantas daninhas espalhadas, diferente da palhada deixada pelo plantio direto na maioria das lavouras brasileiras, os modelos de IA treinados neste trabalho serão utilizados para analisar o processo de detecção em tempo real em ambiente relevante. A Figura 58 ilustra a instalação de uma UNIDADE DE PULVERIZAÇÃO no pulverizador autopropelido da empresa MP Agro para captura de imagens em movimento.



(a)



(b)



(c)



(d)



(e)

Figura 58 – Instalação de uma UNIDADE DE PULVERIZAÇÃO em um pulverizador autopropelido para realização de testes de captura de imagens em altas velocidades. a) Pulverizador utilizado; b) Visão frontal; Visão lateral c) esquerda e d) direita da unidade; e) Unidade capturando imagens em movimento.

Fonte: Elaborada pelo autor.

Na Figura 58a, é possível observar o pulverizador autopropelido da empresa MP Agro no qual foi instalado a UNIDADE DE PULVERIZAÇÃO do sistema de pulverização localizada da Agrio Tecnologia. Na Figura 58b é possível observar a UNIDADE DE PULVERIZAÇÃO instalada na haste de fixação que, por sua vez, encontra-se instalada em dois pontos na barra de pulverização. Nas Figuras 58c e 58d, é possível observar as laterais esquerda e direita, respectivamente, da UNIDADE DE PULVERIZAÇÃO, assim como o

conduíte passando a fiação elétrica para alimentação do módulo através de duas baterias 12 V posicionadas perto da cabine do trator. Por fim, na Figura 58e, é possível observar a UNIDADE DE PULVERIZAÇÃO instalada na extremidade da barra de pulverização capturando imagens com o pulverizador autopropelido em movimento.

Os modelos treinados nas imagens RGB e NIR obtidas em campo na Seção 4.1 foram utilizados para realizar tarefas preliminares de detecção nos vídeos obtidos pela UNIDADE DE PULVERIZAÇÃO instalada no pulverizador autopropelido se movendo à 10 km/h. Assim como é possível observar na Figura 59, diversas plantas não foram detectadas, sugerindo que o algoritmo precisa ser melhorado e incluir imagens obtidas com as lentes de 6 mm utilizadas nesse teste. Também será necessário otimizar novamente os parâmetros das câmeras, uma vez que a intensidade da iluminação solar tende a saturar os sensores CMOS das câmeras, tornando as imagens esbranquiçadas.

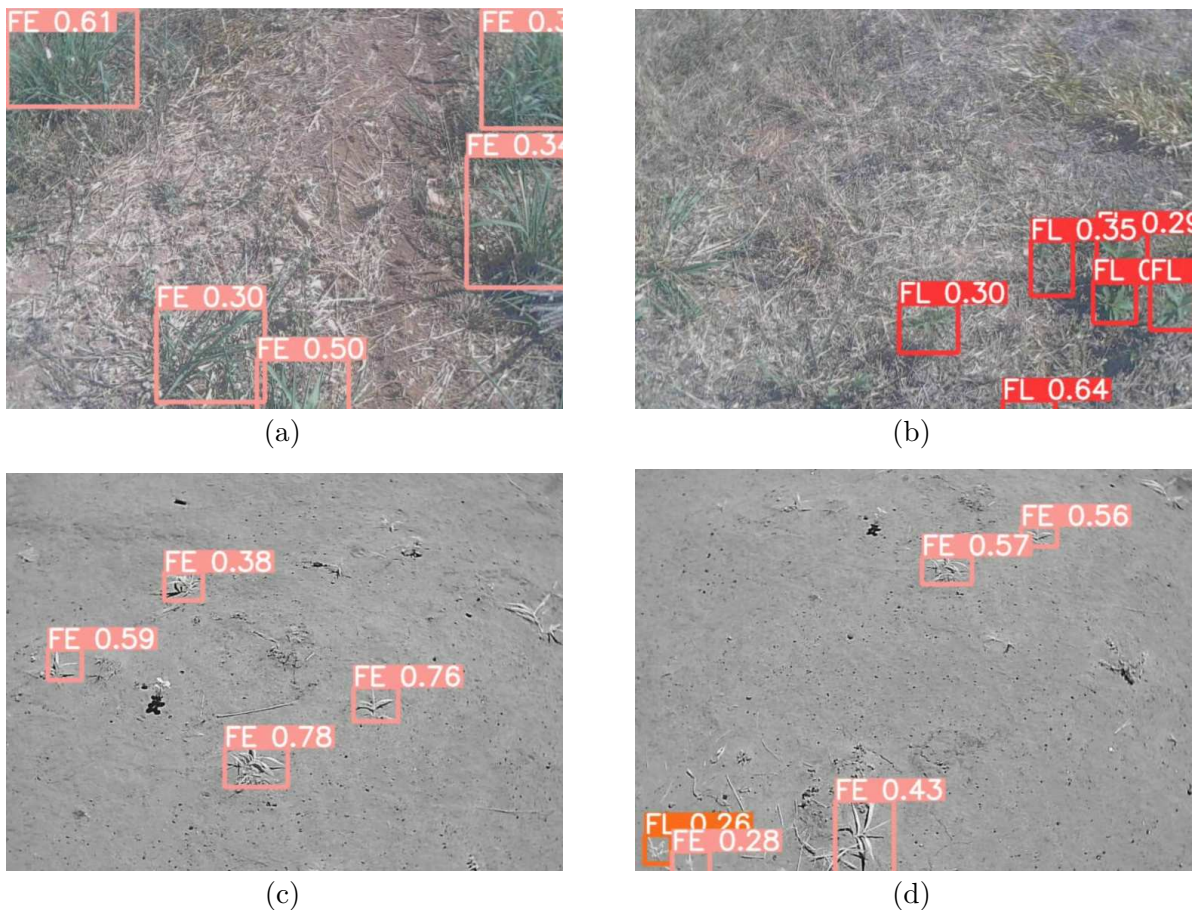


Figura 59 – Exemplo do processo de detecção de plantas daninhas nas imagens obtidas no primeiro teste com a UNIDADE DE PULVERIZAÇÃO instalada em um pulverizador autopropelido. a) e b) Detecção nas imagens RGB; c) e d) Detecção nas imagens NIR;

Fonte: Elaborada pelo autor.

De forma reduzida, os próximos passos do desenvolvimento tecnológico do projeto são listados à seguir:

1. Desenvolvimento de uma unidade do CONTROLADOR;
2. Retroalimentação do banco de imagens multiespectrais em lavouras de soja utilizando a barra de pulverização instalada no veículo automotor;
3. Melhorias nos algoritmos de detecção e classificação;
4. Desenvolvimento de seis UNIDADES DE PULVERIZAÇÃO para instalação na barra de pulverização do veículo automotor;
5. Instalação de seis UNIDADES DE PULVERIZAÇÃO e uma unidade do CONTROLADOR no pulverizador autopropelido para validação do protótipo funcional em lavouras de soja através da detecção, classificação e pulverização localizada em tempo real com o veículo em movimento, em aplicações de dessecação e após a emergência da cultura da soja em campo.

6 CONSIDERAÇÕES FINAIS

A pulverização localizada de herbicidas em plantas daninhas é de extrema importância para o progresso de uma agricultura mais sustentável para o Brasil. O país, reconhecido como um dos maiores produtores de alimentos do mundo, carece do desenvolvimento de novas tecnologias nacionais voltadas para a área de Agricultura de Precisão. Com o constante crescimento de investimentos na área de Inteligência Artificial voltada para a agricultura, técnicas de Visão Computacional surgem como uma promissora abordagem para a detecção em tempo real de plantas daninhas em campo em aplicações de herbicidas pós-emergentes. O objetivo principal desse trabalho consiste em detectar e classificar plantas daninhas entre plantas de soja, em ambiente com iluminação artificial e natural, utilizando Inteligência Artificial e imagens multiespectrais.

Os resultados obtidos indicam que o algoritmo YOLO é capaz de detectar plantas de soja e plantas daninhas em ambiente com iluminação artificial em todas as bandas utilizadas, mesmo com um número limitado de imagens obtido após a construção de dois bancos de imagens em uma estufa *indoor*. Na primeira abordagem em iluminação artificial utilizando um sistema com cinco câmeras, os melhores resultados obtidos para as métricas *Precision* e *Recall* foram para os modelos treinados nas imagens RGB (0,796 e 0,758), IR (0,778 e 0,733) e NIR (0,731 e 0,718), respectivamente. O mesmo padrão seguiu para a métrica $mAP_{(0,5)}$, considerada a mais importante para algoritmos de detecção e classificação, com os melhores resultados obtidos para os modelos treinados nas imagens RGB (0,798), IR (0,746) e NIR (0,712), demonstrando a importância da captura de imagens de plantas em comprimentos de onda do infravermelho devido às características da assinatura espectral desses indivíduos.

Na segunda abordagem em iluminação natural utilizando um sistema contendo uma roda de filtros espectrais, os melhores resultados obtidos para a métrica *Precision* para os modelos treinados nas imagens G (0,956), RGB-LB (0,952), RGB-FS (0,935) e NIR-01 (0,841), enquanto que os melhores resultados obtidos para a métrica *Recall* foram para os modelos treinados nas imagens G (0,885), NIR-02 (0,874), UV+B (0,853) e IR-780 (0,846). Com relação à métrica $mAP_{(0,5)}$, os melhores resultados obtidos foram para os modelos treinados nas imagens G (0,960), IR-780 (0,919), NIR-01 (0,902) e RGB-LB (0,902) e NIR-02 (0,897), destacando a presença de três comprimentos de onda do infravermelho próximo entre os cinco melhores resultados obtidos para a métrica. Aumentando a rigidez do processo de detecção, a métrica $mAP_{(0,5;0,95)}$ foi responsável por destacar quatro comprimentos de onda do infravermelho próximo entre os cinco melhores resultados, na ordem decrescente: G (0,748), NIR-01 (0,714), R+IR (0,702), IR-780 (0,700) e NIR-02 (0,690). Reduzindo a quantidade de classes de três (FE, FL e SOJA) para uma

(plantas), os melhores resultados obtidos para a métrica $mAP_{(0,5;0,95)}$ foram para os modelos treinados nas imagens IR-780 (0,806), IR-850 (0,793), RGB-LB (0,785) e NIR-01 (0,785), demonstrando que modelos treinados nas bandas do infravermelho próximo seriam melhor utilizados em aplicações de "verde-sobre-palhada", ou seja, aplicações de herbicidas antes do plantio da cultura, onde a tarefa principal do algoritmo seria detectar apenas plantas em solo coberto por palha da cultura anterior. Ainda nessa abordagem do projeto, imagens do índice vegetativo NDVI foram geradas através da fusão das imagens das bandas espectrais R e NIR-01 e foram treinados modelos com classificação multi-classe e uni-classe. Quando comparados com os resultados das outras bandas espectrais, os resultados para a métrica $mAP_{(0,5;0,95)}$ demonstraram que os modelos NDVI multi-classe e uni-classe ficaram entre os melhores modelos treinados, o que era esperado devido ao processo de segmentação das plantas no solo ao combinar duas bandas espectrais com características opostas.

Buscando compreender como o algoritmo lidaria com imagens mais complexas, com número maior de plantas, casos de sobreposição/sombras e para futuras aplicações reais em campo, foi construído um banco de imagens em iluminação natural contendo 10.000 imagens RGB e 10.000 imagens NIR em uma lavoura de soja na Safra 2022/23 na região de São Carlos - SP. Com o modelo treinado nas imagens RGB obtidas em campo, os valores obtidos foram 0,772 para a métrica *Precision* e 0,726 para a *Recall*, enquanto que os valores obtidos para essas métricas no modelo treinado nas imagens NIR foram 0,733 e 0,735, respectivamente. O valor da métrica $mAP_{(0,5)}$ foi de 0,800 para o modelo RGB e 0,742 para o modelo NIR, resultados que poderiam ser suficientes para tarefas de detecção, classificação e posterior aplicação localizada de herbicidas em campo, mas que idealmente deveriam ser aperfeiçoados através da implementação de novos modelos visando melhorar a acurácia do processo.

No geral, os valores médios dos tempos de inferência necessários para que os modelos detectassem e classificassem todas as plantas presentes em uma imagem variaram de 56,6 ms na segunda abordagem em iluminação artificial para 60,2 ms na terceira abordagem, em iluminação natural, sendo resultados compatíveis com aplicações em tempo real, mesmo com os sistemas de captura de imagens em movimento.

Como avanços de cunho científico, é possível destacar o estudo da influência de diferentes comprimentos de onda no processo de detecção e classificação de plantas de soja e plantas daninhas, destacando a importância dos comprimentos de onda do infravermelho próximo no processo de segmentação natural das plantas no solo e corroborando com os padrões conhecidos de suas assinaturas espectrais. Além disso, é possível destacar a criação e rotulação de três bancos de imagens contendo imagens de plantas de soja e de três espécies importantes de plantas daninhas que, juntos, totalizam 45.440 imagens multispectrais em diferentes bandas contendo informações espectrais importantes de plantas gravadas.

De mesma forma, é possível destacar os avanços tecnológicos e empresariais através da incorporação do projeto na empresa Agrio Tecnologia LTDA, o que trouxe grandes avanços para o projeto através da solicitação de dois financiamentos: um PIPE-SIMPLES aprovado para desenvolvimento de uma prova de conceito e um PIPE FASE II ainda em análise para desenvolvimento de um protótipo através dos conhecimentos construídos em parte por este projeto. Além disso, a incorporação do projeto na empresa agregou uma equipe multidisciplinar e diversas parcerias que vêm colaborando para que o projeto um dia se torne um produto com alto nível tecnológico agregado, aumentando a sustentabilidade da agricultura brasileira através da redução significativa de herbicidas aplicados em campo, reduzindo a poluição ambiental causada por essas substâncias, prevenindo o surgimento de resistência das plantas daninhas aos herbicidas amplamente aplicados, contribuindo com a rentabilidade do produtor rural e contribuindo com a Agricultura 4.0 no Brasil.

REFERÊNCIAS

- 1 BASSOI, L. H. *et al.* Agricultura de precisão e agricultura digital. **TECCOGS: revista digital de tecnologias cognitivas**, n. 20, jul./dez. 2019. DOI: 10.23925/1984-3585.2019i20p17-36.
- 2 ELI-CHUKWU, N. C. Applications of artificial intelligence in agriculture: a review. **Engineering, Technology & Applied Science Research**, v. 9, n. 4, p. 4377–4383, 2019.
- 3 PONTES, L. B.; CAVICHIOLI, F. A. **Agricultura de Precisão**. Disponível em: <https://simtec.fatectq.edu.br/index.php/simtec/article/view/367/257>. Acesso em: 23 jan. 2023.
- 4 ISLAM, N. *et al.* Early weed detection using image processing and machine learning techniques in an australian chilli farm. **Agriculture**, v. 11, n. 5, p. 387, 2021.
- 5 FUNKE, T. *et al.* Molecular basis for the herbicide resistance of roundup ready crops. **Proceedings of the National Academy of Sciences**, v. 103, n. 35, p. 13010–13015, 2006.
- 6 PEREIRA, C. *et al.* News techniques for the application of herbicides on soybean crops. **Planta Daninha**, v. 36, 2018. DOI: 10.1590/S0100-83582018360100091.
- 7 REEG, J. *et al.* Potential impact of effects on reproductive attributes induced by herbicides on a plant community. **Environmental Toxicology and Chemistry**, v. 37, n. 6, p. 1707–1722, 2018.
- 8 RUUSKANEN, S. *et al.* Ecosystem consequences of herbicides: the role of microbiome. **Trends in Ecology & Evolution**, v.38, n.1, p. 35-43, 2022.
- 9 PETERSON, M. A. *et al.* The challenge of herbicide resistance around the world: a current summary. **Pest Management Science**, v. 74, n. 10, p. 2246–2259, 2018.
- 10 GAINES, T. A.; BUSI, R.; KÜPPER, A. Can new herbicide discovery allow weed management to outpace resistance evolution? **Pest Management Science**, v. 77, n. 7, p. 3036–3041, 2021.
- 11 TSOUROS, D. C.; BIBI, S.; SARIGIANNIDIS, P. G. A review on uav-based applications for precision agriculture. **Information**, v. 10, n. 11, p. 349, 2019.
- 12 LIU, B.; BRUCH, R. Weed detection for selective spraying: a review. **Current Robotics Reports**, v. 1, n. 1, p. 19–26, 2020.
- 13 BECKIE, H. J.; ASHWORTH, M. B.; FLOWER, K. C. Herbicide resistance management: recent developments and trends. **Plants**, v. 8, n. 6, p. 161, 2019.
- 14 WANG, A.; ZHANG, W.; WEI, X. A review on weed detection using ground-based machine vision and image processing techniques. **Computers and Electronics in Agriculture**, v. 158, p. 226–240, 2019. DOI: 10.1016/j.compag.2019.02.005.

- 15 YU, J. *et al.* Weed detection in perennial ryegrass with deep learning convolutional neural network. **Frontiers in Plant Science**, v. 10, p. 1422, 2019. DOI: 10.3389/fpls.2019.01422.
- 16 XUE, Y. *et al.* Maf-yolo: multi-modal attention fusion based yolo for pedestrian detection. **Infrared Physics & Technology**, v. 118, p. 103906, 2021. DOI: 10.1016/j.infrared.2021.103906.
- 17 YU, Z. *et al.* Recognition and monitoring of the feeding behavior of dairy cows based on video and tcs-yolo model. 2022. DOI: 10.21203/rs.3.rs-1743573/v1.
- 18 WANG, Q. *et al.* A deep learning approach incorporating yolo v5 and attention mechanisms for field real-time detection of the invasive weed solanum rostratum dunal seedlings. **Computers and Electronics in Agriculture**, v. 199, p. 107194, 2022. DOI: 10.1016/j.compag.2022.107194.
- 19 OSORIO, K. *et al.* A deep learning approach for weed detection in lettuce crops using multispectral images. **AgriEngineering**, v. 2, n. 3, p. 471–488, 2020.
- 20 YING, B. *et al.* Weed detection in images of carrot fields based on improved yolo v4. **Traitement du Signal**, v. 38, n. 2, p. 341–348, 2021.
- 21 CHEN, J. *et al.* Weed detection in sesame fields using a yolo model with an enhanced attention mechanism and feature fusion. **Computers and Electronics in Agriculture**, v. 202, p. 107412, 2022. DOI: 10.1016/j.compag.2022.107412.
- 22 BARNHART, I. H. *et al.* Use of open-source object detection algorithms to detect palmer amaranth (*amaranthus palmeri*) in soybean. **Weed Science**, v. 70, n. 6, p. 648–662, 2022.
- 23 PANPATTE, S.; GANESHKUMAR, C. Artificial intelligence in agriculture sector: case study of blue river technology. *In: INTERNATIONAL CONFERENCE ON INFORMATION MANAGEMENT AND MACHINE INTELLIGENCE*, 2., 2021, Singapore. **Proceedings [...]**. Singapore: Springer, 2021. p. 147–153. (Lecture notes in networks and systems, v. 166).
- 24 REHMAN, T. U. *et al.* Current and future applications of statistical machine learning algorithms for agricultural machine vision systems. **Computers and Electronics in Agriculture**, v. 156, p. 585–605, 2019.
- 25 HASAN, A. M. *et al.* A survey of deep learning techniques for weed detection from images. **Computers and Electronics in Agriculture**, v. 184, n. 3, p. 106067, 2021.
- 26 FANG, P. *et al.* Aboveground biomass mapping of crops supported by improved casa model and sentinel-2 multispectral imagery. **Remote Sensing**, v. 13, n. 14, p. 2755, 2021.
- 27 SA, I. *et al.* Weedmap: a large-scale semantic weed mapping framework using aerial multispectral imaging and deep neural network for precision farming. **Remote Sensing**, v. 10, n. 9, p. 1423, 2018.
- 28 WILKE, N. *et al.* Assessment of plant density for barley and wheat using uav multispectral imagery for high-throughput field phenotyping. **Computers and Electronics in Agriculture**, v. 189, p. 106380, 2021.

- 29 KARPYSHEV, P. *et al.* Autonomous mobile robot for apple plant disease detection based on cnn and multi-spectral vision system. *In: IEEE/SICE INTERNATIONAL SYMPOSIUM ON SYSTEM INTEGRATION (SII)*, 2021, Iwaki, Fukushima. **Proceedings [...]**. Iwaki, Fukushima: IEEE, 2021. p. 157–162.
- 30 EMBRAPA. **Trajatória da agricultura brasileira**. Disponível em: <https://www.embrapa.br/visao/trajetoria-da-agricultura-brasileira>. Acesso em: 14 jun. 2023.
- 31 IPEA. **Revisão da previsão de crescimento do PIB agropecuário brasileiro em 2020**: atualização de abril. Disponível em: <http://www.ipea.gov.br/cartadeconjuntura/index.php/2020/04/29/boletim-agro-2/>. Acesso em: 14 jun. 2023.
- 32 CEPEA. **PIB do agronegócio brasileiro**. Disponível em: <https://www.cepea.esalq.usp.br/br/pib-do-agronegocio-brasileiro.aspx>. Acesso em: 14 jun. 2023.
- 33 PAM. **Produção agrícola municipal**: principais resultados. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9117-producao-agricola-municipal-culturas-temporarias-e-permanentes.html>. Acesso em: 14 jun. 2023.
- 34 CEPEA. **Após alcançar patamar recorde em 2021, PIB do agronegócio recua 4,22% em 2022**. Disponível em: <https://www.cepea.esalq.usp.br/upload/kceditor/files/PIB-DO-AGRONEGOCIO-2022.17MAR2023.pdf>. Acesso em: 15 jun. 2023.
- 35 MONTEIRO, J. E. *et al.* **Agrometeorologia dos cultivos**: o fator meteorológico na produção agrícola. Brasília: INMET, 2009.
- 36 SHARMA, S. *et al.* Physical characteristics and nutritional composition of some new soybean (glycine max (l.) merrill) genotypes. **Journal of Food Science and Technology**, v. 51, n. 3, p. 551–557, 2014.
- 37 BISCHOFF, T. Z. *et al.* Technological quality of soybean oil obtained from stored grain under controlled environmental conditions. **Engenharia Agrícola**, v. 36, n. 6, p. 1145–1156, 2016.
- 38 FARIAS, J. R. B.; NEPOMUCENO, A. L.; NEUMAIER, N. **Ecofisiologia da soja**. Londrina: Embrapa, 2007. (Circular técnica, n. 48).
- 39 CEPEA. **PIB da cadeia de soja**. Disponível em: <https://cepea.esalq.usp.br/br/pib-da-cadeia-de-soja.aspx>. Acesso em: 15 jun. 2023.
- 40 CONAB. **Boletim da safra de grãos**. Disponível em: <https://www.conab.gov.br/info/safras/graos/boletim-da-safra-de-graos>. Acesso em: 15 jun. 2023.
- 41 UNITED STATES DEPARTMENT OF AGRICULTURE. World Agricultural Production. **Brazil soybean**: record output expected despite severe drought in rio grande do sul. Disponível em: <https://downloads.usda.library.cornell.edu/usda-esmis/files/5q47rn72z/sb397t758/2j62sq079/production.pdf>. Acesso em: 15 jun. 2023.
- 42 UNITED STATES DEPARTMENT OF AGRICULTURE. World Agricultural Production. **Ethiopia wheat**: drought and conflict reduces wheat production estimate. Disponível em: <https://apps.fas.usda.gov/psdonline/circulars/production.pdf>. Acesso em: 15 jun. 2023.

- 43 OLIVEIRA, R. P. D. *et al.* **Contributions towards decision support for site-specific crop management - a study of aspects influencing the development of knowledge-intensive differential management decisions.** 2009. Ph. D. Thesis (Doctor of Ph Philosophy) - Faculty of Agriculture, Food and Natural Resources, University of Sydney, Sydney, 2009.
- 44 XMOBOTS. **XMobots: sky is our field.** 2020. Disponível em: <https://xmrobots.com.br/>. Acesso em: 30 jan. 2023.
- 45 ARANTES, B. H. T. *et al.* Drone aplicado na agricultura digital. **Ipê Agronomic Journal**, v. 3, n. 1, p. 14–18, 2019.
- 46 BREUNIG, F. M.; GALVÃO, L. S.; MARTINS NETO, R. P. Drones na agricultura de precisão. *In*: PRUDKIN, G.; BREUNIG, F. M. **Drones e ciência: teoria e aplicações metodológicas.** Santa Maria: FACOS-UFSM, 2019. v. 1, p. 91.
- 47 GONZALEZ, R. C.; WOODS, R. E. **Digital image processing.** 3rd ed. Upper Saddle River: Pearson Prentice Hall, 2008.
- 48 GAMAL, A. E.; ELTOUKHY, H. CMOS image sensors. **IEEE Circuits and Devices Magazine**, v. 21, n. 3, p. 6–20, 2005.
- 49 PETERSON, C. How it works: the charged-coupled device, or CCD. **Journal of Young Investigators**, v. 3, n. 1, 2001. Disponível em: <https://www.if.ufrgs.br/marcia/ccd.pdf>. Acesso em: 23 jan. 2023.
- 50 IMAGING DEVELOPMENT SYSTEMS. **Color filter (Bayer filter).** 2022. Disponível em: https://www.1stvision.com/cameras/IDS/IDS-manuals/uEye_Manual/hw_farbfilter_bayerfilter.html. Acesso em: 15 jun. 2023.
- 51 BIGAS, M. *et al.* Review of CMOS image sensors. **Microelectronics Journal**, v. 37, n. 5, p. 433–451, 2006.
- 52 INPE. **Introdução ao sensoriamento remoto.** 2006. Disponível em: <http://www3.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm#vania>. Acesso em: 30 jan. 2023.
- 53 BARET, F.; ANDRIEU, B.; GUYOT, G. A simple model for leaf optical properties in visible and near-infrared: application to the analysis of spectral shifts determinism. *In*: LICHTENTHALER, H. K. (ed). **Applications of chlorophyll fluorescence in photosynthesis research, stress physiology, hydrobiology and remote sensing.** Dordrecht: Springer, 1988. p. 345–351.
- 54 DATT, B. Visible/near infrared reflectance and chlorophyll content in eucalyptus leaves. **International Journal of Remote Sensing**, v. 20, n. 14, p. 2741–2759, 1999.
- 55 BACKES, A. R.; SÁ JUNIOR, J. J. M. **Introdução à visão computacional usando Matlab.** Rio de Janeiro: Alta Books Editora, 2019.
- 56 MOHANTY, S. P.; HUGHES, D. P.; SALATHÉ, M. Using deep learning for image-based plant disease detection. **Frontiers in Plant Science**, v. 7, p. 1419, 2016. DOI: 10.3389/fpls.2016.08.024.

-
- 57 DYRMANN, M.; KARSTOFT, H.; MIDTIBY, H. S. Plant species classification using deep convolutional neural network. **Biosystems Engineering**, v. 151, p. 72–80, 2016. DOI: 10.1016/j.biosystemseng.2016.08.024.
- 58 ZEILER, M. D.; FERGUS, R. Visualizing and understanding convolutional networks. *In: FLEET, D. et al. (ed.). European conference on computer vision*. Cham: Springer, 2014. p. 818–833.
- 59 DESHPANDE. **A beginner’s guide to understanding convolutional neural networks**. 2016. Disponível em: <https://adeshpande3.github.io/A-Beginner%27s-Guide-To-Understanding-Convolutional-Neural-Networks/>. Acesso em: 30 jan. 2023.
- 60 ZHANG, H.; HONG, X. Recent progresses on object detection: a brief review. **Multimedia Tools and Applications**, v. 78, n. 19, p. 27809–27847, 2019.
- 61 XIAO, Y. *et al.* A review of object detection based on deep learning. **Multimedia Tools and Applications**, v. 79, p. 23729–23791, 2020. DOI: 10.1007/s11042-020-08976-6.
- 62 ZHAI, S. *et al.* DF-SSD: an improved SSD object detection algorithm based on densenet and feature fusion. **IEEE Access**, v. 8, p. 24344–24357, 2020. DOI: 10.1109/ACCESS.2020.2971026.
- 63 GONG, M. *et al.* A review of non-maximum suppression algorithms for deep learning target detection. *In: SYMPOSIUM ON NOVEL PHOTOELECTRONIC DETECTION TECHNOLOGY AND APPLICATIONS*, 7., 2021, Kunming, China. **Proceedings [...]**. Kunming, China: SPIE, 2021. p. 821–828.
- 64 REN, J.; WANG, Y. Overview of object detection algorithms using convolutional neural networks. **Journal of Computer and Communications**, v. 10, n. 1, p. 115–132, 2022.
- 65 KUMAR, A.; ZHANG, Z. J.; LYU, H. Object detection in real time based on improved single shot multi-box detector algorithm. **EURASIP Journal on Wireless Communications and Networking**, v. 2020, n. 1, p. 1–18, 2020.
- 66 JIANG, P. *et al.* A review of yolo algorithm developments. **Procedia Computer Science**, v. 199, p. 1066–1073, 2022. DOI: 10.1016/j.procs.2022.01.135.
- 67 PADILLA, R.; LIMA NETTO, S.; SILVA, E. A. D. A survey on performance metrics for object-detection algorithms. *In: INTERNATIONAL CONFERENCE ON SYSTEMS, SIGNALS AND IMAGE PROCESSING (IWSSIP)*, 2020, Niteroi. **Proceedings [...]** Niteroi: IEEE, 2020. p. 237–242.
- 68 REDMON, J. *et al.* You only look once: unified, real-time object detection. *In: CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION*, 2016, Las Vegas. **Proceedings [...]** Las Vegas: IEEE, 2016. p. 779–788.
- 69 WANG, C.-Y.; BOCHKOVSKIY, A.; LIAO, H.-Y. M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. *In: IEEE/CVF CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION*, 2023, Vancouver. **Proceedings [...]** Vancouver: IEEE, 2023. p. 7464–7475.

- 70 TERVEN, J.; CORDOVA-ESPARZA, D. **A comprehensive review of YOLO: from YOLOv1 to YOLOv8 and beyond.** Disponível em: <https://arxiv.org/pdf/2304.00501.pdf>. Acesso em 12 out. 2023.
- 71 DIWAN, T.; ANIRUDH, G.; TEMBHURNE, J. V. Object detection using YOLO: Challenges, architectural successors, datasets and applications. **Multimedia Tools and Applications**, v. 82, n. 6, p. 9243–9275, 2023.
- 72 GARG, D. *et al.* A deep learning approach for face detection using YOLO. *In: 2018 IEEE PUNECON, 2018, Pune, India. Proceedings [...]* Pune, India: IEEE, 2018. p. 1–4.
- 73 CHEN, W. *et al.* YOLO-face: a real-time face detector. **Visual Computer**, v. 37, p. 805–813, 2021. DOI: 10.1007/s00371–020–01831–7.
- 74 PANIGRAHI, S.; RAJU, U. Inceptiondepth-wiseYOLOv2: improved implementation of YOLO framework for pedestrian detection. **International Journal of Multimedia Information Retrieval**, v. 11, n. 3, p. 409–430, 2022.
- 75 FARID, A. *et al.* A fast and accurate real-time vehicle detection method using deep learning for unconstrained environments. **Applied Sciences**, v. 13, n. 5, p. 3059, 2023.
- 76 AL-SMADI, Y. *et al.* Early wildfire smoke detection using different yolo models. **Machines**, v. 11, n. 2, p. 246, 2023.
- 77 CHEN, C. *et al.* YOLO-based UAV technology: a review of the research and its applications. **Drones**, v. 7, n. 3, p. 190, 2023.
- 78 HU, D. *et al.* Rice weed detection method on yolov4 convolutional neural network. *In: IEEE INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE, BIG DATA AND ALGORITHMS (CAIBDA), 2021, Xi'an, China. Proceedings [...]* Xi'an, China: IEEE, 2021. p. 41–45.
- 79 HONRADO, J. *et al.* UAV imaging with low-cost multispectral imaging system for precision agriculture applications. *In: IEEE GLOBAL HUMANITARIAN TECHNOLOGY CONFERENCE (GHTC), 2017, San Jose. Proceedings [...]* San Jose: IEEE, 2017. p. 1–7.
- 80 ENGESAT. **NDVI: criando índice de vegetação no global mapper.** 2016. Disponível em: <http://www.engesat.com.br/software/globa-mapper/calculo-do-ndice-de-vegetacao-ndvi-no-global-mapper/>. Acesso em: 23 jun. 2023.
- 81 SA, I. *et al.* Weednet: dense semantic weed classification using multispectral images and MAV for smart farming. **IEEE Robotics and Automation Letters**, v. 3, n. 1, p. 588–595, 2017.
- 82 FAWAKHERJI, M. *et al.* Multi-spectral image synthesis for crop/weed segmentation in precision farming. **Robotics and Autonomous Systems**, v. 146, p. 103861, 2021. DOI: 10.1016/j.robot.2021.103861.
- 83 LOTTES, P. *et al.* Joint stem detection and crop-weed classification for plant-specific treatment in precision farming. *In: IEEE/RSJ INTERNATIONAL CONFERENCE ON INTELLIGENTE ROBOTS AND SYSTEMS (IROS), 2018, Madrid. Proceedings [...]* Madrid: IEEE, 2018. p. 8233–8238.

- 84 OLSEN, A. *et al.* Deepweeds: a multiclass weed species image dataset for deep learning. **Scientific Reports**, v. 9, n. 1, p. 1–12, 2019.
- 85 PARTEL, V.; KAKARLA, S. C.; AMPATZIDIS, Y. Development and evaluation of a low-cost and smart technology for precision weed management utilizing artificial intelligence. **Computers and Electronics in Agriculture**, v. 157, p. 339–350, 2019. DOI: 10.1016/j.compag.2018.12.048.
- 86 BRIGHENTI, A. M.; OLIVEIRA, M. de. Biologia de plantas daninhas. *In*: OLIVEIRA JÚNIOR, R. S.; CONSTANTIN, J.; INOUE, M. H. (ed.). **Biologia e manejo de plantas daninhas**. Curitiba: Omnipax, 2011.
- 87 SILVA, A. F. A. *et al.* Interferência de plantas daninhas sobre plantas cultivadas. **Agropecuária Científica no Semiárido**, v. 8, n. 1, p. 01–06, 2012.
- 88 NEPOMUCENO, M. *et al.* Períodos de interferência das plantas daninhas na cultura da soja nos sistemas de semeadura direta e convencional. **Planta Daninha**, v. 25, p. 43–50, 2007.
- 89 SPADOTTO, C. A. *et al.* Determinação do período crítico para prevenção da interferência de plantas daninhas na cultura de soja: uso do modelo "broken-stick". **Planta Daninha**, v. 12, p. 59–62, 1994.
- 90 PITELLI, R. A. Competição e controle das plantas daninhas em áreas agrícolas. **Série técnica IPEF**, v. 4, n. 12, p. 1–24, 1987.
- 91 EMBRAPA. **Folhas estreitas**. 2023. Disponível em: <http://panorama.cnpms.embrapa.br/plantas-daninhas/plantas-daninhas/identificacao/folhas-estreitas>. Acesso em: 23 jun. 2023.
- 92 EMBRAPA. **Folhas largas**. 2023. Disponível em: <http://panorama.cnpms.embrapa.br/plantas-daninhas/plantas-daninhas/identificacao/folhas-largas>. Acesso em: 23 jun. 2023.
- 93 AEGRO. **Plantas daninhas da soja**. 2023. Disponível em: <https://blog.aegro.com.br/plantas-daninhas-da-soja/>. Acesso em: 26 jun. 2023.
- 94 OLIVEIRA JUNIOR, R.; CONSTANTIN, J.; INOUE, M. **Biologia e manejo de plantas daninhas**. Curitiba: Omnipax, 2011.
- 95 AMARANTE JUNIOR, O. P. *et al.* Glifosato: propriedades, toxicidade, usos e legislação. **Química Nova**, v. 25, p. 589–593, 2002.
- 96 SANTOS, J. *et al.* Avaliação de formulações de glyphosate sobre soja roundup ready. **Planta Daninha**, v. 25, p. 165–171, 2007.
- 97 GOMES JUNIOR, F.; CHRISTOFFOLETI, P. J. Biologia e manejo de plantas daninhas em áreas de plantio direto. **Planta Daninha**, v. 26, p. 789–798, 2008.
- 98 ROMAN, E. *et al.* Resistência de azevém (*lolium multiflorum*) ao herbicida glyphosate. **Planta Daninha**, v. 22, p. 301–306, 2004.
- 99 VARGAS, L. *et al.* Alteração das características biológicas dos biótipos de azevém (*lolium multiflorum*) ocasionada pela resistência ao herbicida glyphosate. **Planta Daninha**, v. 23, p. 153–160, 2005.

100 MONQUERO, P.; CHRISTOFFOLETI, P. J. Dinâmica do banco de sementes em áreas com aplicação freqüente do herbicida glyphosate. **Planta Daninha**, v. 21, p. 63–69, 2003.

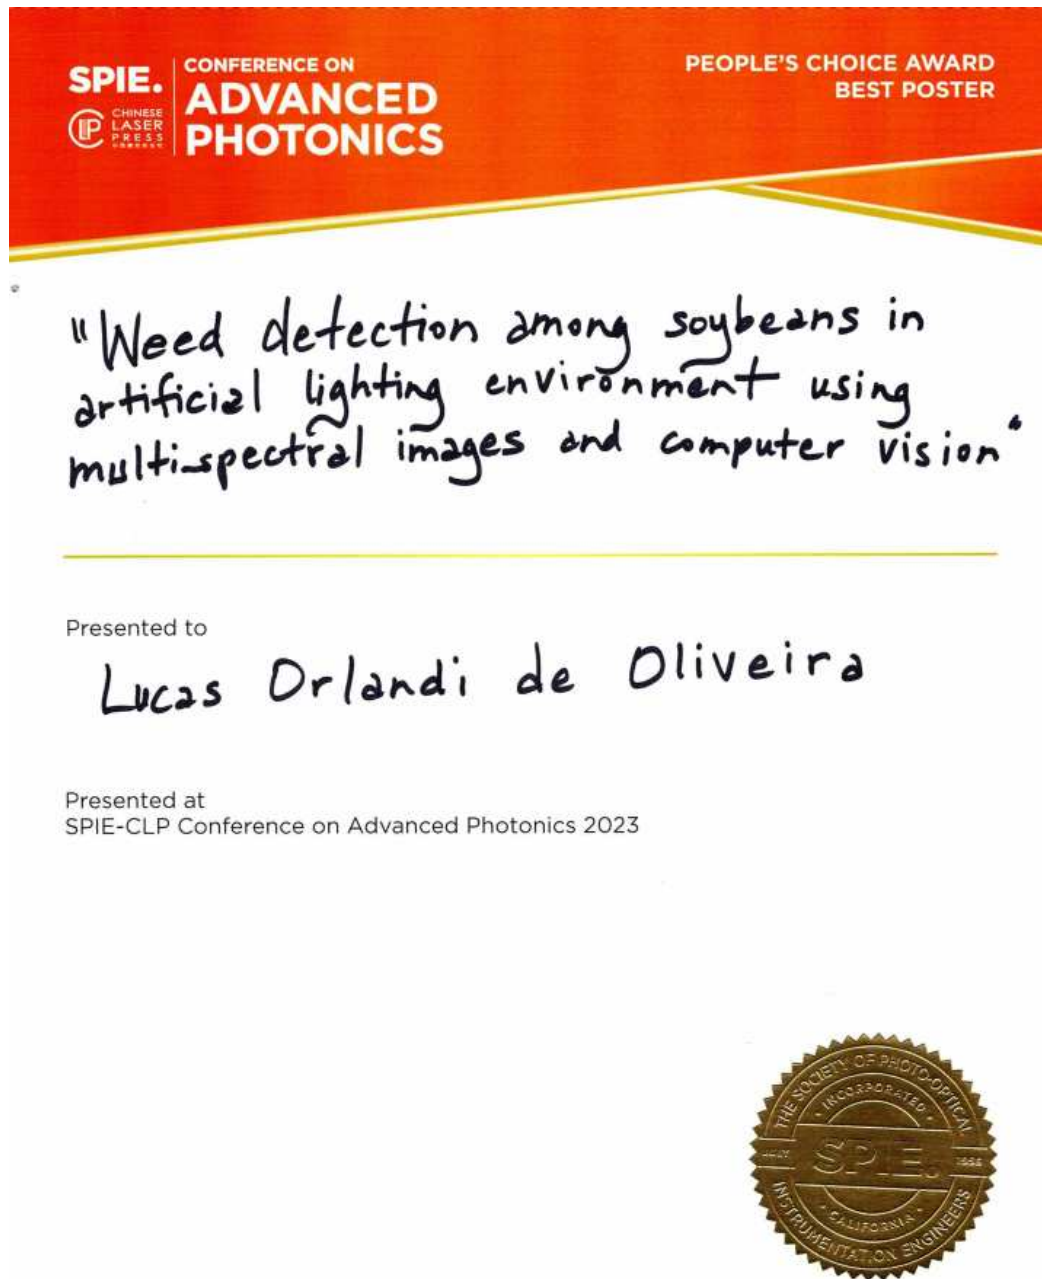
101 IBAMA. **Boletins anuais de produção, importação, exportação e vendas de agrotóxicos no Brasil**. 2022. Disponível em: <https://www.gov.br/ibama/pt-br/assuntos/quimicos-e-biologicos/agrotoxicos/relatorios-de-comercializacao-de-agrotoxicos#boletinsanuais>. Acesso em: 23 jun. 2023.

102 BLUERIVER TECHNOLOGY. **Blueriver technology**: optimize every plant. 2015. Disponível em: <http://www.bluerivertechnology.com/>. Acesso em: 23 jun. 2023.

103 LORENZI, H. *et al.* **Manual de identificação e controle de plantas daninhas: plantio direto e convencional**. Nova Odessa: Instituto Plantarum de Estudos da Flora, 2014.

ANEXOS

(Continuação)



(b)

Figura 60 – Trabalhos recorrentes. a) Pôster do trabalho desenvolvido durante este projeto apresentado pelo Me. Lucas Orlandi de Oliveira no congresso SPIE Conference on Advanced Photonics. b) Prêmio de melhor pôster apresentado no congresso conquistado na categoria "People's Choice Award Best Poster".

Fonte: Elaborada pelo autor.