

Detecção da Praga *Spodoptera frugiperda* no Cultivo de Milho usando Armadilhas Inteligentes e Visão Computacional

Wendell dos S. Silva¹, Bianca Soares¹, Valentine de L. Almeida², Leonardo Viana¹, Patrik L. Pastori³, Deborah M. V. Magalhães⁴, Atslands R. da Rocha¹

¹Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará

²Laboratório de Entomologia Aplicada, Universidade Federal do Ceará, Brasil

³Programa de Pós-Graduação em Agronomia/Fitotecnia, Universidade Federal da Grande Dourados, MS – Brasil

⁴Universidade da Integração Internacional da Lusofonia Afro-Brasileira (Unilab – CE)

{wendellsantos, biancasoares, valentine.lalmeida, leomaximo}@alu.ufc.br, patrikpastori@ufgd.edu.br, deborah.vm@unilab.edu.br, atslands@ufc.br

Abstract. *Crop health is a crucial concern in agriculture, which has led to the development of various technological approaches to ensure crop vitality. One of the challenges facing farmers is the need to combat pests, such as *Spodoptera frugiperda*, which significantly affects several types of crops, such as corn and cotton, on a global scale. Accurate monitoring of insect population density per unit area is essential for Integrated Pest Management (MIP) to provide farmers with essential information about the occurrence of pest species in their crops. However, this monitoring process is predominantly manual and requires producers. This article aims to present the development of a trap and a machine learning model for automatically detecting this pest in the field, thereby supporting decision-making for implementing MIP programs.*

Resumo. *A preocupação com a sanidade das plantações tem sido uma prioridade constante na agricultura, impulsionando o desenvolvimento de diversas abordagens tecnológicas para garantir a vitalidade das culturas. Um dos desafios que os agricultores enfrentam é a necessidade de combater pragas, como a *Spodoptera frugiperda*, que afeta significativamente diversos tipos de plantações, como milho e algodão, em escala global. O monitoramento preciso da densidade populacional de insetos por área é crucial para o Manejo Integrado de Pragas (MIP) e fornece aos agricultores informações essenciais sobre a saúde de suas culturas. No entanto, esse processo de monitoramento é predominantemente manual envolvendo os produtores. Neste artigo é apresentado o desenvolvimento de uma armadilha e de um modelo de aprendizado de máquina para detecção automática desta praga no campo, visando o suporte à tomada de decisão para implementação de programas MIP.*

1. Introdução

Conhecida como lagarta-do-cartucho, a *Spodoptera frugiperda* (J. E. Smith) (Lepidoptera: Noctuidae) é nativa da América do Sul [Sparks 1979] e ao longo dos anos vem se

expandindo para outras regiões do mundo como África, Ásia, e, recentemente na Austrália [Maino et al. 2021]. Por ser uma praga polífaga, que acaba atacando diversas culturas, principalmente da família Poaceae, como milho e sorgo, assim como culturas pertencentes a outras famílias botânicas distintas, como o algodão [Montezano et al. 2018] [Maino et al. 2021], a *S. frugiperda* desponta como uma das principais pragas da agricultura mundial. Tal espécie apresenta grande risco aos produtores rurais, pois se alimentam dos órgãos vegetativos e reprodutivos das plantas e possuem alta taxa de reprodução.

Para o controle de pragas na agricultura, preconiza-se o manejo integrado de pragas (MIP), que consiste na utilização de técnicas em conjunto, com o intuito de reduzir a infestação da população de insetos-praga a um número inferior ao do nível de controle [Gallo et al. 2002]. Diante disso, torna-se necessário o uso de métodos de controle em conjunto que não comprometam a eficácia um do outro [Torres and Bueno 2018]. Para determinar o momento correto de aplicar uma ou mais técnicas de controle, as armadilhas para o monitoramento das espécies-praga são fundamentais pois indicam a densidade populacional, o que aumenta as chances de sucesso do processo de decisão.

O monitoramento de pragas é usualmente realizado por meio de armadilhas iscasadas com feromônios sexuais específicos para cada espécie, sendo as armadilhas projetadas para atrair os indivíduos e capturá-los. Geralmente capturam-se os machos da espécie de interesse e esses podem ser identificados visualmente por meio dos padrões de coloração e desenhos de suas asas, que exibem manchas triangulares brancas nas pontas e na parte medial [Kenis et al. 2022] (Figura 1). No entanto, o processo de monitoramento ainda é predominantemente realizado com armadilhas que requerem inspeção visual, exigindo que uma pessoa se desloque até as armadilhas para realizar a contagem dos indivíduos capturados que atrasa ou retarda a tomada de decisão.



Figura 1. Indivíduos machos de *Spodoptera frugiperda*.

Neste trabalho é apresentado o desenvolvimento de um protótipo de armadilha inteligente que visa aprimorar o monitoramento de *S. frugiperda*. O protótipo é equipado com uma câmera e as imagens capturadas são transmitidos por Wi-Fi para um servidor, no qual são analisadas por meio de visão computacional para realizar a identificação de indivíduos adultos desta praga. Esta abordagem tem como objetivo oferecer uma solução confiável para o monitoramento dessa relevante praga agrícola.

A validação deste projeto foi conduzida por meio de testes em campo, em uma

plantação de milho afetada pela *S. frugiperda*. Foram realizadas diversas capturas de imagens, resultando em uma base de dados composta por mais de 5000 fotos. A classificação das imagens foi realizada utilizando métodos de aprendizado de máquina, incluindo *Random Forest* (RF) e *Support Vector Machine* (SVM). Os resultados indicam que o protótipo é capaz de identificar a presença de *S. frugiperda* nas armadilhas com excelente precisão.

2. Trabalhos Relacionados

O risco de ocorrência de *S. frugiperda* e sua rápida reprodução nos cultivos são investigados em [Bakry and Abdel-Baky 2024]. Para reduzir os danos causados pela *S. frugiperda* nas plantações, tem sido desenvolvidas diversas abordagens de monitoramento baseadas em armadilhas. Em [Chen et al. 2023] é descrito um dispositivo de monitoramento de pragas de baixo consumo de energia, que utiliza feromônios e visão computacional. No entanto, o método de segmentação de imagem baseado em MATLAB mencionado dificulta a distinção entre machos e fêmeas e devido à inconsistência na iluminação, pode resultar em confusão entre a coloração do inseto e do solo.

Em [López et al. 2023] é apresentada uma plataforma para contagem de insetos em cultivos de milho. O sistema é monitorado e visualizado em uma estação base, além de dispositivos como Raspberry Pi com acesso à internet, um módulo de câmera Raspberry Pi V2 (RPI-CAM-V2), uma placa solar e uma bateria de 12V. No entanto, esse projeto é sensível à qualidade da iluminação para a identificação dos insetos-praga, ao contrário deste trabalho, que utiliza uma câmera noturna mais acessível, uma vez que *Spodoptera frugiperda* tem hábito noturno, eliminando então essa desvantagem.

Em [Zhang et al. 2022], foram utilizadas redes neurais convolucionais (CNNs) para classificação do inseto na fase adulta com o intuito de disponibilizar uma aplicação Web que identifica o inseto através de uma foto enviada pelo usuário. Esse tipo de ferramenta possibilita ao produtor rural controlar com maior rapidez surtos populacionais dessa praga em suas lavouras, podendo diminuir danos em suas plantações.

Em [Alves et al. 2020] foi proposto um sistema de classificação para as principais pragas encontradas em cultivos de algodão. O sistema utilizou a ResNet34 pré-treinada com ImageNet e empregou aprendizado por transferência. O modelo foi treinado com imagens coletadas no campo, abrangendo quinze espécies incluindo a *S. frugiperda*. As amostras incluíram tanto imagens originais quanto imagens geradas através de técnicas de *augmentation*. No entanto, essa técnica pode acarretar desvantagens, como perda de qualidade, artefatos e ruídos, além de aumentar o tempo de processamento. Portanto, este trabalho propõe uma abordagem de aquisição de imagens que não depende dessa técnica.

Em [Souza et al. 2019] foi organizado um conjunto de imagens coletadas no campo que representam as seis principais pragas encontradas em plantações de milho, incluindo a *S. frugiperda*. Três modelos CNN pré-treinados com ImageNet foram avaliados por meio de transferência de aprendizado: AlexNet, Inception-V3 e Inception-V3* (versão modificada). O melhor resultado foi obtido com a arquitetura Inception-V3*. O presente trabalho refere-se apenas a *S. frugiperda* possibilitando mais precisão no algoritmo quanto a identificação do inseto. Além disso, neste trabalho é utilizada uma armadilha no campo para captura do inseto e auxílio do processo de identificação enquanto [Souza et al. 2019] apenas utiliza de imagens com alta qualidade dos insetos livres no campo. Quanto mais precisa é a informação coletada, mais confiável é a informação que

chega ao produtor, que pode utilizá-la para decidir o método de controle adequado.

Em [Du et al. 2022] é apresentado o modelo Pest R-CNN para a detecção da *S. frugiperda*, baseando-se nos vestígios de alimentação deixados nas folhas de milho. Este modelo foi desenvolvido com base na estrutura do Faster R-CNN. Foram usadas imagens capturadas por um veículo aéreo não tripulado para o treinamento e validação. Essas imagens foram recortadas em diversos tamanhos, dependendo da presença dos vestígios de alimentação, sem padronização no tamanho das imagens para o modelo. Contudo, este estudo se diferencia em termos de custo e facilidade de uso em comparação com o trabalho apresentado, visando uma abordagem mais acessível e prática para aplicação em diversos campos. Além disso, esse tipo de trabalho é importante pela agilidade da identificação, já que uma vez que a praga é identificada, o agricultor pode realizar o controle.

3. Metodologia

3.1. Sistema de Aquisição

Neste estudo é proposto um protótipo de armadilha inteligente que integra uma variedade de componentes para realizar diversas funções como a coleta de imagens, a transferência dos dados coletados para um servidor e a detecção de indivíduos adultos da espécie *S. frugiperda*. O esquema apresentado na Figura 2 ilustra o conceito do modelo físico.

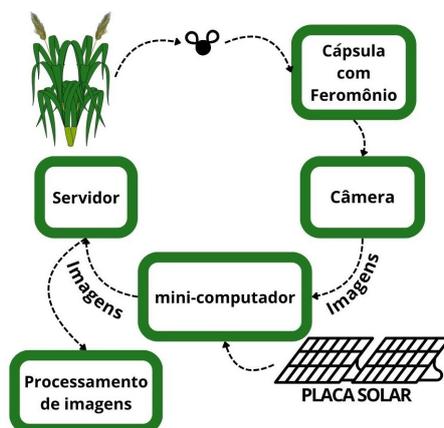


Figura 2. Esquemático do sistema de aquisição

Para atingir este objetivo, foi conduzido um estudo para identificar os componentes essenciais necessários para o desenvolvimento da armadilha inteligente. Como resultado, a configuração atual foi adaptada a partir de uma armadilha disponível comercialmente, incorporando um minicomputador Raspberry Pi, uma câmera, e uma placa solar. O Raspberry Pi foi selecionado devido à sua capacidade de processamento e facilidade de uso. Além do mais, essas placas são amplamente adotadas pela comunidade científica, o que facilita a disponibilidade de diversos módulos e bibliotecas que podem ser utilizados no desenvolvimento do protótipo. A demanda de CPU e memória no Raspberry Pi foi investigada usando a ferramenta RPi-Monitor e é relatada na Tabela 1.

A Figura 3 mostra a integração dos componentes mencionados. A câmera é embutida na armadilha (representada pela bola funil verde) e protegida por meio de uma estrutura de filamento de Polietileno Tereftalato Glicol (PETG), proporcionando resistência

Tabela 1. Amostragem do processamento e temperatura do processador e da memória do Raspberry Pi.

Categoria	Informação
Carga da CPU (1 min)	0,07
Carga da CPU (5 min)	0,16
Carga da CPU (15 min)	0,24
Frequência da CPU	600MHz
Voltagem	1,250V
Scalling governor	ondemand
Temperatura da CPU	45,62°C
Memória Usada	142,27MB (39,12%)
Memória Disponível	221,41MB
Memória Total	363,68MB

a impactos, a química, a umidade relativa e ao sol, tornando-se ideal para o projeto. O módulo controlador de carga solar e as baterias de íon-lítio de 2100Wh estão alojados em uma caixa protetora devido ao espaço considerável que ocupam e a placa solar. A Figura 4 apresenta um inseto fotografado durante a noite com o uso da câmera da armadilha.



Figura 3. Armadilha inteligente.

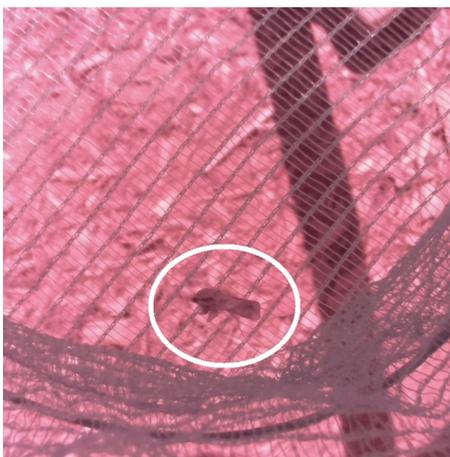


Figura 4. Imagem obtida pela armadilha.

3.2. Detecção de Pragas com Visão Computacional

A detecção de pragas por meio da Visão Computacional representa uma abordagem inovadora e eficaz para o monitoramento de pragas agrícolas [Karunathilake et al. 2023]. Nesse contexto, foi realizado um experimento de classificação das imagens adquiridas, que foi dividido em quatro etapas. A primeira etapa consistiu na seleção das imagens coletadas, que foram capturadas pela armadilha em diferentes momentos ao longo de um dia específico, para garantir uma representação abrangente e comportamental da praga. Em seguida, aplicou-se uma etapa de pré-processamento para aprimorar a qualidade e uniformizar as características das imagens, preparando-as para análises subsequentes. A terceira etapa envolveu a extração de características utilizando redes neurais convolucionais (CNN), uma técnica robusta para identificação de padrões complexos em imagens.

Por fim, para categorizar as imagens em duas classes (com inseto e sem inseto) com base nas características extraídas, foi realizada a classificação, empregando dois algoritmos clássicos da literatura: *Random Forest* e SVM. As etapas são detalhadas a seguir.

3.2.1. Seleção das Imagens

Para a condução deste experimento, as imagens adotadas foram capturadas no dia 29/11/2023. Os horários selecionados para coleta, foram distribuídos da seguinte maneira: 01:17:00 a 03:44:00, 05:44:01 e 22:17:16. Dessa forma, garante-se uma representação abrangente do período de atuação dos insetos. No processo de amostragem, um total de 2050 imagens foram selecionadas da base construída por terem melhor qualidade. Assim, cada classe foi composta por 1025 imagens, sendo uma referente à presença de insetos e a outra à ausência de insetos. A seleção foi realizada de maneira aleatória visando uma distribuição balanceada entre as classes identificadas e redução da repetição das imagens.

3.2.2. Pré-processamento

Na etapa de pré-processamento, inicialmente as imagens foram normalizadas no intervalo $[0, 1]$, com o objetivo de padronizar os pixels e otimizar a convergência durante o treinamento dos modelos. Essa normalização é fundamental para garantir que as variações nos valores dos pixels não impactem de forma negativa o desempenho do modelo, permitindo uma melhor aprendizagem e generalização para novas imagens [Bechar et al. 2019]. Após a normalização, as imagens foram redimensionadas para o tamanho 224x224, uma dimensão amplamente utilizada em modelos CNN [Zhang et al. 2022].

3.2.3. Extração de características

As CNNs são redes de aprendizado profundo populares devido à sua capacidade em aprender padrões complexos em imagens. Assim, elas produzem descritores em tarefas de classificação de imagens [Rawat and Wang 2017]. A extração de características foi realizada utilizando a biblioteca Keras, uma interface de alto nível para redes neurais, que se beneficia do *backend* da ferramenta TensorFlow. Foram adotados dois modelos CNN pré-treinados com a base de dados ImageNet [Russakovsky et al. 2015]: ResNet50 [He et al. 2016] e MobileNet [Howard et al. 2017]. Em todos os modelos, as características foram obtidas da última camada de *pooling*, enquanto as camadas totalmente conectadas foram desconsideradas. Posteriormente, aplicou-se o método de média global de *pooling* ao mapa de características resultante, reduzindo o descritor para a profundidade da última camada de *pooling*. A entrada foi padronizada para todas as arquiteturas, mantendo dimensões iguais de $224 \times 224 \times 3$. Contudo, os descritores resultantes possuem dimensões distintas, sendo 2048 para a ResNet50 e 1024 para a MobileNet.

3.2.4. Classificação

Para avaliar o desempenho dos descritores foram utilizados dois classificadores com características distintas: *Random Forest* e SVM. Foi realizada uma divisão treino e teste sem

interseção, sendo que 80% das imagens foram destinadas ao treinamento, e os outros 20% foram utilizados na avaliação dos modelos. A fim de encontrar os melhores parâmetros dos classificadores dentro de um espaço de busca, foi utilizado o algoritmo *Grid Search* [Bergstra and Bengio 2012]. A Tabela 2 apresenta os parâmetros selecionados pelo algoritmo dentro do seu respectivo espaço de busca para cada classificador.

Tabela 2. Configuração dos hiperparâmetros dos classificadores otimizada por meio do algoritmo Grid Search.

Classificadores	Intervalo dos Parâmetros	ResNet50	MobileNet
RF	estimators: [100, 200, 300, 400, 500, 700]	500	200
SVM	kernel: ['linear', 'rbf', 'poly', 'sigmoid'], C: [0.1, 0.5, 0.7, 1.0, 1.5]	linear 1,0	linear 0,1

Para a validação dos modelos de classificação foram usadas as métricas: acurácia, índice Kappa, *precision*, *recall* e F1-score. A acurácia fornece uma medida geral da precisão do modelo, sendo calculada como a proporção de previsões corretas em relação ao total de previsões. O índice Kappa avalia a concordância entre as previsões do modelo e as classes reais, ajustando para a concordância esperada ao acaso. A métrica *precision* indica a proporção de verdadeiros positivos em relação ao número total de positivos previstos pelo modelo, enquanto *recall* indica a proporção de verdadeiros positivos em relação ao número total de exemplos positivos reais. Já o F1-score é a média harmônica entre *precision* e *recall*, proporcionando uma medida balanceada entre essas métricas.

4. Experimentos e Resultados

4.1. Aquisição de Dados

Os experimentos foram realizados em condições controladas de temperatura e umidade (25 ± 3 °C, $70 \pm 10\%$ de UR e fotofase de 12 h) no Laboratório de Entomologia Aplicada (LEA) da Universidade Federal do Ceará (UFC), Fortaleza, Ceará, Brasil ($3^{\circ}44'34.17''S$; $38^{\circ}34'31.58''O$) no qual foi realizado uma simulação de campo colocando um grupo de *S. frugiperda* macho em uma gaiola entomológica, como demonstrado na Figura 5. A mesma estava equipada com um protótipo de armadilha para capturar as imagens e enviar para um servidor. Também obteve-se as imagens de mariposas mortas da espécie mencionada, com o intuito de aumentar a base de dados e testar diferentes posições dos insetos.

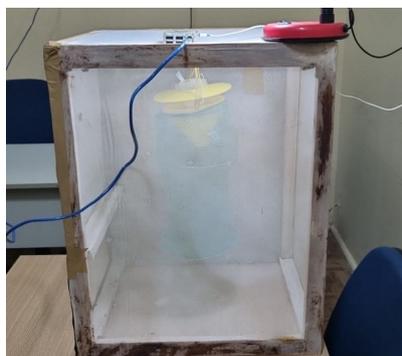


Figura 5. Armadilha em laboratório.



Figura 6. Armadilha em campo.

Após o experimento em laboratório, uma armadilha inteligente foi implantada em campo, como demonstrado na Figura 6. O experimento em campo foi realizado em uma área experimental localizada na Universidade Federal do Ceará (campus Fortaleza) no período de 28/11/2023 às 16h10min até o dia 30/11/2023 às 7h47min, (horário de Fortaleza) sob pressão atmosférica, temperatura e umidade informados na Tabela 3, fornecida pelo INMET. Em alguns momentos, a armadilha não capturou insetos, ou as imagens não correspondiam à espécie desejada ou foram afetadas por interferências ambientais, como vento e outras perturbações, que resultaram em imagens borradas. Consequentemente, houve a necessidade de selecionar cuidadosamente as imagens com e sem a mariposa. Ao todo, foram coletadas 5.413 fotografias de *S. frugiperda* e 4.351 fotografias sem ela.

Tabela 3. Dados meteorológicos do experimento fornecidos pelo INMET.

Data	Precipitação Total (mm)	Pressão Atmosférica Média (mB)	Temperatura Média (°C)	Umidade Relativa do Ar Média (%)
28/11/2023	39,6	1010,3375	26,779167	72
29/11/2023	0,2	1008,795833	27,7875	70,375
30/11/2023	0,2	1008,520833	28,229167	69,958333

4.2. Detecção de Pragas: Classificação

Os resultados da classificação utilizando ResNet50 e MobileNet como descritores, em conjunto com os classificadores *Random Forest* e SVM (apresentados na Tabela 4), demonstraram desempenhos relevantes, sendo a MobileNet destacada pelos melhores resultados. Ambas as redes neurais convolucionais foram capazes de extrair características relevantes das imagens, mas a MobileNet apresentou resultados superiores a 0,99 em todas as métricas. Esses resultados indicam a eficácia da MobileNet na representação eficiente de padrões complexos nas imagens, contribuindo para uma classificação precisa. Por outro lado, o pior desempenho foi observado ao utilizar o SVM em conjunto com a ResNet50 como descritor. Essa combinação pode indicar uma menor capacidade da ResNet50 em extrair características relevantes para o SVM, resultando em uma classificação menos eficaz, porém, os resultados ainda são considerados promissores, visto que, foram superiores a 0,92, o que evidencia o potencial de melhorias e otimizações, como a investigação de técnicas de pré-processamento e a utilização de algoritmos de seleção de características.

Em alguns testes foram obtidos valores máximos de recall (1,00), o que pode ser atribuído a uma classificação precisa de todas as instâncias positivas, indicando que o modelo conseguiu identificar corretamente todos os exemplos de *S. frugiperda* presentes nas imagens. Além disso, o *precision* também alcançou 1,00 quando a MobileNet foi combinada ao SVM, refletindo a capacidade do modelo em evitar falsos positivos, o que pode ser atribuído à capacidade da MobileNet de extrair características distintivas, juntamente com a eficácia do SVM em definir fronteiras de decisão precisa. Portanto, a utilização da MobileNet como descritor revelou-se uma solução promissora na tarefa de detecção de pragas, destacando-se especialmente quando combinada com o classificador *Random Forest*, que resultou em um recall de 1,00. Portanto, tal combinação permite identificar todas as instâncias positivas de maneira precisa. Além disso, a MobileNet é reconhecida por ser uma arquitetura CNN "leve", devido a quantidade de parâmetros (4.3M), o que a torna uma escolha eficiente em termos de recursos, sendo capaz de atender às demandas práticas de implementação com restrições computacionais como os ambientes IoT.

Tabela 4. Resultados de classificação das características extraídas pelos modelos CNN, os melhores resultados são destacados em negrito.

Descritor	Classificador	Acurácia	Kappa	Precision	Recall	F1-score
ResNet50	RF	0,9926	0,9853	0,9852	1,0000	0,9925
	SVM	0,9634	0,9269	0,9305	1,0000	0,9640
MobileNet	RF	0,9951	0,9902	0,9901	1,0000	0,9950
	SVM	0,9975	0,9951	1,0000	0,9950	0,9975

5. Considerações Finais

Insetos-praga são aqueles cuja existência se torna conflitante com os interesses humanos, pois acarretam problemas e trazem prejuízos para a produção de alimentos. Este trabalho apresenta uma proposta de sistema para detecção de adultos de *S. frugiperda* por meio de armadilhas inteligentes e visão computacional. A contribuição do trabalho inicia desde a aquisição de imagens até o resultado da classificação, relevante para o monitoramento e posterior controle dessa praga em campo. O experimento de detecção de adultos de *S. frugiperda* em imagens visa validar a base de dados criada e mostrar sua aplicabilidade. Os resultados indicam que técnicas clássicas de aprendizado de máquina associadas a CNNs são capazes de detectar a presença da *S. frugiperda* com elevada precisão. Como trabalho futuro será investigado o desempenho do modelo de classificação embarcado em uma placa de circuito impresso (PCB) na armadilha.

6. Agradecimentos

Este trabalho recebeu apoio da Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico (FUNCAP) através do projeto MLC-0191-00164.01.00/22.

Referências

- Alves, A. N., Souza, W. S., and Borges, D. L. (2020). Cotton pests classification in field-based images using deep residual networks. *Computers and Electronics in Agriculture*, 174:105488.
- Bakry, M. M. S. and Abdel-Baky, N. F. (2024). Impact of the fall armyworm, *spodoptera frugiperda* (lepidoptera: Noctuidae) infestation on maize growth characteristics and yield loss. *Brazilian Journal of Biology*, 84:e274602.
- Bechar, M. E. A., Settouti, N., Daho, M. E. H., Adel, M., and Chikh, M. A. (2019). Influence of normalization and color features on super-pixel classification: application to cytological image segmentation. *Australasian physical & engineering sciences in medicine*, 42:427–441.
- Bergstra, J. and Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of machine learning research*, 13(2).
- Chen, M., Chen, L., Yi, T., Zhang, R., Xia, L., Qu, C., Xu, G., Wang, W., Ding, C., Tang, Q., and Wu, M. (2023). Development of a Low-Power Automatic Monitoring System for *Spodoptera frugiperda* (J. E. Smith). *Agriculture*, 13(4).
- Du, L., Sun, Y., Chen, S., Feng, J., Zhao, Y., Yan, Z., Zhang, X., and Bian, Y. (2022). A novel object detection model based on faster r-cnn for *spodoptera frugiperda* according to feeding trace of corn leaves. *Agriculture*, 12(2):248.

- Gallo, D., Nakano, O., Silveira Neto, S. S., Carvalho, R. P. L., Batista, G. C., Filho, E. B., P., P. J. R., Zucchi, R. A., Alves, S. B., Vendramim, J. D., Marchini, L. C., Lopes, J. R. S., and Omoto, C. (2002). *Entomologia agrícola*. FEALQ, Piracicaba.
- He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 770–778.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., and Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- Karunathilake, E., Le, A. T., Heo, S., Chung, Y. S., and Mansoor, S. (2023). The path to smart farming: Innovations and opportunities in precision agriculture. *Agriculture*, 13(8):1593.
- Kenis, M., Benelli, G., Biondi, A., Calatayud, P.-A., Day, R., Desneux, N., Harrison, R. D., Kriticos, D., Rwomushana, I., van den Berg, J., et al. (2022). Invasiveness, biology, ecology, and management of the fall armyworm, *spodoptera frugiperda*. *Entomologia Generalis*.
- López, A.-F. J., Jiménez-López, F.-R., and Alvarez, C. S. L. (2023). Electronic trap for field detection of fall armyworm (*spodoptera frugiperda*) in corn. In *2023 IEEE 6th Colombian Conference on Automatic Control (CCAC)*, pages 1–5.
- Maino, J. L., Schouten, R., Overton, K., Day, R., Ekesi, S., Bett, B., Barton, M., Gregg, P. C., Umina, P. A., and Reynolds, O. L. (2021). Regional and seasonal activity predictions for fall armyworm in australia. *Current Research in Insect Science*, 1:100010.
- Montezano, D. G., Sosa-Gómez, D., Specht, A., Roque-Specht, V. F., Sousa-Silva, J. C., Paula-Moraes, S. d., Peterson, J. A., and Hunt, T. (2018). Host plants of *s. frugiperda* (lepidoptera: Noctuidae) in the americas. *African entomology*, 26(2):286–300.
- Rawat, W. and Wang, Z. (2017). Deep convolutional neural networks for image classification: A comprehensive review. *Neural computation*, 29(9):2352–2449.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., et al. (2015). Imagenet large scale visual recognition challenge. *International journal of computer vision*, 115:211–252.
- Souza, W. S., Alves, A. N., and Borges, D. L. (2019). A deep learning model for recognition of pest insects in maize plantations. In *2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)*, pages 2285–2290. IEEE.
- Sparks, A. N. (1979). A review of the biology of the fall armyworm. *Florida entomologist*, pages 82–87.
- Torres, J. B. and Bueno, A. d. F. (2018). Conservation biological control using selective insecticides—a valuable tool for ipm. *Biological Control*, 126:53–64.
- Zhang, H., Zhao, S., Song, Y., Ge, S., Liu, D., Yang, X., and Wu, K. (2022). A deep learning and grad-cam-based approach for accurate identification of the fall armyworm (*spodoptera frugiperda*) in maize fields. *Computers and Electronics in Agriculture*, 202:107440.