

MONITORAMENTO INTELIGENTE DE INSETOS: A CONVERGÊNCIA ENTRE ARMADILHAS FOTOGRÁFICAS E DEEP LEARNING NA AGRICULTURA MODERNA

Lucas de Souza Dias¹.

¹Universidade Federal da Grande Dourados (UFGD), Dourados, MS.

<http://lattes.cnpq.br/3843522753361026>

RESUMO: O monitoramento de insetos bioindicadores é crucial para a preservação ambiental e o manejo agrícola, porém métodos tradicionais enfrentam gargalos operacionais e dependem excessivamente da especialização taxonômica. Este artigo revisa a integração de armadilhas fotográficas automatizadas e algoritmos de inteligência artificial (IA), com foco em redes neurais convolucionais (CNN) e aprendizado profundo. A literatura recente (2020–2026) indica que sistemas baseados em Visão Computacional, como o Automated Moth Trap (AMT) e o uso de Aprendizado por Transferência, permitem a identificação de espécies com precisão frequentemente superior a 90%. Discutem-se avanços em processamento de borda, aprendizado federado e gêmeos digitais, os quais buscam mitigar limitações de conectividade e escassez de dados rotulados. Conclui-se que a automação não apenas otimiza a coleta de dados em larga escala, mas estabelece um novo paradigma na entomologia aplicada, ao permitir respostas rápidas e sustentáveis frente a mudanças ecológicas e surtos de pragas. Apesar dos persistentes desafios em padronização e variabilidade ambiental, a convergência tecnológica em curso é o caminho mais promissor para a democratização do monitoramento da biodiversidade global.

PALAVRAS-CHAVE: Monitoramento automatizado. Deep learning. Entomologia.

SMART INSECT MONITORING: THE CONVERGENCE OF PHOTOGRAPHIC TRAPS AND DEEP LEARNING IN MODERN AGRICULTURE

ABSTRACT: Monitoring bioindicator insects is crucial for environmental preservation and agricultural management, but traditional methods face operational bottlenecks and rely excessively on taxonomic expertise. This paper reviews the integration of automated photographic traps and artificial intelligence (AI) algorithms, focusing on convolutional neural networks (CNNs) and deep learning. Recent literature (2020–2026) indicates that computer visionbased systems, such as the Automated Moth Trap (AMT) and transfer learning, enable species identification with accuracy often exceeding 90%. Advances in edge processing, federated learning, and digital twins are discussed, as they seek to

mitigate connectivity limitations and scarcity of labeled data. It is concluded that automation not only optimizes largescale data collection but establishes a new paradigm in applied entomology, enabling rapid and sustainable responses to ecological changes and pest outbreaks. Despite persistent challenges in standardization and environmental variability, the ongoing technological convergence is the most promising path toward democratizing global biodiversity monitoring.

KEY-WORDS: Automated monitoring. Deep learning. Entomology.

INTRODUÇÃO

O monitoramento de insetos é uma ferramenta essencial para a avaliação da qualidade ambiental, a detecção precoce de mudanças ecológicas e o manejo integrado de pragas em agroecossistemas (HØYE et al., 2021). Tradicionalmente, a identificação e contagem desses organismos são realizadas por meio de coleta manual, armadilhas de interceptação e análise visual *post hoc* por especialistas. Esses procedimentos, embora confiáveis, são lentos, demandam profundo conhecimento taxonômico e frequentemente apresentam viés amostral, o que limita a escala e a resolução temporal dos dados (SILVA et al., 2025).

Com o avanço das tecnologias digitais, as armadilhas fotográficas – inicialmente consagradas em estudos com vertebrados – foram adaptadas para a captura automatizada de imagens de insetos em campo. Paralelamente, algoritmos de inteligência artificial (IA), especialmente redes neurais convolucionais (CNNs) e técnicas de aprendizado profundo, têm demonstrado capacidade notável para classificar imagens de insetos com precisão comparável, e por vezes até superior a de taxonomistas experientes (HØYE et al., 2021). A convergência entre hardware de captura e *software* de classificação inaugura uma nova era para o monitoramento entomológico, com potencial para reduzir custos, aumentar a frequência de amostragem e gerar dados massivos e padronizados.

Esta revisão tem como objetivo sintetizar o conhecimento atual sobre o uso integrado de armadilhas fotográficas e inteligência artificial para a identificação automatizada de insetos, destacando as principais aplicações em bioindicação e agricultura, os avanços metodológicos recentes, os desafios técnicos ainda não superados e as perspectivas futuras promissoras.

METODOLOGIA

A presente revisão bibliográfica adotou uma abordagem exploratória e qualitativa, com levantamento de artigos originais, revisões sistemáticas e anais de conferências publicados entre 2015 e 2026. A busca foi realizada nas bases Scopus, Web of Science e IEEE Xplore, utilizando descritores como “*automated insect monitoring*”, “*deep learning*”, “*computer vision entomology*”, “*smart traps*”, “*edge computing pest detection*”, “*federated learning*”.

agriculture” e “*digital twin pest*”. Foram priorizados estudos que integram componentes de hardware (armadilhas) e *software* (modelos de IA), com atenção especial a publicações dos últimos três anos que apresentam conceitos como processamento de borda, aprendizado federado e gêmeos digitais. Essa abordagem metodológica permitiu caracterizar o estado da arte, as capacidades atuais e os principais fatores que limitam a disseminação dessas tecnologias em larga escala.

Sistemas de armadilhas fotográficas para monitoramento de insetos

Os sistemas de captura de imagem para insetos evoluíram de adaptações caseiras para plataformas robustas e cada vez mais integradas. As soluções atuais variam desde armadilhas comerciais adaptadas com câmeras de alta resolução até dispositivos de baixo custo baseados em sensores de movimento e microcontroladores como Arduino e Raspberry Pi (BJERGE et al., 2021; KASINATHAN et al., 2021).

Um marco nesse campo é o sistema “Automated Moth Trap” (AMT), desenvolvido por Bjerger et al. (2021), que combina uma armadilha luminosa LED com uma câmera de alta resolução e processamento embarcado. Em testes de campo realizados durante 48 noites consecutivas, o sistema capturou mais de 250.000 imagens, com uma média de 5.675 registros por noite. A rede neural treinada com 2.000 imagens de mariposas distribuídas em oito classes atingiu um F1-score de validação de 0,93, comprovando a viabilidade de um monitoramento não destrutivo e de alta resolução temporal (BJERGE et al., 2021). A popularidade do projeto fomentou adaptações globais, como a versão implementada por naturalistas amadores na Austrália para o estudo de mariposas locais (RASPBERRY PI, 2023). Este é um exemplo claro de como o hardware de código aberto está democratizando o acesso a ferramentas de ponta em ecologia.

Na área de monitoramento de pragas agrícolas, sistemas de armadilhas adesivas equipadas com câmeras macro e iluminação controlada têm sido desenvolvidos para fotografar insetos capturados em intervalos programados. As imagens são então enviadas via rede celular para servidores em nuvem, onde modelos de *deep learning* as processam, permitindo um monitoramento remoto em tempo real. Estudos recentes mostram que sistemas baseados em sensores de imagem e algoritmos de *machine learning* permitem observações contínuas e remotas, melhorando drasticamente a resolução espacial e temporal dos dados e alinhando-se perfeitamente aos princípios do Manejo Integrado de Pragas (MIP) (VALENT, 2024; LI et al., 2025).

Soluções de baixo custo com alto desempenho também vêm ganhando destaque. Um exemplo é o sistema que integra a tecnologia IoT com o modelo YOLO-Evo (uma variante aprimorada do YOLOv10) em uma armadilha movida a energia solar e equipada com um Raspberry Pi 4B. Este dispositivo realiza a detecção de insetos diretamente no dispositivo, transmitindo alertas em tempo real via celular. Seu custo é inferior a 300 dólares, valor significativamente mais acessível que armadilhas eletrônicas comerciais (que chegam

a custar entre 850 e 1000 dólares), demonstrando a viabilidade econômica da tecnologia (KUMAR et al., 2025). Paralelamente, sistemas inovadores baseados em armadilhas de solo (“pitfall traps”) com câmeras de lapso de tempo e modelos YOLOv8 vêm permitindo análises em escala fina sobre o movimento de insetos, revelando, por exemplo, o aumento da atividade de ninfas de percevejos em condições quentes e secas com detalhes nunca antes capturados por métodos manuais (JONES et al., 2025).

Algoritmos de inteligência artificial na classificação entomológica

A maioria dos estudos revisados utiliza redes neurais convolucionais (CNNs) profundas pré-treinadas (como ResNet, Inception e EfficientNet) e as ajusta com conjuntos de imagens de insetos (THENMOZHI; SRINIVASULU REDDY, 2019). Essa técnica, conhecida como aprendizado por transferência, é um dos pilares do sucesso da área, pois reduz drasticamente a necessidade de milhões de imagens rotuladas, um dos maiores gargalos para a implementação de soluções de IA em larga escala.

Høye et al. (2021) identificaram quatro áreas focais para consolidar essa transformação tecnológica na entomologia: (1) validação sistemática da identificação taxonômica baseada em imagens; (2) geração de dados de treinamento robustos e representativos; (3) desenvolvimento de bases de dados de referência públicas e curadas; e (4) integração de ferramentas de *deep learning* com métodos moleculares tradicionais.

Esforços recentes na direção dos grandes bancos de dados incluem o “BugNet”, um *pipeline* automatizado que agrega dados de imagens de insetos de bancos online, como o GBIF, para treinar modelos de classificação hierárquicos. O BugNet demonstrou alta precisão em imagens de campo e uma capacidade aprimorada de lidar com táxons desconhecidos, um passo crucial para a criação de uma plataforma de monitoramento de insetos verdadeiramente escalável e generalizável (JIANG et al., 2026). Revisões recentes indicam que, embora as CNNs tenham dominado o campo nos últimos anos, há uma clara tendência de migração para modelos híbridos e baseados em transformadores (“vision transformers” - ViTs), que oferecem maior precisão e melhor compreensão contextual da cena, embora desafios como desbalanceamento de dados, detecção de insetos muito pequenos e capacidade de generalização ainda persistam (HUSSAIN et al., 2025).

Aplicações em bioindicação e monitoramento ambiental

A integração de armadilhas fotográficas com IA já foi aplicada com sucesso em diversos contextos de bioindicação. Estudos mostram que esses sistemas automatizados oferecem vantagens significativas para o monitoramento de insetos, alinhando-se aos princípios do Manejo Integrado de Pragas (MIP) e promovendo estratégias de controle mais eficientes e sustentáveis (VALENT, 2024; LI et al., 2025).

No monitoramento de insetos vetores de doenças, os avanços são particularmente relevantes. Uma revisão sistemática avaliou métodos baseados em *machine learning* para identificação de mosquitos a partir de imagens, destacando que modelos pré-treinados apresentam maior acurácia em comparação com modelos treinados do zero. Contudo, desafios como a diversidade limitada dos *datasets* e a similaridade morfológica entre espécies crípticas ainda dificultam a generalização dos modelos (SILVA et al., 2025). No Brasil, iniciativas concretas ilustram o potencial da tecnologia. Um exemplo é a armadilha digital desenvolvida para monitorar a broca-da-cana (*Diatraea saccharalis*) em São Paulo, que registra automaticamente a praga diariamente, ao contrário dos métodos manuais que dependem de vistorias semanais, permitindo uma resposta muito mais ágil e precisa (EMBRAPA, 2025). Outro caso é o desenvolvimento de um sistema de visão computacional na Universidade de São Paulo (USP) para identificar espécies de vespas que podem substituir inseticidas no controle biológico de pragas (JORNAL DA USP, 2025).

Desafios e limitações

Apesar dos avanços impressionantes, a consolidação da tecnologia em larga escala exige a superação de desafios técnicos e operacionais. A qualidade das imagens é frequentemente comprometida por condições adversas de luz, movimento rápido do inseto, sobreposição de múltiplos indivíduos e obstrução por detritos, o que pode reduzir significativamente a acurácia dos modelos. A variação intraespecífica de coloração e morfologia, comum em muitos grupos, exige conjuntos de treinamento extremamente robustos e a atualização periódica dos modelos. A padronização de protocolos de captura, armazenamento e metadados continua sendo um ponto crítico. Høye et al. (2021) já enfatizavam a necessidade de bases de dados de referência públicas e curadas para viabilizar a implementação em larga escala destas soluções e criar bases de dados integradas, permitindo a comparação de resultados entre diferentes estudos.

Questões relacionadas à capacidade computacional em dispositivos de borda, que possuem limitações severas de processamento e bateria, e os altos custos de anotação de dados (rotulagem manual por especialistas) ainda são barreiras significativas. Pesquisas futuras estão explorando abordagens alternativas promissoras para superar tais obstáculos. O **aprendizado autossupervisionado** reduz a necessidade de dados rotulados ao fazer o modelo aprender padrões diretamente de grandes volumes de imagens não anotadas. O **aprendizado federado** permite treinar modelos de forma descentralizada, processando os dados diretamente nos dispositivos de borda e compartilhando apenas os parâmetros atualizados, o que economiza largura de banda, preserva a privacidade dos dados da propriedade e acelera o aprendizado (LI et al., 2025).

Um exemplo recente dessa abordagem é o modelo federado LeViT-ResUNet, que integra dados de drones e sensores IoT para identificar “hotspots” de insetos em tempo real com precisão superior a 98% (AL-GARDI et al., 2025). Os **gêmeos digitais** (*digital*

twins) são réplicas virtuais de ecossistemas reais que podem simular o comportamento de pragas em tempo real, permitindo intervenções preditivas e mais precisas. Um marco nesta área é o framework “PesTwin”, que modela agentes biológicos (pragas) em interação com o ambiente para simular infestações em cenários realísticos, considerando variáveis climáticas e do solo (DE ANTONI et al., 2026). Estas tecnologias, combinadas, podem viabilizar sistemas de monitoramento inteligente mais eficientes, confiáveis e sustentáveis, superando as atuais limitações e facilitando a tomada de decisão em campo.

Figura 1. Armadilha eletrônica inteligente equipada com piso adesivo com feromônios, câmeras fotográficas, painel solar e conexão 4G. A tecnologia possibilita tirar fotos programadas do piso adesivo, identificar o tipo de praga e fazer a contagem dos insetos capturados por meio de inteligência artificial.



Fonte: Ricardo Jayme

CONSIDERAÇÕES FINAIS

A integração entre armadilhas fotográficas e inteligência artificial consolida-se como uma das abordagens mais promissoras para a modernização do monitoramento de insetos. Ao longo desta revisão, evidenciou-se que tais sistemas já atingem níveis de acurácia comparáveis aos métodos tradicionais de identificação, ao mesmo tempo em que proporcionam ganhos expressivos em escala amostral, resolução temporal, redução de custos operacionais de longo prazo e padronização dos dados gerados. Esses avanços representam um marco importante para a entomologia aplicada, especialmente em contextos que demandam respostas rápidas e monitoramento contínuo, como o manejo integrado de pragas e a avaliação da qualidade ambiental em áreas de conservação.

Entretanto, a consolidação dessa tecnologia em larga escala ainda depende da superação de desafios intrínsecos. A sensibilidade dos modelos às variações ambientais em condições reais de campo e a necessidade de conjuntos de dados robustos e representativos da biodiversidade local são problemas centrais. A ausência de padronização e interoperabilidade entre as dezenas de plataformas e sistemas de coleta existentes e a carência de profissionais com formação interdisciplinar (entomologia, ciência de dados e engenharia) são gargalos que exigem atenção coordenada entre universidades, indústria e poder público.

Do ponto de vista prospectivo, a convergência de abordagens emergentes, como modelos fundacionais de visão computacional, aprendizado multimodal, gêmeos digitais e técnicas de visão noturna computacional para pequenos insetos, promete ampliar exponencialmente a eficiência, autonomia e capacidade preditiva desses sistemas. Nesse cenário, o monitoramento automatizado deixa de ser uma ferramenta de registro para se tornar um componente estratégico na tomada de decisão em tempo real, transformando profundamente a forma como dados sobre insetos são coletados, analisados e aplicados. Seu avanço contínuo será determinante para fortalecer programas de bioindicação e manejo de pragas, contribuindo de maneira decisiva para a sustentabilidade dos ecossistemas naturais e agrícolas e para a segurança alimentar global.

REFERÊNCIAS

- ALGARDI, M.; ALMUTAIRI, J.; ALZAMIL, I.** Federated LeViTResUNet for scalable and privacy-preserving agricultural monitoring using drone and internet of things data. **Agronomy**, v. 15, n. 4, p. 928, 2025. Disponível em: <https://doi.org/10.3390/agronomy15040928>. Acesso em: 6 abr. 2026.
- BJERGE, K. et al.** An automated light trap to monitor moths (Lepidoptera) using computer vision-based tracking and deep learning. **Sensors**, v. 21, n. 2, p. 343, 2021. Disponível em: <https://doi.org/10.3390/s21020343>. Acesso em: 6 abr. 2026.
- DE ANTONI, A. et al.** PesTwin: a biology-informed digital twin for enabling precision farming. **arXiv**, 2026. Disponível em: <https://arxiv.org/abs/2603.12294>. Acesso em: 6 abr. 2026.
- EMBRAPA.** Armadilha digital com inteligência artificial monitora praga da cana-de-açúcar. **Semear Digital**, 2025. Disponível em: <https://www.semear.digital.cnptia.embrapa.br>. Acesso em: 6 abr. 2026.
- HØYE, T. T. et al.** Deep learning and computer vision will transform entomology. **Proceedings of the National Academy of Sciences**, v. 118, n. 2, e2002545117, 2021. Disponível em: <https://doi.org/10.1073/pnas.2002545117>. Acesso em: 6 abr. 2026.
- HUSSAIN, A. et al.** Crop pest classification using deep learning techniques: a review. **arXiv**, 2025. Disponível em: <https://arxiv.org/abs/2507.01494>. Acesso em: 6 abr. 2026.

JIANG, S. et al. BugNet: a rapid and scalable pipeline for automated insect monitoring using hierarchical data. **Frontiers in Ecology and Evolution**, v. 14, 2026. Disponível em: <https://doi.org/10.3389/fevo.2026.1750931>. Acesso em: 6 abr. 2026.

JONES, T. et al. Imagebased finescale analysis of insect movement patterns and environmental triggers using pitfall traps. **Smart Agricultural Technology**, v. 12, 100543, 2025. Disponível em: <https://doi.org/10.1016/j.atech.2025.100543>. Acesso em: 6 abr. 2026.

JORNAL DA USP. IA automatiza a identificação de vespas que podem substituir inseticidas na agricultura. **Jornal da USP**, 2025. Disponível em: <https://jornal.usp.br/ciencias/iaautomatizaaidentificacaodevespasquepodemsubstituirinseticidasnaagricultura/>. Acesso em: 6 abr. 2026.

KASINATHAN, T.; SINGARAJU, D.; UYYALA, S. R. Insect classification and detection in field crops using modern machine learning techniques. **Information Processing in Agriculture**, v. 8, n. 3, p. 446457, 2021. Disponível em: <https://doi.org/10.1016/j.inpa.2020.10.003>. Acesso em: 6 abr. 2026.

KUMAR, A. et al. Enhancing integrated pest management with IoT and YOLOEvo: a smart, lowcost monitoring system for sustainable apple farming. **Results in Engineering**, v. 26, 104567, 2025. Disponível em: <https://doi.org/10.1016/j.rineng.2025.104567>. Acesso em: 6 abr. 2026.

LI, W. et al. Research progress of deep learningbased artificial intelligence technology in pest and disease detection and control. **Agriculture**, v. 15, n. 19, p. 2077, 2025. Disponível em: <https://doi.org/10.3390/agriculture15192077>. Acesso em: 6 abr. 2026.

RASPBERRY PI. Capturing photos of moths in Australia. **Raspberry Pi News**, 2023. Disponível em: <https://www.raspberrypi.com/news/capturingphotosofmothsinaustralia/>. Acesso em: 6 abr. 2026.

SILVA, F. S. et al. Trends and advances in imagebased mosquito identification and classification using machine learning models: a systematic review. **Computers in Biology and Medicine**, v. 193, p. 110373, 2025. Disponível em: <https://doi.org/10.1016/j.compbiomed.2025.110373>. Acesso em: 6 abr. 2026.

THENMOZHI, K.; SRINIVASULU REDDY, U. Crop pest classification based on deep convolutional neural network and transfer learning. **Computers and Electronics in Agriculture**, v. 164, p. 104906, 2019. Disponível em: <https://doi.org/10.1016/j.compag.2019.104906>. Acesso em: 6 abr. 2026.

VALENT, R. Remote pest monitoring: state of the art and case study using iScout traps in Douro region, Portugal. 2024. Dissertação (Mestrado) – Universidade de Pádua, Itália, 2024. Disponível em: <https://thesis.unipd.it/handle/20.500.12608/82309>. Acesso em: 6 abr. 2026.