
Tenebrio AI Detection: Um modelo para identificação e classificação precisa de *Tenebrio molitor* por meio de visão computacional

Tenebrio AI Detection: A model for accurate identification and classification of *Tenebrio molitor* through computer vision

Tenebrio AI Detection: Un modelo para la identificación y clasificación precisa de *Tenebrio molitor* através de visión computacional

Paulo Sallarola Takao¹  
Julio Franz Moura¹  
Pâmela Souza Corrêa¹  
Rafaela de Campos Oliveira¹  
Renan Rodrigues Rocha¹  
Flávio Francisco da Silva¹  
Fabiano Bezerra Menegidio¹  

Tipo de Publicação: Artigo Completo

Área do Conhecimento: Área Exatas e Tecnologias; Engenharias; Pesquisa.

¹ Laboratório de Bioinformática e Ciências Ômicas (LaBiOmics), Universidade de Mogi das Cruzes, Mogi das Cruzes, SP, Brasil.

RESUMO

Objetivo: Desenvolver e implementar um modelo funcional de detecção utilizando visão computacional para a identificação e classificação precisa de *Tenebrio molitor*, mais conhecido como tenébrio ou larva-da-farinha. **Métodos:** A metodologia adotada compreendeu a aquisição de 394 imagens brutas e respectivas anotações detalhadas de tenébrios, utilizando a plataforma *Roboflow*. Realizou-se o pré-processamento e a augmentação das imagens para mitigar o *overfitting*, totalizando 946 imagens. A partição do conjunto de dados seguiu uma distribuição de 70% para treinamento, 20% para validação e 10% para teste. O modelo de detecção foi submetido a retreinamento com parâmetros constantes, sendo a avaliação do desempenho conduzida por meio de métricas como *Precision*, *Recall* e *mAP@0.5*. **Resultados:** O modelo exibiu um desempenho significativo, alcançando uma precisão de 93,6%, *recall* de 88,4% e *mAP* de 94,8%. Estes resultados denotam uma notável melhoria em relação a modelos preexistentes. A análise dos resultados indica que a introdução de novas imagens e a implementação da técnica de augmentação de rotação desempenharam uma função crucial na otimização da eficácia do modelo. **Conclusão:** O presente estudo contribui significativamente para o avanço da visão computacional na entomologia aplicada, oferecendo não apenas uma solução prática para a identificação de insetos comestíveis, mas também estabelecendo uma base para futuras investigações em outras espécies e contextos industriais.

Palavras-chave: *Tenebrio molitor*, Visão Computacional, MS COCO, *Roboflow*, Aprendizado de Máquina.

ABSTRACT

Objective: Develop and implement a functional detection model using computer vision for the precise identification and classification of *Tenebrio molitor*, better known as mealworm or flour beetle larva. **Methods:** The adopted methodology involved acquiring 394 raw images and their respective detailed annotations of mealworms using the *Roboflow* platform. Pre-processing and image augmentation were performed to mitigate overfitting, resulting in a total of 946 images. The data set was partitioned with a distribution of 70% for training, 20% for validation, and 10% for testing. The detection model underwent retraining with constant parameters, and performance evaluation was conducted using metrics such as Precision, Recall, and mAP@0.5. **Results:** The model exhibited significant performance, achieving an accuracy of 93.6%, recall of 88.4%, and mAP of 94.8%. These results indicate a notable improvement compared to pre-existing models. Result analysis suggests that the introduction of new images and the implementation of the rotation augmentation technique played a crucial role in optimizing the model's effectiveness. **Conclusion:** This study contributes significantly to the advancement of computer vision in applied entomology, providing not only a practical solution for the identification of edible insects but also establishing a foundation for future investigations in other species and industrial contexts.

Keywords: *Tenebrio molitor*, Computer Vision, MS COCO, *Roboflow*, Machine Learning

RESUMEN

Objetivo: Desarrollar e implementar un modelo funcional de detección utilizando visión computacional para la identificación y clasificación precisa de *Tenebrio molitor*, más conocido como gusano de la harina o larva de escarabajo de la harina. **Métodos:** La metodología adoptada implicó la adquisición de 394 imágenes en bruto y sus respectivas anotaciones detalladas de gusanos de la harina utilizando la plataforma *Roboflow*. Se realizó el preprocesamiento y la aumentación de imágenes para mitigar el sobreajuste, dando como resultado un total de 946 imágenes. La partición del conjunto de datos siguió una distribución del 70% para entrenamiento, 20% para validación y 10% para prueba. El modelo de detección fue sometido a un nuevo entrenamiento con parámetros constantes, y la evaluación del rendimiento se llevó a cabo mediante métricas como *Precision*, *Recall* y *mAP@0.5*. **Resultados:** El modelo mostró un rendimiento significativo, alcanzando una precisión del 93,6%, un *recall* del 88,4% y un *mAP* del 94,8%. Estos resultados indican una mejora notable en comparación con modelos preexistentes. El análisis de resultados sugiere que la introducción de nuevas imágenes y la implementación de la técnica de aumentación de rotación jugaron un

papel crucial en la optimización de la eficacia del modelo. **Conclusión:** Este estudio contribuye de manera significativa al avance de la visión computacional en entomología aplicada, ofreciendo no solo una solución práctica para la identificación de insectos comestibles, sino también estableciendo una base para futuras investigaciones en otras especies y contextos industriales.

Palabras clave: *Tenebrio molitor*, Visión Computacional, MS COCO, *Roboflow*, Aprendizaje Automático.

1. INTRODUÇÃO

A visão computacional tem desempenhado um papel fundamental na revolução tecnológica da agricultura e indústria alimentícia, proporcionando avanços significativos em termos de eficiência, precisão e sustentabilidade¹. Esta área interdisciplinar, que combina conhecimentos de ciência da computação e processamento de imagens, tem se destacado na identificação e classificação de organismos, abrindo novas perspectivas para a inovação biotecnológica e biomédica.

No contexto agrícola, a aplicação da visão computacional tem se revelado indispensável no manejo e gestão de plantas e animais de interesse comercial²⁻⁴. Desde a monitorização de culturas até o acompanhamento do desenvolvimento animal, as tecnologias visuais têm aprimorado a tomada de decisões e a eficácia operacional⁵. No entanto, seu impacto transcende os limites agrícolas, estendendo-se à identificação de novas espécies de interesse biotecnológico e biomédico, promovendo avanços significativos na compreensão e exploração da diversidade biológica^{6,7}.

Neste contexto, o presente artigo propõe a implementação de um modelo de visão computacional, desenvolvido através do *Microsoft Common Objects in Context (MS COCO)*⁸ na plataforma *Roboflow*⁹, para a identificação e classificação precisa do inseto *Tenebrio molitor*. Este inseto, popularmente conhecido como tenébrio, destaca-se como um dos insetos comestíveis mais importantes, sendo reconhecido não apenas por seu valor nutricional, mas também por seu potencial sustentável na indústria alimentícia.

A crescente demanda por fontes de proteína alternativas e sustentáveis tem elevado o *status* dos insetos comestíveis como uma opção viável¹⁰. Os tenébrios, em particular, emergem como protagonistas nesse cenário, apresentando-se como uma fonte de proteína rica e de baixo impacto ambiental¹¹. No entanto, sua criação em escala comercial requer técnicas avançadas de manejo, incluindo a identificação precisa de indivíduos, o que motiva a integração da visão computacional neste contexto¹².

Este trabalho visa, portanto, explorar a sinergia entre a visão computacional e a criação de tenébrios, apresentando um modelo eficiente para a identificação e classificação desses insetos. Ao fazê-lo, almejamos contribuir não apenas para o avanço na produção sustentável de alimentos, mas também para a compreensão mais profunda das potencialidades que a visão computacional oferece no domínio da entomologia aplicada.

2. MATERIAL E MÉTODOS

2.1. Conjunto de Dados

A coleta de dados adotada neste estudo envolveu duas categorias principais de arquivos no conjunto de dados, ambas concebidas para proporcionar uma representação abrangente dos tenébrios (*Tenebrio molitor*).

A primeira categoria consiste em imagens digitais brutas, compreendendo um total de 394 unidades. Estas imagens abrangem uma extensa variedade de poses, ângulos e contextos de fundo, todas no formato *JPG*. Concomitantemente, foram gerados arquivos de anotação de imagem correspondentes às 394 imagens brutas. Esses arquivos, essenciais para a execução do treinamento do modelo, detalham as coordenadas exatas dos objetos presentes nas imagens e fornecem rótulos identificadores para cada tenébrio (Figura 1). Um dos atributos presentes nos rótulos são as fases de desenvolvimento do tenébrio (larva, pupa e besouro), além disso, foi inserido um rótulo para a identificação de larvas de tenébrio mortas. A anotação foi conduzida de maneira sistemática e consistente, empregando o método de caixas delimitadoras através da plataforma *Roboflow*⁹

A escolha de empregar o *Roboflow*⁹ como plataforma para a anotação não apenas assegurou a eficiência no processo, mas também conferiu padronização, garantindo consistência nas marcações e facilitando a interpretação e manipulação dos dados. Este método estabelece uma base sólida para o treinamento do modelo de visão computacional, visando atingir níveis elevados de precisão na identificação e classificação dos tenébrios em diversas condições visuais.

2.2. Pré-processamento e Augmentação de Dados

Para reduzir o *overfitting* do nosso modelo, utilizamos procedimentos de pré-processamento e augmentação de imagens fornecidos pelo *Roboflow*⁹. O pré-processamento da imagem incluiu o redimensionamento da imagem para resolução de 640×640. Na etapa de augmentação, geramos variantes diferentes de imagens de treinamento usando augmentação de rotação (Rotação de 90°: sentido horário, anti-horário, de cabeça para baixo) para variar o número de objetos (ou seja, tenébrios) na imagem e aumentar a diversidade dos dados de treinamento.

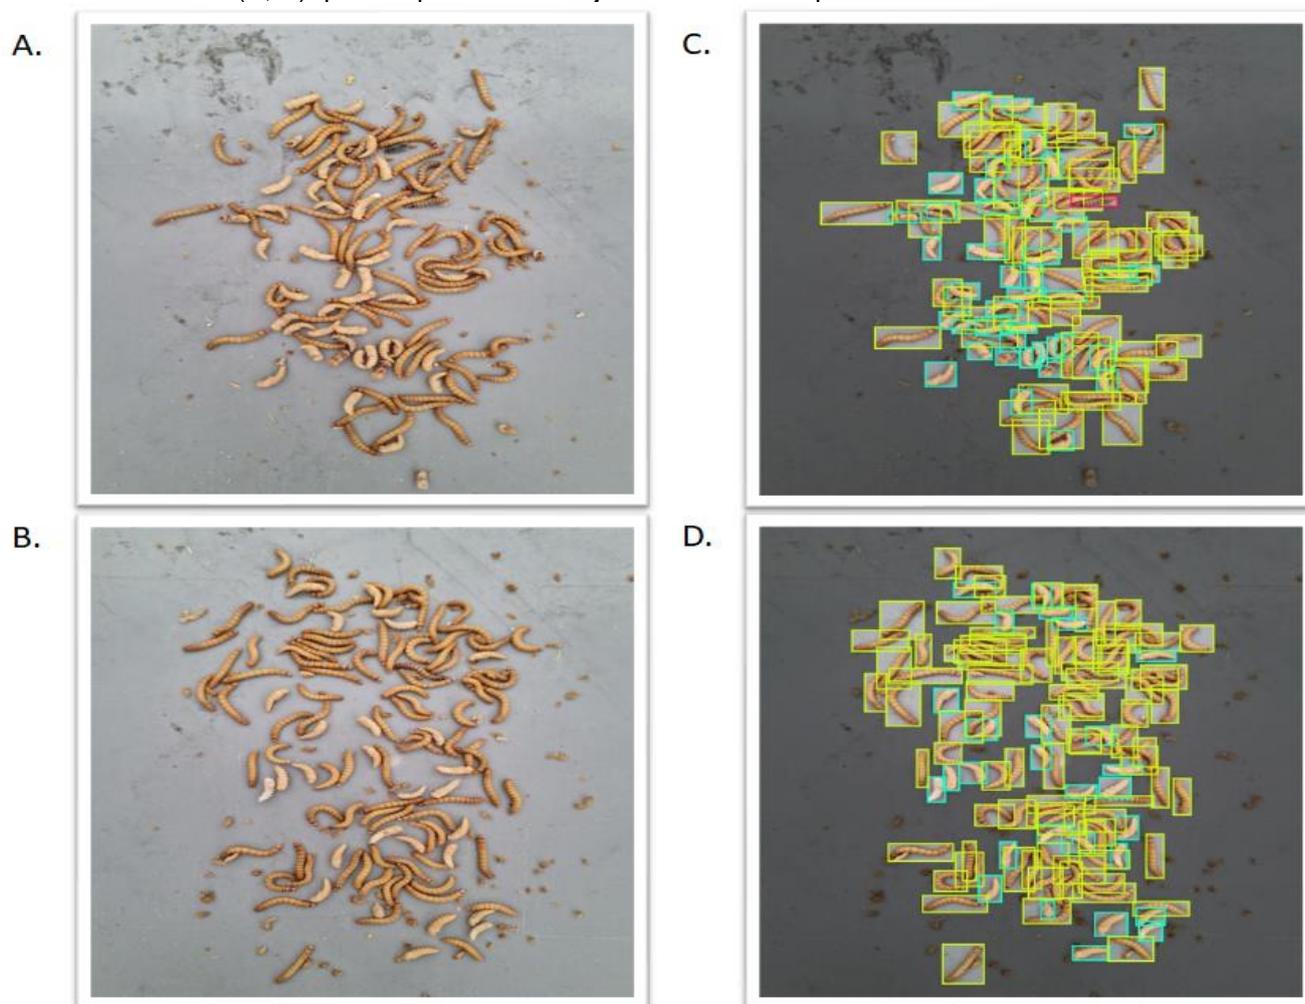
2.3. Proporção de Divisão dos Dados

O conjunto de dados original de imagens consistia em 394 imagens com diferentes números de densidades de tenébrios. Após o processo de augmentação, foram geradas 946 imagens. Para treinar o modelo de detecção, dividimos o novo conjunto de dados em conjuntos de treinamento, validação e teste numa proporção de 70:20:10, respectivamente. Uma proporção maior de dados foi utilizada na fase de treinamento devido à complexidade da detecção de tenébrios (ou seja, objetos pequenos) e para aumentar as características de aprendizado dos tenébrios durante a fase de treinamento. Além disso, essa proporção

se aproxima as proporções comumente usadas para tarefas de detecção de insetos e doenças usando modelos de aprendizado profundo ¹³⁻¹⁶.

O conjunto de treinamento consistiu em 757 imagens, 79 imagens para o conjunto de validação e 39 imagens para o conjunto de teste, todos com uma resolução de entrada de 640x640 pixels. Após a definição dos conjuntos de treinamento, validação e teste, as imagens foram utilizadas para treinar o modelo *Microsoft Common Objects in Context (MS COCO)* ⁸ para detectar tenébrions e avaliar todas as métricas de desempenho.

FIGURA 1. Exemplos de imagens com resolução de entrada de 640 x 640 pixels sem (A, B) ou com rótulos (C, D) que compuseram o conjunto de dados do presente trabalho.



Fonte: Takao et al. (2023)

2.4. Treinamento do Modelo e Descrição dos Hiperparâmetros

O modelo de detecção avaliado neste estudo foi pré-treinado no conjunto de dados *Common Objects in Context (COCO)* ⁸. Retreinamos o presente modelo utilizando um conjunto de dados de imagens

rotulado manualmente para a detecção de tenébrios. Utilizamos as configurações padrões de 300 épocas (*epochs*) com um tamanho de lote de 32 como parâmetros de treinamento.

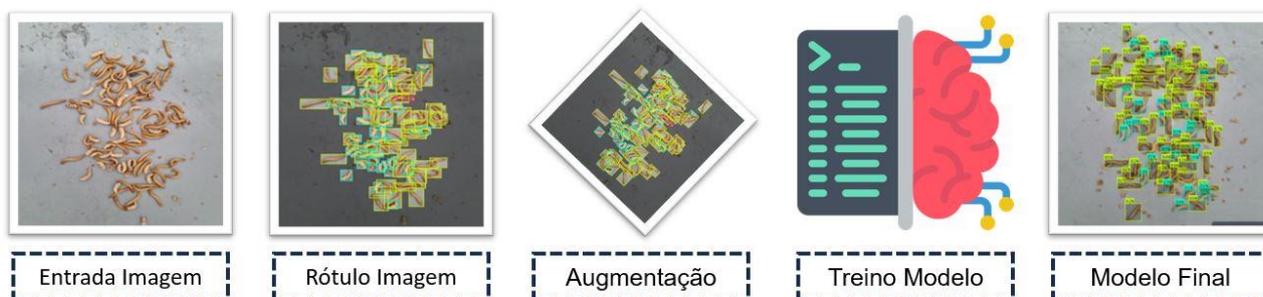
2.5. Métricas de Desempenho do Modelo Treinado

Para modelos de detecção de objetos, *Precision*, *Recall* e *Mean Average Precision (mAP)* são métricas populares para avaliar o desempenho geral, utilizando uma Interseção sobre União definida como 0,5 (*mAP@0.5*)^{17,18}. Avaliamos essas métricas para determinar a robustez do modelo de detecção de objetos. A Interseção sobre União (*IoU*) é uma métrica que mede a área de sobreposição entre a caixa delimitadora prevista e a caixa delimitadora verdadeira, dividida pela área de união entre elas¹⁹. A métrica de precisão é a capacidade do modelo de detecção em identificar apenas objetos relevantes e representa a porcentagem de previsões positivas corretas¹⁹. A porcentagem de previsões positivas corretas em relação a todos os verdadeiros positivos fornecidos é definida como *recall*¹⁹.

2.6. Diagrama de Fluxo de Dados

O fluxo de dados para toda a nossa metodologia é caracterizado na Figura 2. As imagens de treinamento são usadas para treinar o modelo, enquanto as imagens de validação são usadas para avaliar e ajustar os hiperparâmetros. O desempenho do modelo final utilizado neste estudo foi avaliado nas imagens de teste.

FIGURA 2. Fluxo de dados para avaliar o desempenho do modelo de detecção de tenébrios.



Fonte: Takao et al. (2023)

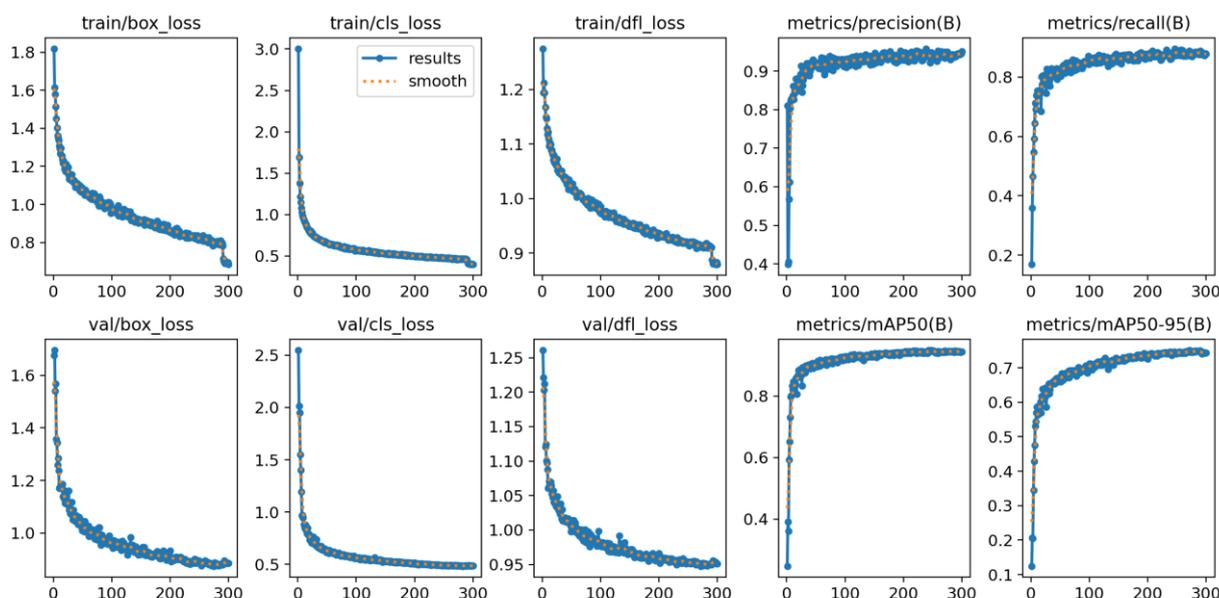
3. RESULTADOS E DISCUSSÃO

O modelo de visão computacional, denominado *Tenebrio AI Detection*, foi meticulosamente desenvolvido para a identificação e classificação precisa do *Tenebrio molitor*, revelando um desempenho notável e métricas robustas. A precisão do modelo atingiu 93.6%, indicando sua habilidade em corretamente classificar os tenébrios identificados nas imagens. O *recall*, alcançando 88.4%, evidenciou a capacidade abrangente do modelo em identificar os tenébrios presentes nas imagens analisadas. Além disso, o *mAP (mean Average Precision)*, atingindo 94.8%, refletiu a consistência geral do modelo em sua performance, conforme apresentado na Figura 3.

Ao comparar os resultados do *Tenebrio AI Detection* com modelos anteriores desenvolvidos para a mesma problemática através do *Roboflow*⁹, nota-se uma significativa melhoria. O modelo anterior, utilizando 202 imagens, apresentou um *precision* de 75.8%, *recall* de 58.8%, e *mAP* de 66.0%. A disparidade entre esses resultados sugere um avanço substancial no desempenho alcançado com o modelo proposto, permitindo a identificação eficaz de larvas vivas e mortas, pupas e besouros (Figura 4).

A análise da precisão média por classe, tanto no conjunto de validação quanto no conjunto de teste, revelou resultados robustos para os rótulos disponíveis, como larva viva e morta, pupa e besouro. A precisão média por classe para o conjunto de validação foi de 95%, 93%, 94%, 96%, e 96% para todos os rótulos, besouros, larvas mortas, larvas e pupas, respectivamente. Já para o conjunto de teste, foram observadas precisões médias por classe de 94%, 88%, 96%, 98%, e 95% para os mesmos rótulos.

FIGURA 3. Gráficos de *mAP* e perda após o treinamento do modelo no conjunto de dados de detecção de tenébrios.



Fonte: Takao et al. (2023)

A comparação com os estudos de Bramantoro e Pratondo²⁰, Majewski et al.²¹, Baur et al.²² e Majewski et al.²¹ destaca a relevância crescente da aplicação de métodos de visão computacional na identificação e classificação de *Tenebrio molitor*. Bramantoro e Pratondo²⁰ focam na distinção entre *Zophobas morio* e *Tenebrio molitor*, destacando as diferenças nutricionais e econômicas. Seu uso de aprendizado profundo, com arquiteturas *VGG-19* e *Inception v3*, evidencia as promissoras taxas de acurácia, reforçando a importância de abordagens avançadas para distinção precisa.

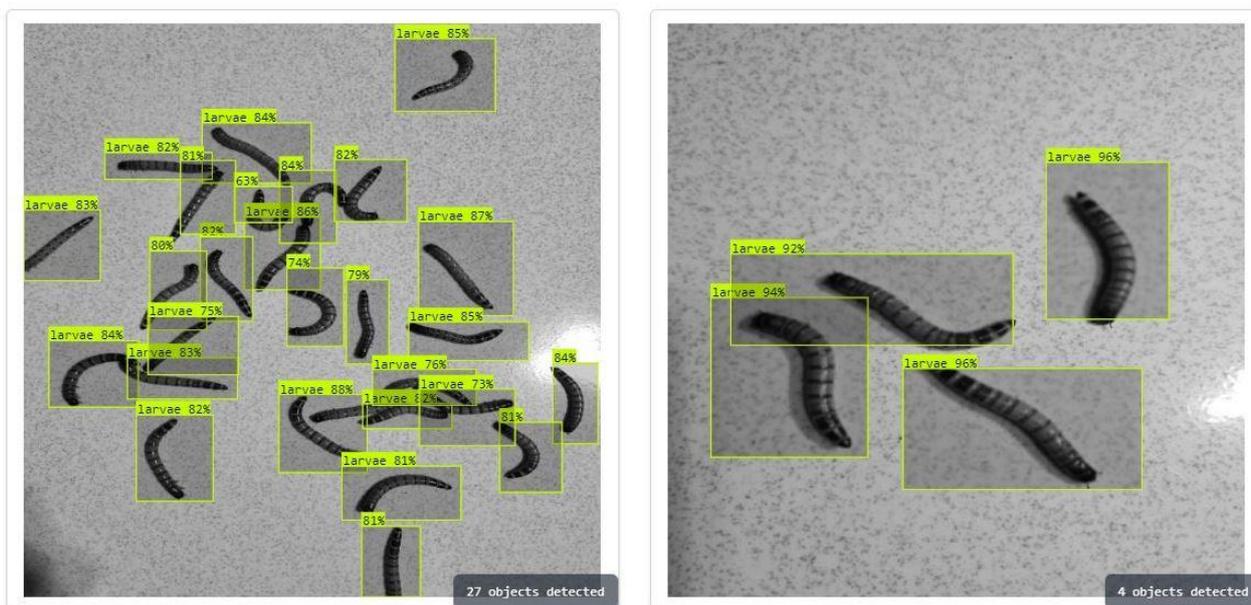
Majewski et al.²¹ propõem um sistema de monitoramento abrangente, utilizando módulos de segmentação de instâncias, segmentação semântica e fenotipagem de larvas. O emprego de modelos de aprendizado de máquina, como *Mask R-CNN*, *U-Net* e *LDA*, destaca a viabilidade dessas técnicas na automação e aprimoramento da produção em escala.

A pesquisa de Baur *et al.*²² reforça a necessidade crucial de técnicas híbridas para superar desafios específicos na criação de insetos. A combinação de processamento de imagem clássico e uma rede neural não apenas demonstra a eficácia na medição da distribuição de tamanho da população, mas também ressalta a importância de abordagens inovadoras na busca por soluções confiáveis e precisas.

Majewski *et al.*²³ contribui com uma abordagem eficiente para determinar a distribuição de tamanho de larvas em tempo real, utilizando uma rede neural de regressão convolucional (*RegCNN*) e transferência de conhecimento. Essa abordagem oferece uma medição indireta do comprimento e volume das larvas, minimizando a necessidade de rótulos extensivos, ressaltando a importância de métodos inovadores para a eficiência na análise de imagens densas.

Os resultados promissores deste estudo indicam um potencial significativo para a aplicação prática do modelo *Tenebrio AI Detection*. A contínua expansão do conjunto de dados, a otimização das resoluções de entrada e a aplicação contínua de técnicas de aumento de dados oferecem perspectivas para aprimorar ainda mais o desempenho do modelo. A metodologia e as descobertas deste estudo contribuem significativamente para o avanço da visão computacional aplicada à entomologia e, mais especificamente, à identificação precisa de insetos comestíveis.

FIGURA 4. Classificação das larvas de *Tenebrio molitor* utilizando o modelo treinado.



Fonte: Takao et al. (2023)

Como perspectiva futura, o trabalho aqui apresentado sugere um caminho promissor para a evolução contínua de modelos de visão computacional especializados em identificação de insetos. A integração de abordagens semelhantes às propostas por Bramantoro e Pratondo²⁰, Majewski *et al.*²¹, Baur *et al.*²³ e Majewski *et al.*²³ podem resultar em sistemas ainda mais abrangentes e eficientes. A colaboração entre essas diferentes abordagens e a contínua incorporação de inovações na área de aprendizado de

máquina e processamento de imagem oferecem uma perspectiva emocionante para o avanço contínuo na identificação precisa e automatizada de insetos, contribuindo para áreas como a produção de alimentos e a entomologia aplicada.

4. CONCLUSÃO

O presente estudo buscou integrar avanços significativos da visão computacional no domínio específico da identificação e classificação do *Tenebrio molitor*, um inseto de relevância crescente na indústria alimentícia. A implementação bem-sucedida do modelo proposto, utilizando o *MS COCO* na plataforma *Roboflow*, resultou em métricas notáveis, destacando a eficácia da abordagem adotada.

Os resultados obtidos evidenciam não apenas a precisão do modelo, mas também sua capacidade abrangente de identificação em diferentes contextos visuais. A comparação com modelos anteriores revelou uma melhoria substancial, destacando a importância da inclusão de novas imagens e a aplicação de estratégias de augmentação, como a rotação, para fortalecer a capacidade do modelo em lidar com variabilidades no ambiente.

Além de contribuir para a eficácia da produção sustentável de alimentos, este trabalho enfatiza a relevância da visão computacional na entomologia aplicada, abrindo caminho para aplicações mais amplas em outros contextos biológicos e industriais. A constante evolução e aprimoramento desses modelos são cruciais para enfrentar os desafios emergentes na agricultura e na indústria alimentícia, promovendo não apenas eficiência, mas também sustentabilidade.

À medida que avançamos, novas possibilidades surgem, não apenas para aprimorar a identificação de tenébricos, mas também para explorar aplicações similares em diferentes espécies de interesse econômico e biomédico. A sinergia entre a visão computacional e a entomologia aplicada representa uma fronteira promissora de pesquisa, oferecendo soluções inovadoras para desafios contemporâneos relacionados à produção de alimentos e à gestão de recursos naturais.

Em síntese, os resultados obtidos neste estudo não apenas validam a eficácia do modelo proposto, mas também destacam a importância contínua da inovação tecnológica na busca por soluções práticas e sustentáveis. Este trabalho oferece uma base sólida para futuras investigações, ampliando o escopo de aplicações da visão computacional na entomologia e consolidando sua posição como uma ferramenta essencial na promoção da segurança alimentar e sustentabilidade.

AGRADECIMENTOS E FINANCIAMENTO

P.S.T e J.F.M são bolsistas do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), R.C.O., R.R.R., P.S.C são bolsistas da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES). F.B.M é bolsista da Fundação de Amparo ao Ensino e Pesquisa (FAEP) da Universidade de Mogi das Cruzes (UMC).

CONFLITO DE INTERESSES

Os autores declaram não haver conflitos de interesse. Eles são os únicos responsáveis pelo conteúdo e pela redação do artigo.

DISPONIBILIDADE DOS DADOS

O conjunto de dados e o modelo apresentado no presente trabalho, denominado *Tenebrio AI Detection*, estão agora acessíveis e disponíveis para a comunidade científica no *Roboflow Universe* (<https://universe.roboflow.com/insectia-detect-vn18h/tenebrio-ai-detection>). Essa plataforma oferece uma maneira conveniente para pesquisadores e profissionais explorarem e utilizarem esses recursos valiosos relacionados à identificação e classificação de *Tenebrio molitor* por meio de visão computacional.

Além disso, o modelo pode ser experimentado como uma aplicação web, proporcionando facilidade de acesso e uso prático. A versatilidade dessa ferramenta é evidenciada pelo seu repositório no *GitHub* (<https://github.com/InsectOmics/TenebrioAI>), onde a comunidade pode explorar o modelo e seus resultados de forma interativa, promovendo colaboração e avanço na pesquisa em entomologia aplicada.

REFERÊNCIAS

1. Farhood H, Bakhshayeshi I, Pooshideh M, Rezvani N, Beheshti A. Recent advances of image processing techniques in agriculture. *Artificial Intelligence and Data Science in Environmental Sensing*; 2022. p. 129–53.
2. Haridasan A, Thomas J, Raj ED. Deep learning system for paddy plant disease detection and classification. *Environmental Monitoring and Assessment* 2023;195(1):120.
3. Elbasi E, Mostafa N, AlArnaout Z, Zreikat AI, Cina E, Varghese G, et al. Artificial intelligence technology in the agricultural sector: a systematic literature review. *IEEE Access* 2023;11:171-202.
4. Fracarolli JA, Pavarin FFA, Castro W, Blasco J. Computer vision applied to food and agricultural products. *Revista Ciência Agronômica*. 2020;51(5):e20207749.
5. Ji B, Zhu W, Liu B, Ma C, Li X. Review of Recent Machine-Vision Technologies in Agriculture. Em: 2009 Second International Symposium on Knowledge Acquisition and Modeling. Wuhan, China: IEEE 2009; p. 330–4.
6. Holzinger A, Keiblinger K, Holub P, Zatloukal K, Müller H. AI for life: Trends in artificial intelligence for biotechnology. *New Biotechnology* 2023;74:16–24.
7. Voulodimos A, Doulamis N, Doulamis A, Protopapadakis E. Deep Learning for Computer Vision: A Brief Review. *Computational Intelligence and Neuroscience*. 2018;2018:1–13.
8. Lin TY, Maire M, Belongie S, Hays J, Perona P, Ramanan D, et al. Microsoft coco: Common objects in context. Em: *Computer Vision—ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part V 13*. Springer 2014. p. 740–55.
9. Dwyer B, Nelson J, Solawetz J. Roboflow (version 1.0) [acesso em 16 nov 2023]. Disponível em: <https://roboflow.com>.
10. Nascimento AF do, Natel AS, Corsini F dos S, Madureira ER, Costa DV da. Insetos: Alimento sustentável para alimentação animal. *SA*. 2020;159–99.
11. Reis TL, Dias ACC. Farinha de insetos na nutrição de monogástricos. *RVZ*. 6 de maio de 2020;27:1–16.
12. Cadinu LA, Barra P, Torre F, Delogu F, Madau FA. Insect Rearing: Potential, Challenges, and Circularity. *Sustainability*. 3 de junho de 2020;12(11):4567.
13. Kiratiratanapruk K, Temniranrat P, Sinthupinyo W, Marukatat S, Patarapuwadol S. Automatic Detection of Rice Disease in Images of Various Leaf Sizes. *arXiv preprint 2022*; arXiv:220607344.
14. Krishnadas P, Sampathila N. Automated detection of malaria implemented by deep learning in PyTorch. Em: 2021 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT) 2021; p. 01–5.
15. Mulchandani P, Siddiqui MU, Kanani P. Real-time mosquito species identification using deep learning techniques. *International Journal of Engineering and Advanced Technology* 2019;2249–8958.
16. Teixeira AC, Ribeiro J, Neto A, Morais R, Sousa JJ, Cunha A. Using deep learning for detection and classification of insects on traps. *IGARSS 2022-2022 IEEE International Geoscience and Remote Sensing Symposium* 2022;5746–9.
17. Ahmad I, Yang Y, Yue Y, Ye C, Hassan M, Cheng X, et al. Deep learning-based detector yolov5 for identifying insect pests. *Applied Sciences* 2022;12(19):10167.

-
18. Henderson P, Ferrari V. End-to-End Training of Object Class Detectors for Mean Average Precision. Em: Lai SH, Lepetit V, Nishino K, Sato Y, organizadores. Computer Vision – ACCV 2016. Cham: Springer International Publishing 2017; p. 198–213. (Lecture Notes in Computer Science; vol. 10115).
 19. Padilla R, Netto SL, Da Silva EA. A survey on performance metrics for object-detection algorithms. Em: 2020 international conference on systems, signals and image processing (IWSSIP). IEEE 2020. p. 237–42.
 20. Pratondo A, Bramantoro A. Classification of Zophobas morio and Tenebrio molitor using transfer learning. PeerJ Computer Science 2022;8:e884.
 21. Majewski P, Zapotoczny P, Lampa P, Burduk R, Reiner J. Multipurpose monitoring system for edible insect breeding based on machine learning. Scientific Reports 2022;12(1):7892.
 22. Baur A, Koch D, Gatternig B, Delgado A. Noninvasive monitoring system for Tenebrio molitor larvae based on image processing with a watershed algorithm and a neural net approach. Journal of Insects as Food and Feed 2022;8(8):913–20.
 23. Majewski P, Mrzyglód M, Lampa P, Burduk R, Reiner J. Monitoring the growth of insect larvae using a regression convolutional neural network and knowledge transfer. Engineering Applications of Artificial Intelligence 2023;127:107358.