

**EGGSCAN-AI - APLICAÇÃO WEB PARA CONTAGEM DE OVOS EM OVITRAMPAS PARA
Aedes spp.**

**EGGSCAN-AI - WEB APPLICATION FOR COUNTING EGGS IN OVITRAPS
FOR *Aedes* spp.**

William Cardoso Barbosa

Fundação Oswaldo Cruz, Laboratório de Bioinformática e Química Medicinal, Porto Velho, RO, Brasil
wcardoso.barbosa@aluno.fiocruz.br

Matheus de Araújo Paz

Fundação Oswaldo Cruz, Laboratório de Entomologia, Porto Velho, RO, Brasil
matheus.paz@fiocruz.br

Mirilene Mendes Martins

Universidade Federal de Rondônia, Laboratório de Bioecologia de Insetos, Porto Velho, RO, Brasil
mirimendes53@gmail.com

Alexandre de Almeida e Silva

Universidade Federal de Rondônia, Laboratório de Bioecologia de Insetos, Porto Velho, RO, Brasil
aleasil@unir.br

Jonathan da Silva Ramos

Universidade Federal de Rondônia, Departamento de Ciência da Computação, Porto Velho, RO, Brasil
jonathan@unir.br

Genimar Rebouças Julião

Fundação Oswaldo Cruz, Laboratório de Entomologia, Porto Velho, RO, Brasil
genimar.juliao@fiocruz.br

Fernando Berton Zanchi

Fundação Oswaldo Cruz, Laboratório de Bioinformática e Química Medicinal, Porto Velho, RO, Brasil
fernando.zanchi@fiocruz.br

RESUMO

A pesquisa apresenta o EggScan-AI, uma aplicação web desenvolvida para automatizar a contagem de ovos de *Aedes* spp. em palhetas de fibra de madeira utilizadas em ovitrapas, preconizadas pelo Ministério da Saúde do Brasil. O objetivo é oferecer uma solução prática e escalável para programas de vigilância entomológica. A metodologia envolveu a instalação das armadilhas e obtenção de 130 palhetas em duas localidades no município de Porto Velho-RO, seguido da digitalização com scanner doméstico, pré-processamento das imagens e o treinamento de um modelo YOLOv11 sobre 1.513 amostras de ovos registrados. O desempenho do modelo resultou em um mAP@50 de 0,895, precisão de 0,925 e recall de 0,808. Em ambiente operacional, com 130 palhetas reais, houve boa capacidade preditiva do modelo para a quantidade de ovos de *Aedes* observada ($r = 0,92$). Os resultados mostraram concordância com a avaliação humana e robustez em condições reais. Conclui-se que o EggScan-AI pode ser uma ferramenta acessível, consistente, capaz de reduzir o tempo das contagens e ampliar o esforço amostral durante o monitoramento desse importante mosquito, fortalecendo as estratégias de vigilância e controle vetorial.

Palavras-chave: Vigilância entomológica. Mosquitos vetores. Aprendizado profundo. Contagem automatizada.

ABSTRACT

The research presents EggScan-AI, a web application developed for the automatic counting of *Aedes* spp. eggs on wooden paddles used in ovitraps recommended by the Brazilian Ministry of Health. The objective is to offer a practical and scalable solution for entomological surveillance programs. The methodology involved trap installation and the sampling of 130 paddles in two locations in the municipality of Porto Velho, RO, followed by digitization with a

home scanner, image preprocessing, and the training of a YOLOv11 model on 1,513 recorded egg samples. The model's performance resulted in a mAP@50 of 0.895, precision of 0.925, and recall of 0.808. In an operational environment, using 130 real paddles, the model demonstrated good predictive capacity ($r = 0.92$) for the observed number of *Aedes* eggs. The results showed agreement with human observer analysis and robustness under real-world conditions. We conclude that EggScan-AI can be an affordable and consistent tool capable of reducing counting time and increasing sampling efforts during the monitoring of this important mosquito, thereby strengthening surveillance and vector control strategies.

Keywords: Entomological surveillance. Mosquito vectors. Deep learning. Automated counting.

INTRODUÇÃO

Dentre os mosquitos adultos e imaturos encontrados em ambientes tipicamente urbanos, destacam-se *Aedes aegypti* e *Aedes albopictus* (Lima-Camara *et al.*, 2006; Maia *et al.*, 2022). Essas espécies são mundialmente reconhecidas por participar da transmissão vetorial de diferentes vírus, com grande impacto aos sistemas de saúde devido aos surtos epidêmicos recorrentes e crescentes (Wallau *et al.* 2023). No Brasil, houve um aumento súbito nos casos de dengue, Zika e chikungunya entre os anos de 2023 e 2024, observando-se padrões de cocirculação dos vírus e *hotspots* de ocorrência no país (Daudt-Lemos *et al.* 2025). Mas atualmente verifica-se redução de 75,7%, 56,6% e 7,2% no número de casos prováveis de dengue, chikungunya e Zika, respectivamente, quando comparado aos mesmos períodos do ano anterior (Brasil, 2025a).

A persistência dessas arboviroses está intrinsecamente ligada aos determinantes sociais de saúde, uma vez que a distribuição espacial do *Aedes aegypti* não ocorre de forma homogênea, concentrando-se em áreas com vulnerabilidades estruturais e climáticas (Santos *et al.*, 2020). A urbanização acelerada e desordenada, aliada a deficiências crônicas no abastecimento de água e na gestão de resíduos sólidos, cria condições ideais para a manutenção de criadouros e a proliferação do vetor em aglomerados urbanos (Souza *et al.*, 2023). Estudos indicam que o baixo nível socioeconômico e a alta densidade populacional são preditores cruciais para a formação de hotspots de transmissão, evidenciando que o controle dessas patologias requer intervenções que transcendam o setor saúde e alcancem melhorias nas condições de vida e infraestrutura urbana (Honório *et al.*, 2009; Santos *et al.*, 2019).

O Programa Nacional de Controle da Dengue (PNCD) estabelece diretrizes estratégicas para reduzir a infestação pelo *Aedes aegypti*, minimizar a incidência de casos de dengue e diminuir a letalidade da doença no Brasil. Dentro desse contexto, a vigilância entomológica desempenha um papel central ao fornecer dados sistemáticos sobre os níveis de infestação do vetor em diferentes áreas geográficas, permitindo a identificação de locais de maior risco e a implementação oportuna de medidas de controle (Brasil, 2002).

Diferentes técnicas podem ser empregadas para o monitoramento de *Aedes aegypti*, tais como Pesquisa Larvária, armadilhas Adultrap, MosquiTrap e BG-Sentinela, com destaque para as armadilhas de oviposição denominadas ovitrampas, que constituem uma técnica altamente sensível e específica, além de representarem baixo custo operacional (Fiocruz, 2014). Ao gerar métricas baseadas em ovos, as ovitrampas podem fornecer boas estimativas de variação nas densidades populacionais de adultos dos mosquitos *Aedes*, além de melhor sensibilidade e sua forte associação com variáveis climáticas (Codeço *et al.* 2015).

Recentemente, o Ministério da Saúde lançou nota técnica recomendando o aprimoramento da vigilância entomológica por meio do uso de ovitrampas em todos os municípios brasileiros, considerando que essa armadilha é bastante efetiva mesmo em períodos de baixa infestação do mosquito e uma importante ferramenta para avaliação de novas tecnologias de controle vetorial (Brasil, 2025b). No entanto, as ovitrampas ainda apresentam desvantagens referentes ao tempo necessário para contagem de ovos e à necessidade de obtenção de larvas, pupas e/ou adultos para identificação taxonômica da espécie (Fiocruz 2014).

Visando resolver esse problema, diversos trabalhos relatam o uso de ferramentas (Gaburro *et al.*, 2016; Javed *et al.*, 2023) e algoritmos (Vivente *et al.*, 2025) utilizando IA para a contagem automatizada de ovos de mosquito. Apesar disso, alguns requerem o uso de equipamentos ópticos mais complexos (Naranjo-Alcazar *et al.*, 2024; Evans e Moorhead, 2025) ou substratos de oviposição não compatíveis/convencionais com aqueles usados em campo (Javed *et al.*, 2023; Wang *et al.*, 2024; Evans e Moorhead, 2025), limitando seu uso em condições similares àquelas empregadas no monitoramento desses vetores no Brasil.

Aplicações da Inteligência artificial em análise de imagens biológicas

De acordo com Sheikh *et al.* (2023), definir inteligência artificial (IA) não é uma tarefa fácil, pois existem várias definições que são utilizadas para se referenciar ao termo, o que pode levar à confusão. Em sua definição mais estrita, a IA é a imitação por computadores da inteligência inerente aos humanos. Dentro do vasto campo da IA, é fundamental reconhecer a diversidade de sistemas que podem ser classificados como baseados em IA. Kühl *et al.* (2022) propõem uma tipologia que distingue entre sistemas de IA estáticos e adaptativos, baseada na presença de *machine learning* (ML) em seu funcionamento.

O uso de algoritmos de ML na análise de imagens biológicas tem se expandido significativamente, permitindo não apenas a identificação de espécies, mas também a caracterização morfológica detalhada, como no estudo de ovos de mosquito (Zemouri *et al.* 2019).

Atualmente, existem diversas ferramentas de inteligência artificial (IA) voltadas para a análise de imagens, cada uma com suas peculiaridades e aplicações específicas. Entre as mais conhecidas, destacam-se YOLO (*You Only Look Once*), *Faster R-CNN* e *Single Shot MultiBox Detector* (SSD), que têm sido amplamente utilizadas em diversos estudos e aplicações práticas (Ren *et al.*, 2015; Redmon *et al.*, 2016; Liu *et al.*, 2016).

A aplicação do YOLO (*You Only Look Once*) é notável por sua capacidade de identificar rapidamente múltiplos objetos em uma única imagem. Essa abordagem é particularmente valiosa em análises em que, ao treinar um modelo YOLO com imagens, pesquisadores podem acelerar a detecção e melhorar a precisão das análises (Borba *et al.*, 2021; Xu *et al.*, 2023).

A abordagem do YOLO se destaca por sua arquitetura de estágio único, que permite a identificação de múltiplos pontos de interesse em uma única passada pela imagem, tornando-o uma ferramenta importante para tarefas de detecção e classificação voltadas a áreas biológicas (Diwan *et al.*, 2022; Xu *et al.*, 2023).

Inteligência artificial em monitoramento epidemiológico

A utilização de algoritmos de aprendizado de máquina (*machine learning* – ML) possibilita a identificação de surtos de doenças infecciosas em tempo real, facilitando intervenções rápidas e direcionadas. No entanto, é fundamental abordar os desafios relacionados à privacidade dos dados e à confiança pública, que são essenciais para a aceitação dessas tecnologias (Anjaria *et al.*, 2023).

O monitoramento epidemiológico não apenas melhora a detecção de surtos, mas também otimiza a alocação de recursos de saúde pública. A análise preditiva pode identificar áreas de riscos elevados, permitindo que as autoridades priorizem intervenções (Neill, 2012). A colaboração entre setores e a educação da população sobre os benefícios e riscos do uso de IA são essenciais para um sistema de vigilância eficaz (Hay *et al.*, 2013).

Um aspecto essencial da IA para o monitoramento epidemiológico é a capacidade de adaptação dos sistemas a novas ameaças e condições dinâmicas. Os modelos preditivos devem ser capazes de integrar dados em tempo real para que as autoridades de saúde possam reagir rapidamente a surtos emergentes (Oliver *et al.*, 2020). Tal flexibilidade acaba sendo vital para ajustes de previsões com base em mudanças nas variáveis epidemiológicas, como mutações ou modificações de patógenos.

O presente trabalho apresenta uma proposta que integra algumas soluções inovadoras para a contagem de ovos: o uso de substratos comumente empregados em ovitrampas de campo, a utilização de scanner de mesa para obtenção das imagens — dispensando equipamentos ópticos sofisticados — e a automatização da contagem por meio de algoritmos de ML.

MATERIAIS E MÉTODOS

Armadilhas de Oviposição - Ovitrapas

As principais descrições de ovitrampas podem ser encontradas em Fay e Eliason (1966), Reiter *et al.* (1991) e Brasil (2025b). No presente estudo, os ovos de mosquitos foram obtidos em substrato de fibra de madeira (Eucatex® ou similar), chamado de “palheta” (com cerca de 3 × 14 cm), inserida no interior de um vaso de plástico preto, preenchido com água de torneira (500 mL). A palheta foi acoplada verticalmente em seu interior, com a superfície rugosa voltada para a parede da armadilha (Figura 1).

Figura 1 – Armadilha de oviposição constituída de recipiente com água e palheta de fibra de madeira



Fonte: Os autores, 2025.

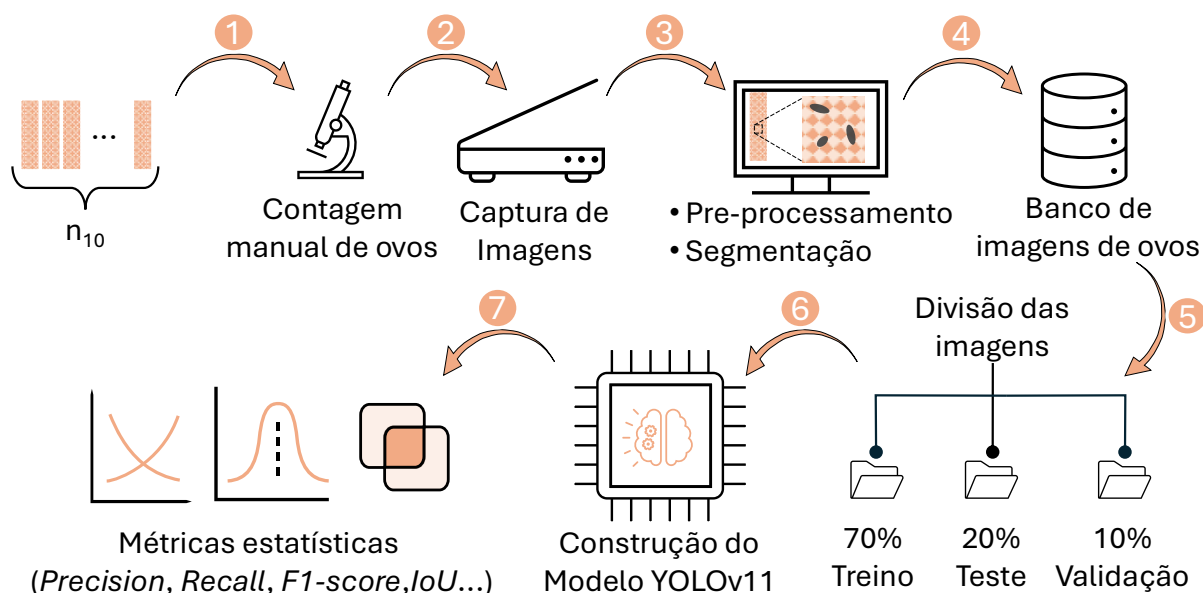
As armadilhas foram instaladas no período de fevereiro e março de 2025 em duas áreas no município de Porto Velho, estado de Rondônia, na região Norte do Brasil. A primeira foi na sede da Fundação Oswaldo Cruz – Fiocruz Rondônia com coordenadas (-8.784412 N, -63.859182 W) e a segunda no campus da Universidade Federal de Rondônia (UNIR) com coordenadas (-8.837445 N, -63.937979 W). Os locais de instalação de armadilhas eram protegidos de chuva e sombreados, onde permaneceram por sete dias. Após esse período, as armadilhas foram recolhidas e levadas ao laboratório. A água das ovitrampas foi descartada. As palhetas foram envolvidas em toalhas de papel, devidamente identificadas, e mantidas no insetário para secar em temperatura ambiente, por cerca de 2 a 3 dias.

A inspeção de palhetas para ovos foi realizada em microscópio estereoscópico (Leica EZ4), com a contagem de ovos feita por um observador treinado. O número de ovos foi registrado na etiqueta externa da palheta e em planilha, juntamente ao código da palheta, data da amostragem, responsável pela contagem manual e local de instalação das armadilhas.

Coleta de imagens, contagem de ovos e treinamento do algoritmo

O fluxo de treinamento de algoritmo foi estruturado em: (1) Coleta das imagens provenientes de dez palhetas iniciais e leitura manual em microscópio, (2) Escaneamento das palhetas em escâner, (3) Pré-processamento e segmentação dos ovos digitalmente, (4) Criação de uma base de imagens, (5) Divisão entre os grupos de treino, teste e validação, (6) Treinamento do algoritmo e (7) Análise das métricas estatísticas do modelo (Figura 2).

Figura 2 – Fluxo de treinamento do modelo de inteligência artificial: (1) Contagem manual de ovos; (2) Digitalização de imagens; (3) Preparo das imagens; (4) Armazenamento estruturado; (5) Divisão entre treino, teste e validação; (6) aplicação do algoritmo YOLOv11; (7) Cálculos das métricas de avaliação



Fonte: Os autores, 2025.

A captura das imagens foi realizada utilizando o *scanner* Epson L3150 ou L3250 (Epson) (Figura 3), o qual retornou imagens de alta resolução de 2128 x 6384 pixels, formato jpeg e 1200 de DPI (Pontos por polegada), garantindo a padronização do processo. Após a digitalização, as imagens foram submetidas a pré-processamento automatizado por um protocolo estabelecido durante a pesquisa, sem a necessidade de mudanças manuais, que consistiu na divisão em múltiplos quadros de 254 x 254 pixels, correção de exposição, ajuste de gama e aplicação de filtro gaussiano para redução de ruídos.

Em seguida, os ovos presentes em cada quadro foram anotados manualmente por uma equipe especializada de entomologistas. No processo de separação para o treinamento, os quadros foram divididos aleatoriamente em 70% para treinamento, 20% para teste e 10% para validação, sendo o último utilizado pelo YOLO durante o treinamento para ajuste automático de hiperparâmetros, conforme explicado por Xu e Goodacre (2018). O modelo empregado foi o YOLOv11, de acordo com Khanam e Hussain (2024), e foi treinado ao longo de 259 épocas com suporte de uma GPU (Unidade de Processamento Gráfico) (Nvidia GTX 1650 4G VRAM cuda 12) dedicada. Para aumentar a robustez do modelo e simular variações nas condições de escaneamento, foram aplicadas técnicas de *data augmentation*. Durante o treinamento, o *batch size* foi ajustado dinamicamente e a taxa de aprendizado otimizada por meio de um *scheduler* que reduzia os valores com base no desempenho do modelo sobre o conjunto de validação.

Além disso, técnicas como *early stopping* e decaimento de pesos foram aplicadas para evitar o *overfitting*. Para o teste do modelo, foram utilizadas métricas padrão da família YOLO (Redmon et al., 2016), tais como *Precision*, *Recall*, *IoU* (Intersection over Union), *AP* (Average Precision), *Confidence* e *mAP* (mean Average Precision).

Figura 3 – Modo de captura das imagens para processamento provenientes de palhetas contendo ovos de *Aedes* spp. coletados no Campus José Ribeiro Filho da Universidade Federal de Rondônia-UNIR e Fiocruz Rondônia utilizando scanner modelo Epson L3150 com 1200 de DPI



Fonte: Os autores, 2025.

Durante o treinamento, o YOLO utilizou-se de um conjunto de validação para ajuste de hiper parâmetros e monitoramento de desempenho, visando evitar *overfitting*. O conjunto de teste foi empregado apenas ao final, para avaliar a capacidade de generalização do modelo em dados inéditos.

Construção e Implementação do software Web

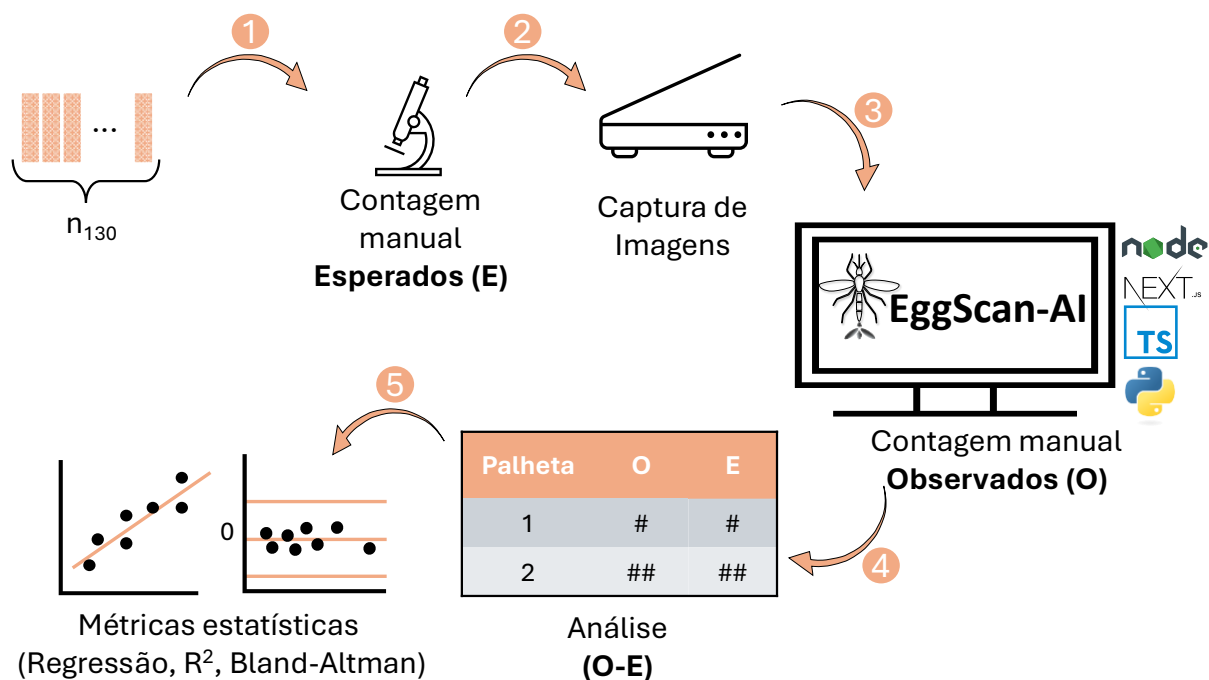
Após o treino e teste, foi desenvolvida uma plataforma web denominada EggScan-AI para a contagem automatizada de ovos em palhetas. Para o desenvolvimento do sistema, utilizou-se o editor de código Visual Studio Code (VS Code, MIT License, Microsoft), devido ao seu suporte a extensões e integração com sistemas de controle de versão, o que facilitou a colaboração e a manutenção do código-fonte. O *Frontend* da aplicação foi desenvolvido com o framework Next.js (MIT License, Vercel), integrado ao ecossistema React (MIT License, Meta), permitindo a construção de interfaces web com suporte à renderização no servidor, conforme descrito por Lazuardy e Anggraini (2022). A comunicação com o *Backend* é realizada por meio de uma arquitetura que combina dois bancos de dados: PostgreSQL (PostgreSQL License), responsável pelo armazenamento de informações estruturadas, e os Buckets da Supabase (Apache 2.0 License), empregados no gerenciamento das imagens enviadas pelos pesquisadores. A infraestrutura da aplicação foi implementada em containers Docker (Apache 2.0 License), orquestrados por meio do Docker Compose (Apache 2.0 License). Conforme destacado por Muzumdar *et al.* (2024), o uso de containers Docker é fundamental para garantir escalabilidade e portabilidade em aplicações modernas, permitindo o processamento eficiente de grandes volumes de dados em ambientes distribuídos. Além disso, adotou-se um fluxo de integração e entrega contínua (CI/CD) com GitHub Actions (proprietário, GitHub/Microsoft), que automatizou o processo de

atualização do sistema com correções e novas funcionalidades, assegurando entregas rápidas e confiáveis aos pesquisadores envolvidos nos testes. Por fim, o *Backend* foi desenvolvido com o framework NestJS (MIT License), baseado em Node.js (MIT License, OpenJS Foundation), escolhido por sua arquitetura modular e escalável.

Avaliação em ambiente operacional

Para avaliação em ambiente real, foram coletadas e escaneadas 130 palhetas pela equipe do Laboratório de Entomologia da Fundação Oswaldo Cruz – Fiocruz Rondônia, que realizou a contagem manual de ovos (quantidade esperada) (etapa 1, Figura 4). Em seguida, as palhetas foram digitalizadas (etapa 2, Figura 4) e submetidas ao EggScan-AI para serem analisadas pelo algoritmo, gerando a contagem automatizada dos ovos (quantidade observada) (etapa 3, Figura 4). Os resultados foram tabulados e a quantidade observada foi subtraída da esperada (etapa 4, Figura 4). Por último, foram avaliadas as métricas R^2 (coeficiente de determinação), MRE (*Mean Relative Error*), MAE (*Mean Absolute Error*) e DICE (*Dice coefficient*), utilizando a biblioteca SciPy (Virtanen *et al.*, 2020). Adicionalmente, empregou-se o teste de Bland-Altman na plataforma Jamovi (GNU GPL), conforme descrito por Bland e Altman (1986), a fim de analisar o grau de concordância entre os valores esperados e observados, complementando a avaliação da acurácia do modelo (etapa 4, Figura 4). Todas as imagens das palhetas foram disponibilizadas no repositório <https://anonymous.4open.science/r/eggs-count-algorithms-82E6/README.md>.

Figura 4 – Fluxo de uso do modelo em ambiente operacional: (1) contagem manual de ovos; (2) Digitalização das Palhetas; (3) Análise pelo algoritmo; (4) Análise dos dados; (5) Métricas estatísticas



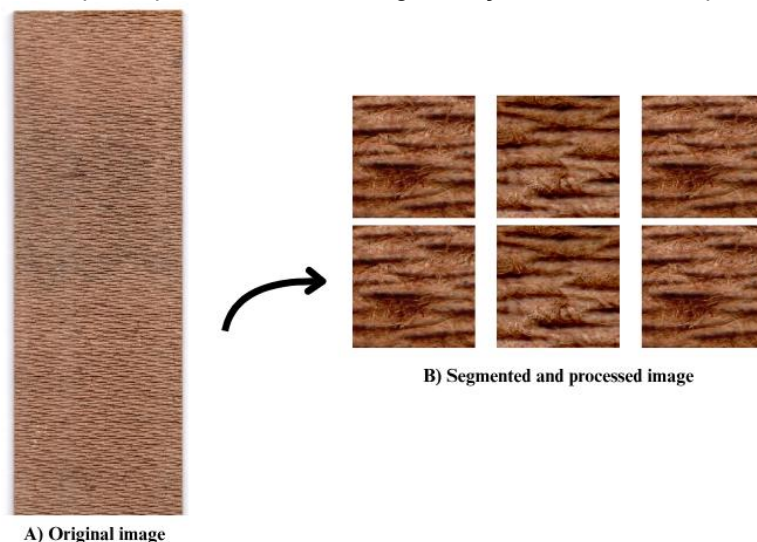
Fonte: Os autores, 2025.

RESULTADOS E DISCUSSÃO

Segmentação, tratamento e separação dos conjuntos

Após a coleta das imagens das dez palhetas escolhidas para o treinamento, foi realizado o pré-processamento das imagens seguidos de quatro etapas, inicialmente as imagens foram submetidas ao algoritmo de corte dos quadrados, após o corte foi aplicado a correção de gama, em seguida as imagens foram salvas (Figura 5) para anotação manual dos objetos.

Figura 5 – Exemplo de imagem bruta da palheta contendo ovos de *Aedes* spp. coletados no Campus da Universidade Federal de Rondônia-UNIR e Fiocruz Rondônia no período de fevereiro a março de 2025, após o processamento e segmentação em 254 × 254 pixels



Fonte: Os autores, 2025.

A última etapa de tratamento foi a aplicação do *augmentation* com os seguintes parâmetros: variações de matiz (HUE) entre -2° e $+2^\circ$; brilho entre -7% e $+7\%$; exposição entre -8% e $+8\%$ e ruído em 0,1% dos pixels. A Figura 6 mostra o resultado dessa etapa, que acumula também todas as etapas anteriores.

Figura 6 – Imagens após o *Data Augmentation* das imagens processadas de palhetas contendo ovos de *Aedes* spp. coletados no Campus da Universidade Federal de Rondônia-UNIR e Fiocruz Rondônia no período de fevereiro a março de 2025



Fonte: Os autores, 2025.

O tratamento e segmentação resultaram na geração de 1.513 imagens processadas, totalizando 1.345 ovos individualmente identificados. Para o desenvolvimento dos modelos de análise, esse conjunto de dados foi separado em três subconjuntos: treinamento, teste e validação (Tabela 1). A separação foi realizada de modo a manter a proporção entre os conjuntos, garantindo representatividade estatística em cada etapa de treinamento e avaliação.


Tabela 1 – Distribuição dos objetos (ovos) nos conjuntos de treinamento, teste e validação obtidas de palhetas contendo ovos de *Aedes* spp. coletados no Campus da Universidade Federal de Rondônia-UNIR e Fiocruz Rondônia no período de fevereiro a março de 2025

Conjunto	Objetos (ovos)	% Objetos
Treinamento	941	69,96%
Teste	269	20,00%
Validação	135	10,04%
Total	1.345	100,00%

Fonte: Os autores, 2025.

A Figura 7 apresenta a curva *Precision-Recall* do modelo na época 255. Nessa iteração, o modelo alcançou uma precisão de 0,925 e uma recall de 0,808. Esses valores indicam que o modelo consegue identificar a maior parte dos exemplos positivos mantendo uma taxa controlada de falsos positivos. A forma da curva, próxima ao canto superior direito, reflete a capacidade do modelo em manter um bom equilíbrio entre precisão e recall.


Figura 7 – Curva de *Precision* e *Recall* obtidas de palhetas contendo ovos de mosquitos *Aedes* coletados no Campus da Universidade Federal de Rondônia-UNIR e Fiocruz Rondônia no período de fevereiro a março de 2025



Fonte: Os autores, 2025.

O *F1 Score* (Figura 8), no melhor ponto de desempenho (mAP@50 de 0,895), o *F1 score* atingiu 0,863, refletindo um bom equilíbrio entre precisão (0,925) e recall (0,808). Na época final (259), houve uma leve queda no *F1 score* para 0,847, acompanhada de pequena redução na precisão e mAP@50.

Figura 8 – Evolução do *F1 Score* e da Confiança obtidas de palhetas contendo ovos de mosquitos *Aedes* coletados no Campus da Universidade Federal de Rondônia-UNIR e Fiocruz Rondônia no período de fevereiro a março de 2025



Fonte: Os autores, 2025.

A Tabela 2 apresenta os resultados gerais. O desempenho permaneceu estável, indicando que o modelo manteve boa generalização sem sinais de sobreajuste.

Tabela 2 – Visão geral dos resultados do treinamento do modelo YOLOv11 obtidas de palhetas contendo ovos de *Aedes* spp. coletados no Campus da Universidade Federal de Rondônia-UNIR e Fiocruz Rondônia no período de fevereiro a março de 2025

Nota	Época	mAP@0,5	Precision	Recall	F1-score	Loss Box (train/val)
Inicial	1	0,000	0,000	0,179	0,000	5,02 / 4,04
Melhor mAP50	255	0,895	0,925	0,808	0,863	1,27 / 1,54
Final	259	0,885	0,875	0,819	0,847	1,30 / 1,50

Fonte: Os autores, 2025.

Embora métodos baseados em segmentação, como o de Silva *et al.* (2022), tenham obtido resultados expressivos no espaço de cor *RGB* — com *IoU* (*Intersection over Union*) médio de 81,90% e *Dice coefficient* de 89,96% utilizando redes *U-Net* —, o presente trabalho emprega uma abordagem de detecção direta com YOLOv11. A avaliação foi realizada por meio do *mAP@0,5*, atingindo 89,5%. Apesar das semelhanças metodológicas, como a divisão em quadrados e a definição do espaço de cor *RGB*, observa-se que o YOLOv11 apresenta desempenho compatível à segmentação pixel a pixel, com a vantagem de localizar ovos individualmente e reduzir a necessidade de pós-processamento adicional. No estudo de Silva *et al.* (2022), por exemplo, foi necessário aplicar técnicas de fechamento morfológico

para unir regiões fragmentadas, abertura para remoção de ruídos e rotulação de componentes conectados para estimar a contagem de ovos a partir das máscaras segmentadas.

Avaliação em ambiente operacional

Após o treinamento, teste e validação do algoritmo, foi realizado um ensaio com palhetas em ambiente real para avaliar sua eficácia em condições operacionais. A Tabela 3 apresenta as quantidades esperadas (E), obtidas por contagem manual, e as quantidades observadas (O), estimadas pelo algoritmo, enquanto a Tabela 4 reúne as métricas de avaliação que indicam desempenho promissor na contagem automática de ovos.

Tabela 3 – Dados da contagem manual (Esperados) e automatizada (Observados) de ovos de *Aedes* spp. contidos nas 130 palhetas coletadas no Campus da Universidade Federal de Rondônia e Fiocruz-Rondônia no período de fevereiro a março de 2025 usadas na avaliação operacional do algoritmo

Nome da Imagem	Ovos esperados (E)	Ovos observados (O)	Diferença (O-E)
palheta-1-25.jpg	25	55	30
palheta-2-112.jpg	112	132	20
palheta-3-2.jpg	2	13	11
palheta-4-4.jpg	4	19	15
palheta-5-4.jpg	4	10	6
palheta-6-10.jpg	10	17	7
palheta-7-37.jpg	37	45	8
palheta-8-56.jpg	56	54	-2
palheta-9-5.jpg	5	14	9
palheta-10-21.jpg	21	26	5
palheta-11-34.jpg	34	54	20
palheta-12-107.jpg	107	177	70
palheta-13-125.jpg	125	140	15
palheta-14-158.jpg	158	179	21
palheta-15-11.jpg	11	20	9
palheta-16-13.jpg	13	15	2
palheta-17-21.jpg	21	47	26
palheta-18-26.jpg	26	39	13
palheta-19-28.jpg	28	34	6
palheta-20-27.jpg	27	31	4

palheta-21-38.jpg	38	46	8
palheta-22-55.jpg	55	57	2
palheta-23-65.jpg	65	40	-25
palheta-24-14.jpg	14	15	1
palheta-25-32.jpg	32	25	-7
palheta-26-53.jpg	53	65	12
palheta-27-89.jpg	89	103	14
palheta-28-15.jpg	15	24	9
palheta-29-25.jpg	25	30	5
palheta-30-64.jpg	64	74	10
palheta-31-100.jpg	100	99	-1
palheta-32-139.jpg	139	158	19
palheta-33-146.jpg	146	182	36
palheta-34-12.jpg	12	21	9
palheta-35-13.jpg	13	17	4
palheta-36-39.jpg	39	47	8
palheta-37-60.jpg	60	52	-8
palheta-38-82.jpg	82	98	16
palheta-39-272.jpg	272	316	44
palheta-40-8.jpg	8	11	3
palheta-41-56.jpg	56	40	-16
palheta-42-79.jpg	79	80	1
palheta-43-103.jpg	103	107	4
palheta-44-128.jpg	128	136	8
palheta-45-179.jpg	179	103	-76
palheta-46-12.jpg	12	15	3
palheta-47-47.jpg	47	76	29
palheta-48-148.jpg	148	109	-39
palheta-49-157.jpg	157	185	28

palheta-50-169.jpg	169	159	-10
palheta-51-178.jpg	178	91	-87
palheta-52-10.jpg	10	17	7
palheta-53-19.jpg	19	30	11
palheta-54-24.jpg	24	32	8
palheta-55-34.jpg	34	32	-2
palheta-56-41.jpg	41	29	-12
palheta-57-93.jpg	93	151	58
palheta-58-181.jpg	181	91	-90
palheta-59-28.jpg	28	16	-12
palheta-60-31.jpg	31	53	22
palheta-61-33.jpg	33	17	-16
palheta-62-82.jpg	82	105	23
palheta-63-83.jpg	83	60	-23
palheta-64-129.jpg	129	140	11
palheta-65-18.jpg	18	21	3
palheta-66-89.jpg	89	88	-1
palheta-67-114.jpg	114	132	18
palheta-68-15.jpg	15	21	6
palheta-69-54.jpg	54	67	13
palheta-70-66.jpg	66	74	8
palheta-71-92.jpg	92	65	-27
palheta-72-111.jpg	111	58	-53
palheta-73-4.jpg	4	11	7
palheta-74-95.jpg	95	106	11
palheta-75-172.jpg	172	225	53
palheta-76-11.jpg	11	28	17
palheta-77-21.jpg	21	39	18
palheta-78-24.jpg	24	33	9

palheta-79-49.jpg	49	54	5
palheta-80-54.jpg	54	54	0
palheta-81-90.jpg	90	107	17
palheta-82-14.jpg	14	24	10
palheta-83-59.jpg	59	60	1
palheta-84-22.jpg	22	15	-7
palheta-85-16.jpg	16	20	4
palheta-86-50.jpg	50	33	-17
palheta-87-108.jpg	108	69	-39
palheta-88-183.jpg	183	83	-100
palheta-89-14.jpg	14	18	4
palheta-90-17.jpg	17	19	2
palheta-91-102.jpg	102	96	-6
palheta-92-242.jpg	242	216	-26
palheta-93-148.jpg	148	144	-4
palheta-94-257.jpg	257	239	-18
palheta-95-26.jpg	26	38	12
palheta-96-30.jpg	30	31	1
palheta-97-7.jpg	7	6	-1
palheta-98-15.jpg	15	20	5
palheta-99-23.jpg	23	20	-3
palheta-100-60.jpg	60	56	-4
palheta-101-8.jpg	8	8	0
palheta-102-55.jpg	55	57	2
palheta-103-41.jpg	41	48	7
palheta-104-50.jpg	50	39	-11
palheta-105-3.jpg	3	13	10
palheta-106-29.jpg	29	15	-14
palheta-107-4.jpg	4	14	10

palheta-108-13.jpg	13	16	3
palheta-109-24.jpg	24	26	2
palheta-110-103.jpg	103	49	-54
palheta-111-136.jpg	136	160	24
palheta-112-32.jpg	32	39	7
palheta-113-34.jpg	34	52	18
palheta-114-46.jpg	46	46	0
palheta-115-0.jpg	0	3	3
palheta-116-11.jpg	11	15	4
palheta-117-3.jpg	3	3	0
palheta-118-152.jpg	152	150	-2
palheta-119-47.jpg	47	44	-3
palheta-120-12.jpg	12	12	0
palheta-121-2.jpg	2	6	4
palheta-122-16.jpg	16	28	12
palheta-123-8.jpg	8	13	5
palheta-124-1.jpg	1	8	7
palheta-125-18.jpg	18	24	6
palheta-126-58.jpg	58	53	-5
palheta-127-20.jpg	20	28	8
palheta-128-11.jpg	11	32	21
palheta-129-4.jpg	4	6	2
palheta-130-44.jpg	44	33	-11
Total	7.648	7.905	257

Fonte: Os autores, 2025.

Tabela 4 – Visão geral dos resultados das métricas em ambiente operacional obtidas de palhetas contendo ovos de mosquitos *Aedes* coletados no Campus da Universidade Federal de Rondônia-UNIR e Fiocruz Rondônia no período de fevereiro a março de 2025

*MAE (ovos)	MRE (%)	Pearson (r)	R ²	DICE
14,78	51,78	0,9166	0,8402	0,9961


*MAE = Erro Médio Absoluto (Mean Absolute Error); MRE = Erro Relativo Médio (Mean Relative Error); Pearson (r) = coeficiente de correlação de Pearson; R² = Coeficiente de Determinação; DICE = Coeficiente de Similaridade de DICE

Fonte: Os autores, 2025.

A Tabela 4 sintetiza o desempenho do modelo de contagem automática de ovos por meio de métricas complementares. O erro absoluto médio de 14,78 ovos indica a magnitude média das discrepâncias entre as contagens esperadas e observadas, enquanto o erro relativo médio de 51,78% evidencia maior sensibilidade do método em amostras com baixas quantidades de ovos. Apesar dessas variações locais, a correlação de Pearson elevada ($r = 0,9166$) e o coeficiente de determinação ($R^2 = 0,8402$) indicam que o modelo preserva a relação linear entre as contagens, explicando grande parte da variabilidade dos dados observados (Figura 9). O coeficiente DICE de 0,9961 reforça a elevada concordância global entre os valores esperados e observados.

Ao analisar a quantidade de ovos esperados por cada palheta individual, observa-se maior discrepância nas amostras com baixos valores de ovos esperados. Esse comportamento pode estar associado à definição do limiar de confiança adotado pelo modelo YOLO para a classificação de um objeto como ovo, o que pode influenciar a contagem em cenários de baixa densidade. Dessa forma, uma análise mais detalhada desses parâmetros pode contribuir para a otimização do desempenho do modelo. Em uma perspectiva global, a discrepância entre o total de ovos esperados e o total de ovos observados é pouco significativa, indicando que o método apresenta consistência suficiente para auxiliar a tomada de decisões no contexto de vigilância na zona estudada.

Figura 9 – Validação da Contagem Ovos observados (O) x Ovos Esperados (E) obtidas de palhetas contendo ovos de *Aedes* spp. coletados no Campus da Universidade Federal de Rondônia-UNIR e Fiocruz Rondônia no período de fevereiro a março de 2025



Fonte: Os autores, 2025.

O coeficiente DICE elevado indica alta concordância global entre as contagens manual e automatizada. Considerando que as imagens foram obtidas em condições reais de campo, com variabilidade de iluminação, fundo e ruído, esse resultado sugere que o modelo mantém desempenho consistente mesmo em cenários operacionais não controlados.

Em comparação, Javed *et al.* (2023) reportaram excelente desempenho do software EggCountAI, obtendo MAE (Mean Absolute Error) = 1,90 para imagens microscópicas e r (coeficiente de correlação de Pearson) = 0,99. No entanto, seus resultados foram obtidos em condições laboratoriais controladas, com substratos padronizados e ausência de ruídos ambientais significativos. O presente estudo, por sua vez, evidencia que é possível alcançar resultados aplicáveis mesmo com amostras coletadas diretamente em cenário real, onde há maior variabilidade de artefatos, iluminação e impurezas, fatores que normalmente desafiam o desempenho dos algoritmos. Em outro trabalho, Gaburro *et al.* (2018) demonstraram o software ICount, que atingiu alta acurácia para a contagem automática de ovos de *Aedes aegypti*. Contudo, o desempenho foi avaliado em condições laboratoriais controladas, especialmente quando utilizada a palheta de lixa (sandpaper) clara e imagens com bom contraste, resultando em R^2 (coeficiente de determinação) = 0,965 e erro reduzido de aproximadamente 2% para imagens com baixa e média densidade de ovos, definidas como aquelas contendo menos de 100 ovos por imagem. Para imagens com alta densidade de ovos, caracterizadas por mais de 200 ovos por imagem, o erro aumentou para cerca de 12%.


Por outro lado, no presente estudo, utilizou-se a palheta de fibra de madeira, um material poroso e escuro que, segundo a literatura, é mais atrativo aos mosquitos no processo de deposição de ovos em ambiente real (Liu *et al.*, 2014). Além disso, as palhetas foram coletadas diretamente do ambiente, sem qualquer tratamento ou padronização do fundo, refletindo a variabilidade e as condições adversas do campo, como fundos heterogêneos, impurezas e diferentes padrões de iluminação. Apesar desses desafios, o modelo alcançou desempenho consistente (MAE – Mean Absolute Error = 14,78; $R^2 = 0,8402$), demonstrando robustez mesmo em cenários menos favoráveis.

Na última avaliação, foi calculado o índice de concordância pelo método de Bland-Altman (Bland; Altman, 1986). Esta metodologia merece destaque, visto que a maioria dos trabalhos se apoia majoritariamente na métrica da correlação de Pearson (r). A grande dificuldade nesses casos é verificar a concordância absoluta e não apenas a tendência. O problema reside no fato de que, em algumas situações, o algoritmo contabiliza mais ovos do que realmente esperado (devido às sombras e rugosidades irregulares do material das palhetas). Nesses casos, a tendência medida pelo R^2 aumenta artificialmente e, portanto, não reflete o melhor resultado. Por exemplo, ao excluir uma palheta em que o algoritmo contou três ovos quando na realidade não havia nenhum (“palheta-115-0.jpg”), observou-se que o R^2 diminuiu para 0,8389. Em outras palavras, contabilizar mais ovos do que o esperado pode inflar o valor de R^2 , sem necessariamente indicar melhor acurácia.

Desse modo, a melhor forma de medir a concordância é com uma análise de Bland-Altman. O resultado pode ser visto na figura 10. O eixo horizontal é composto pela média entre os valores Observados e Esperados, bem como o eixo da vertical a diferença. As diferenças ficam em torno de zero e um p -value igual a 0.3 indicando que a hipótese nula (H_0) deve ser aceita, ou seja, não há diferença significativa entre as duas formas de contagem (manual e EggScan-AI).

Por fim, essa diferença metodológica ressalta a importância de validar algoritmos de contagem em contextos reais, onde a heterogeneidade das amostras pode impactar significativamente a performance, e reforça a aplicabilidade da abordagem proposta para situações de vigilância e monitoramento fora do ambiente laboratorial.

Figura 10 – Análise de Bland-Altman para as diferenças entre a contagem manual (Esperado) e pelo algoritmo (Observado) obtidas de palhetas contendo ovos de *Aedes* spp. coletados no Campus da Universidade Federal de Rondônia-UNIR e Fiocruz Rondônia no período de fevereiro a março de 2025

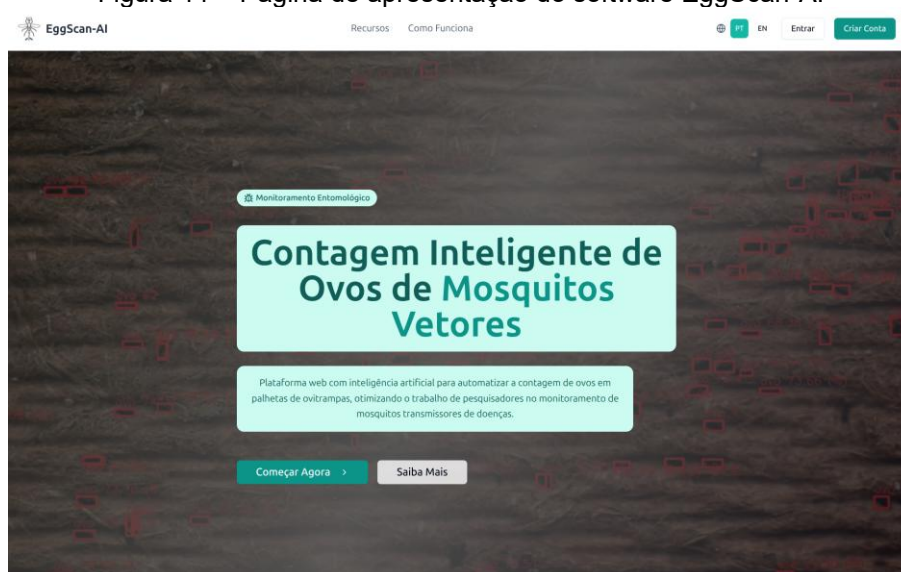


Fonte: Os autores, 2025.

Plataforma Web

A plataforma foi desenvolvida pelo Laboratório de Bioinformática e Química Medicinal (LABIOQUIM) da Fiocruz Rondônia e disponibilizada no endereço <https://ai-eggs-fiocruz-front.vercel.app/login> (Figura 11).

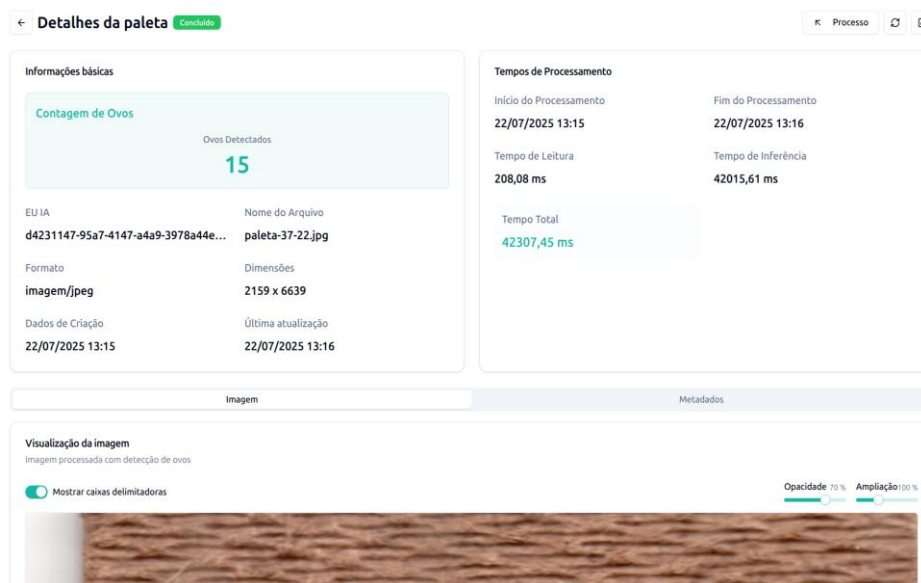
Figura 11 – Página de apresentação do software EggScan-AI



Fonte: Os autores, 2025.

A plataforma permite que o usuário submeta a palheta e em seguida visualize o resultado conforme a Figura 12, nesta tela é possível visualizar a demarcação da contagem de ovos pelo modelo validado.

Figura 12 – Visualização de uma palheta processada utilizando o software EggScan-AI. Palheta obtida a partir do banco de dados de palhetas contendo ovos de *Aedes* spp. coletados no Campus da Universidade Federal de Rondônia-UNIR e Fiocruz Rondônia no período de fevereiro a março de 2025



Fonte: Os autores, 2025.

A plataforma web desenvolvida desempenha papel central tanto em programas de vigilância, como em pesquisas científicas, permitindo que os profissionais submetam imagens de palhetas obtidas em condições reais de campo, com maior agilidade, rastreabilidade e controle de versões dos algoritmos, além de gerar métricas em tempo real para a avaliação da qualidade do modelo. O sistema EggScan-AI possibilita o envio em massa de palhetas, processamento assíncrono e geração de metadados. Em comparação, o software EggCountAI (Javed *et al.*, 2023) alcança alta precisão em ambiente laboratorial, mas não permite submissões em lote nem aplicação direta em campo, enquanto o ICount (Gaburro *et al.*, 2016) apresenta bons resultados em laboratório, mas depende de substratos específicos e não oferece rastreabilidade nem métricas adicionais.

CONCLUSÕES

Embora o estudo tenha apresentado resultados promissores em ambiente real, algumas limitações foram observadas, especialmente maior variação nas estimativas em palhetas com baixa densidade de ovos, além de eventuais discrepâncias associadas a ruídos visuais, condições de iluminação e irregularidades da superfície das palhetas. O uso de scanners no processo de aquisição das imagens contribuiu para reduzir a inconsistência visual nas imagens finais analisadas, minimizando variações de iluminação e perspectiva. Essas limitações não comprometem a aplicabilidade da plataforma, mas evidenciam desafios inerentes a cenários operacionais reais e a trabalhos relacionados, nos quais se busca a padronização das imagens.

Trabalhos futuros devem explorar a ampliação da base de treinamento com imagens provenientes de diferentes regiões, condições ambientais e variações nos formatos e materiais das palhetas, bem como a investigação de métodos mais avançados de pré-processamento de imagens, possibilitados pelo uso de scanners, visando aprimorar a acurácia do modelo e a robustez das estimativas. Como principal contribuição, este trabalho demonstra a viabilidade de integrar modelos avançados de aprendizado profundo, como o YOLOv11 a uma plataforma web acessível e escalável, capaz de apoiar estratégias

de vigilância entomológica em larga escala. A EggScan-AI apresenta potencial de aplicação prática no monitoramento de ovos de *Aedes aegypti* e a abordagem apresentada neste artigo poderá ser aplicado para outras espécies de mosquitos vetores, contribuindo para a modernização e o fortalecimento de programas de controle vetorial.

AGRADECIMENTOS

Os autores agradecem à Fundação para o Desenvolvimento Científico e Tecnológico em Saúde (FIOTEC) pelo apoio institucional e financeiro a partir de bolsa ao desenvolvimento desta pesquisa. À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo suporte na formação e capacitação de recursos humanos. Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo incentivo à pesquisa e ao financiamento de projetos que possibilitam o avanço da ciência e inovação tecnológica no país. À Fundação de Amparo ao Desenvolvimento das Ações Científicas e Tecnológicas e à Pesquisa de Rondônia (FAPERO) pelo apoio essencial à execução deste trabalho no contexto regional. Ao programa de Excelência em Pesquisa – PROEP Rondônia (Chamada Fiocruz Rondônia N° 02/2024), pelo apoio financeiro que proveu materiais e bolsas durante a execução desse estudo.

REFERÊNCIAS

- ANJARIA, P.; ASEDIYA, V.; BHAVSAR, P.; PATHAK, A.; DESAI, D.; PATIL, V. Artificial Intelligence in Public Health: Revolutionizing Epidemiological Surveillance for Pandemic Preparedness and Equitable Vaccine Access. *Vaccines*, v. 11, n. 7, p. 1154, 2023. <https://doi.org/10.3390/vaccines11071154>
- BLAND, J. M.; ALTMAN, D. G. Statistical methods for assessing agreement between two methods of clinical measurement. *The Lancet*, v. 327, n. 8476, p. 307–310, 1986.
- BORBA, V. H.; MARTIN, C.; MACHADO-SILVA, J. R.; XAVIER, S.; DE MELLO, F.; IÑIGUEZ, A. M. Machine learning approach to support taxonomic species discrimination based on helminth collections data. *Parasites & Vectors*, v. 14, n. 1, 2021. <https://doi.org/10.1186/s13071-021-04721-6>
- BRASIL. Ministério da Saúde. Programa Nacional de Controle da Dengue – PNCD. Brasília: Ministério da Saúde, 2002.
- BRASIL. Ministério da Saúde. 2025a. Centro de Operações de Emergências Dengue e outras arboviroses, Informe Semanal nº 17, SE 01 a 23/2025 (09/06/2025), <https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z/a/arboviroses/informe-semanal/2025>. Acesso em: 7 abr. 2025.
- BRASIL. Ministério da Saúde. 2025b. Secretaria de Vigilância em Saúde e Ambiente, Departamento de Doenças Transmissíveis, Coordenação-Geral de Vigilância de Arboviroses, Nota Técnica nº 3/2025-CGAR/DEDT/SVSA/MS - Implementação da estratégia de Vigilância Entomológica de *Aedes aegypti* e *Aedes albopictus* com armadilhas ovitrampas para o território nacional.
- CODEÇO, Claudia T. *et al.* Surveillance of *Aedes aegypti*: comparison of house index with four alternative traps. *PLoS Neglected Tropical Diseases*, v. 9, n. 2, p. e0003475, 2015. <https://doi.org/10.1371/journal.pntd.0003475>
- DAUDT-LEMOS, Matheus *et al.* Rising Incidence and Spatiotemporal Dynamics of Emerging and Reemerging Arboviruses in Brazil. *Viruses*, v. 17, n. 2, p. 158, 2025. DOI: <https://doi.org/10.3390/v17020158>
- 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, 2022. <https://doi.org/10.1007/s11042-022-13644-y>
- DWYER, B.; NELSON, J.; HANSEN, T.; *et al.* **Roboflow (Version 1.0) [Software]**. 2024. Disponível em: <https://roboflow.com>. Acesso em: 7 abr. 2025.
- EVANS, C. C.; MOORHEAD, A. R. A stand-alone tool for mosquito egg enumeration. *Journal of the American Mosquito Control Association*, v. 41, n. 1, p. 43–46, 2025.

EVERINGHAM, M.; VAN GOOL, L.; WILLIAMS, C. K. I.; WINN, J.; ZISSERMAN, A. The Pascal Visual Object Classes (VOC) Challenge. **International Journal of Computer Vision**, v. 88, n. 2, p. 303–338, 2010.

FAY, R.W.; ELIASON, D.A. A preferred oviposition site as a surveillance method for *Aedes aegypti*. **Mosquito News** 26: 531–535 pmid:14651662, 1966.

FIOCRUZ. Instituto Oswaldo Cruz. Nota Técnica n.º 3/2014/IOC-FIOCRUZ/Diretoria: avaliação de armadilhas para a vigilância entomológica de *Aedes aegypti* com vistas à elaboração de novos índices de infestação. Rio de Janeiro: Fiocruz, 2014. Disponível em: https://fiocruz.br/ioc/media/nota_tecnica_ioc_3.pdf. Acesso em: 7 abr. 2025.

GABURRO, J.; DUCHEMIN, J-B; PARADKAR, P.N.; NAHAVANDI, S.; BHATTI, A. Assessment of ICount software, a precise and fast egg counting tool for the mosquito vector *Aedes aegypti*. **Parasites & Vectors**, v. 9, p. 590, 2016. <https://doi.org/10.1186/s13071-016-1870-1>

HAY, S. I.; GEORGE, D. B.; MOYES, C. L.; BROWNSTEIN, J. S. Big Data Opportunities for Global Infectious Disease Surveillance. **PLoS Medicine**, v. 10, n. 4, e1001413, 2013. <https://doi.org/10.1371/journal.pmed.1001413>

HONÓRIO, N.A.; NOGUEIRA, R.M.R.; CODEÇO, C.T.; CARVALHO, M.S.; CRUZ, O.G.; MAGALHÃES M.A.F.M.; ARAÚJO, J.M.G.; ARAÚJO, E.S.M.; GOMES, M.Q.; PINHEIRO, L.S.; PINEL, C.S.; LOURENÇO-DE-OLIVEIRA, R. Spatial Evaluation and Modeling of Dengue Seroprevalence and Vector Density in Rio de Janeiro, Brazil. **PLoS Neglected Tropical Diseases**, v. 3, n. 11, p. e545, 2009. <https://doi.org/10.1371/journal.pntd.0000545>

JAVED, N.; LÓPEZ-DENMAN, A. J.; PARADKAR, P. N.; BHATTI, A. EggCountAI: a convolutional neural network-based software for counting of *Aedes aegypti* mosquito eggs. **Parasites & Vectors**, v. 16, n. 341, 2023. <https://doi.org/10.1186/s13071-023-05956-1>

KHANAM, R.; HUSSAIN, M. **YOLOv11: An Overview of the Key Architectural Enhancements**. 2024. Disponível em: <https://arxiv.org/abs/2410.17725>. Acesso em: 12 abr. 2025.

KÜHL, N.; SCHEMMER, M.; GOUTIER, M.; SATZGER, G. Artificial intelligence and machine learning. **Electronic Markets**, v. 32, n. 4, p. 2235–2244, 2022. <https://doi.org/10.1007/s12525-022-00598-0>

LAZUARDY, M. F. S.; ANGGRAINI, D. Modern Front End Web Architectures with React.Js and Next.Js. **International Research Journal of Advanced Engineering and Science**, v. 7, n. 1, p. 132–141, 2022. Disponível em: <https://irjaes.com/wp-content/uploads/2022/02/IRJAES-V7N1P162Y22.pdf>. Acesso em: 22 abr. 2025.

LIMA-CAMARA, T. N. de; HONÓRIO, N. A.; LOURENÇO-DE-OLIVEIRA, R. Frequência e distribuição espacial de *Aedes aegypti* e *Aedes albopictus* (Diptera, Culicidae) no Rio de Janeiro, Brasil. **Cadernos de Saúde Pública**, v. 22, n. 10, p. 2079–2084, out. 2006. <https://doi.org/10.1590/S0102-311X2006001000013>

LIU, W.; ANGUELOV, D.; ERHAN, D.; SZEGERY, C.; REED, S.; FU, C. Y.; BERG, A. C. SSD: Single shot multibox detector. In: **Computer Vision – ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part I 14**. Springer International Publishing, 2016. p. 21–37.

LIU, Y. L.; ZHAI, X. Z.; OLUWAFEMI, A. R.; ZHANG, H. Y. Influence of Substrate Color on Oviposition Behavior, Egg Hatchability, and Substance of Egg Origin in the Mosquito *Anopheles sinensis* (Wiedemann) (Diptera: Culicidae). **Neotropical Entomology**, v. 43, p. 483–487, 2014. <https://doi.org/10.1007/s13744-014-0236-7>

- MAIA, J. C. S.; FERREIRA, H. R. P.; SILVA, L. E. S.; SANTANA, J. S.; LEAL, J. F. C.; TEIXEIRA, A. C.; GUEDES, M. I. F.; MARQUES, M. M. M.; PACHECO, A. C. L. M. Mapeamento de mosquitos *Aedes* spp. e detecção do vírus Dengue em zona urbana do município de Picos, Piauí. **Research, Society and Development**, v. 11, n. 1, e56311125157, 2022. <https://doi.org/10.33448/rsd-v11i1.25157>
- MUZUMDAR, P.; BHOSALE, A.; BASYAL, G. P.; KURIAN, G. Navigating the Docker Ecosystem: A Comprehensive Taxonomy and Survey. **Asian Journal of Research in Computer Science**, v. 17, n. 1, p. 42–61, 2024. Disponível em: <https://arxiv.org/abs/2403.17940>. Acesso em: 22 abr. 2025.
- NEILL, D. B. New Directions in Artificial Intelligence for Public Health Surveillance. **IEEE Intelligent Systems**, v. 27, n. 1, p. 56–59, 2012. <https://doi.org/10.1109/mis.2012.18>
- NARANJO-ALCAZAR, J.; GRAU-HARO, J.; ZUCCARELLO, P.; ALMENAR, D.; BALLESTER, J. L.. Automatic counting and classification of mosquito eggs in field traps. **Technical Report, Instituto Tecnológico de Informática**, Valencia, 15 out. 2024.
- OLIVER, N.; LEPRI, B.; STERLY, H.; LAMBIOTTE, R.; DELETAILE, S.; DE NADAI, M.; LETOUZÉ, E.; SALAH, A. A.; BENJAMINS, R.; CATTUTO, C.; COLIZZA, V.; DE CORDES, N.; FRAIBERGER, S. P.; KOEBE, T.; LEHMANN, S.; MURILLO, J.; PENTLAND, A.; PHAM, P. N.; PIVETTA, F.; VINCK, P. Mobile phone data for informing public health actions across the COVID-19 pandemic life cycle. **Science Advances**, v. 6, n. 23, 2020. <https://doi.org/10.1126/sciadv.abc0764>
- REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. **You Only Look Once: Unified, Real-Time Object Detection**. In: IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, 2016. Proceedings [...]. [S.l.: s.n.], 2016. p. 779–788. <https://doi.org/10.1109/CVPR.2016.91>.
- REITER, P.; AMADOR, M.A.; COLON, N. Enhancement of the CDC ovitrap with hay infusions for daily monitoring of *Aedes aegypti* populations. **Journal of the American Mosquito Control Association**, v. 7, n. 1, p. 52-55, 1991.
- REN, S.; HE, K.; GIRSHICK, R.; SUN, J. Faster R-CNN: Towards real-time object detection with region proposal networks. **Advances in Neural Information Processing Systems**, v. 28, 2015.
- SANTOS, J. P. C. D.; HONÓRIO, N. A.; NOBRE, A. A. Definition of persistent areas with increased dengue risk by detecting clusters in populations with differing mobility and immunity in Rio de Janeiro, Brazil. **Cadernos de Saúde Pública**, v. 35, n. 12, p. e00248118, 2019. <https://doi.org/10.1590/0102-311X00248118>
- SANTOS, J. P. C.; HONÓRIO, N. A.; BARCELLOS, C.; NOBRE, A. A. A perspective on inhabited urban space: land use and occupation, heat islands, and precarious urbanization as determinants of territorial receptivity to dengue in the city of Rio de Janeiro. **Int J Environ Res Public Health** v.17 n. 18, p. 6537, 2020. <https://doi.org/10.3390/ijerph17186537>
- SHEIKH, H.; PRINS, C.; SCHRIJVERS, E. **Mission AI: The New System Technology**. Springer Nature, 2023.
- SILVA, L. M. de S.; LOPES, L. S.; BARROS, V.; ARAUJO, F. H. D. Segmentação e contagem automática de ovos do *Aedes aegypti* em palhetas de ovitrapa baseada em aprendizado profundo. **Revista de Sistemas e Computação**, v. 12, n. 1, p. 60–69, jan./abr. 2022. DOI: 10.36558/rsc.v12i1.7595. Disponível em: <https://revistas.unifacs.br/index.php/rsc>. Acesso em: 28 abr. 2025.
- SOUZA, R. L.; NAZARE, R. J.; ARGIBAY, H. D.; PELLIZZARO, M.; ANJOS, R. O.; PORTILHO, M. M.; JACOB-NASCIMENTO, L. C.; REIS, M. G.; KITRON, U. D.; RIBEIRO, G. S. Density of *Aedes aegypti* (Diptera: Culicidae) in a low-income Brazilian urban community where dengue, Zika, and chikungunya

viruses co-circulate. **Parasites & Vectors**, v. 16, n. 1, art. 159, 2023. <https://doi.org/10.1186/s13071-023-05766-5>

VAN RIJSBERGEN, C. J. Information Retrieval. 2. ed. London: Butterworths, 1979.

VICENTE, M. N. de O.; HIGA, G. T. H.; PORTO, J. V. de A.; NUCCI, H. H. P.; SANTANA, A. B.; PORTO, K. R. de A.; ROEL, A. R.; PISTORI, H. *Aedes aegypti* Egg Counting with Neural Networks for Object Detection. **Revista de Informática Teórica e Aplicada**, v. 32, n. 1, p. 287–293, fev. 2025. <https://doi.org/10.22456/2175-2745.143494>

VICENTE, M. N. de O. *et al.* *Aedes aegypti* egg counting with neural networks for object detection. **Revista de Informática Teórica e Aplicada**, v. 32, n. 1, p. 287–293, 2025. <https://doi.org/10.22456/2175-2745.143494>

VIRTANEN, P. *et al.* SciPy 1.0: fundamental algorithms for scientific computing in Python. **Nature Methods**, v. 17, n. 3, p. 261–272, 2020. <https://doi.org/10.1038/s41592-019-0686-2>

WALLAU, G. L. *et al.* Arbovirus researchers unite: expanding genomic surveillance for an urgent global need. **The Lancet Global Health** v. 11, n. 10, p. e1501-e1502, 2023. DOI: [https://doi.org/10.1016/S2214-109X\(23\)00325-X](https://doi.org/10.1016/S2214-109X(23)00325-X)

WANG, M. *et al.* Enhancing vector control: AI-based identification and counting of *Aedes albopictus* (Diptera: Culicidae) mosquito eggs. **Parasites & Vectors**, v. 17, art. 511, 2024. <https://doi.org/10.1186/s13071-024-06587-w>

XU, Y.; GOODACRE, R. On splitting training and validation set: a comparative study of cross-validation, bootstrap and systematic sampling for estimating the generalization performance of supervised learning. **Journal of Analytical Testing**, v. 2, n. 3, p. 249–262, 2018. <https://doi.org/10.1007/s41664-018-0068-2>

XU, Z.; LOU, W.; LU, W.; WEI, W. Cell State Recognition of Cytopathic Effect with YOLO Detector. **Journal of Physics Conference Series**, v. 2456, n. 1, p. 012029, 2023. <https://doi.org/10.1088/1742-6596/2456/1/012029>

ZEMOURI, R.; ZERHOUNI, N.; RACOCEANU, D. Deep Learning in the Biomedical Applications: Recent and Future Status. **Applied Sciences**, v. 9, n. 8, 1526, 2019. <https://doi.org/10.3390/app9081526>