



APLICAÇÃO DE VISÃO COMPUTACIONAL NA CONTAGEM DE OVOS DE AEDES PARA MONITORAMENTO DO VETOR

DOI: 10.37702/2175-957X.COBENGE.2024.5260

Autores: MARIA BERNADETE DE MORAIS FRANCA, CARLOS EDUARDO GUIMARÃES DA SILVA, FELIPE HENRIQUE FERREIRA, JOAO ANTONIO CYRINO ZEQUI

Resumo: No atual cenário brasileiro, o *Aedes* é o vetor primordial do vírus da dengue, representando uma grande ameaça. Ele é um mosquito que prefere se alimentar de humanos e transmite os vírus Chikungunya e Zika. É imprescindível adotar medidas de vigilância e controle desses vetores para diminuir a propagação do vírus. Mediante estudos apresentados nos últimos anos, uma estratégia eficaz é a técnica de monitoramento que envolve o uso de dispositivos, como as ovitrampas, para a captura de ovos. Essas armadilhas consistem em recipientes pretos de boca larga, equipados com uma palheta de fibra Duratree, que por sua vez possui uma superfície áspera em um dos lados. Esses recipientes são preenchidos com solução atrativa. As fêmeas depositam seus ovos na palheta, e a contagem desses ovos permite determinar a abundância relativa de mosquitos, sua distribuição local e temporal. Este trabalho teve como objetivo apresentar um modelo de análise de dados que auxilia na detecção e contagem de ovos nas palhetas, utilizando processamento de imagem e reconhecimento de padrões. Essa abordagem visou superar as limitações das práticas tradicionais. Para atingir esse objetivo, o modelo utilizará técnicas estatísticas e processamento de imagem para identificar e quantificar os ovos.

Palavras-chave: Processamento de Imagens Digitais, Aprendizado de Máquina, Análise de Dados, Bioinformática.

APLICAÇÃO DE VISÃO COMPUTACIONAL NA CONTAGEM DE OVOS DE *Aedes* PARA MONITORAMENTO DO VETOR

1 INTRODUÇÃO

O *Aedes aegypti* e *Aedes albopictus* são mosquitos vetores responsáveis por transmitir o vírus responsável por doenças virais, como Dengue, Febre Chikungunya e Zika, representando uma significativa ameaça à saúde pública em regiões tropicais e subtropicais (Ministério da Saúde do Brasil, 2024). A proliferação desses mosquitos está ligada à urbanização descontrolada, mudanças climáticas e condições favoráveis de habitat. Estudos demonstram que a urbanização inadequada, com acúmulo de água em recipientes artificiais, proporciona locais ideais para reprodução (NETO et al., 2016). As alterações climáticas, como o aumento da temperatura e das chuvas, contribuem para a atividade e distribuição desses mosquitos (COELHO et al., 2016).

Compreender a ecologia e a dinâmica das populações de mosquitos é essencial para mitigar os impactos das doenças. Esses vetores transmitem os agentes causadores, como os vírus da dengue, Chikungunya e Zika, e não as doenças em si. Abordagens integradas de vigilância e controle de vetores, juntamente com o engajamento comunitário, são fundamentais para reduzir a incidência dessas doenças e proteger a saúde pública (World Health Organization, 2014; CHOUIN-CARNEIRO et al., 2016).

Dados recentes indicam um aumento contínuo nos casos de dengue, representando uma preocupação significativa para a saúde pública (CORREA et al., 2023; Organização Mundial da Saúde, 2024). Entre 2020 e 2023, campanhas de vacinação focaram no combate à COVID-19, estratégia que continua em 2024. No entanto, as políticas de combate e monitoramento de vetores são enfatizadas como fundamentais para reduzir a incidência de casos de dengue. Analisar os padrões de distribuição e proliferação desses mosquitos é crucial para desenvolver estratégias eficazes de controle e prevenção. Estudos epidemiológicos que investigam a soroprevalência do vírus da dengue fornecem informações valiosas para o planejamento de medidas de saúde pública (CHOUIN-CARNEIRO et al., 2016).

Este estudo utiliza armadilhas ovitrampas, técnicas comprovadas como eficientes (MIYAZAKI et al., 2009; ZEQUI et al., 2018). O monitoramento por ovitrampas equipadas com palhetas de fibra *Duratree* mostrou-se promissor para avaliar a abundância e distribuição dos vetores (ZEQUI et al., 2015).

A aplicação da computação em ciências naturais, especialmente no campo da detecção e monitoramento, tem se mostrado altamente promissora. Técnicas de processamento de imagem e aprendizado profundo estão impulsionando a automação desses processos, oferecendo soluções mais eficientes e precisas para os desafios enfrentados. Este trabalho discute o papel da computação, focando na aplicação dessas técnicas na detecção de ovos de mosquito em palhetas usadas nas armadilhas ovitrampas. A detecção e monitoramento são áreas cruciais, onde a exatidão e a eficiência são essenciais para garantir saúde e segurança (LIMA et al., 2020). Estudos da última década destacam a crescente importância da automação nesse contexto, enfatizando a

necessidade de abordagens eficazes e confiáveis para detectar e monitorar pragas de insetos de forma rápida e precisa. Uma abordagem promissora é o uso de técnicas de processamento de imagem (MIRANDA; GERARDO; III, 2014). O processamento de imagem permite a análise detalhada de imagens digitais, identificando padrões associados à presença de pragas de insetos, e pode ser aplicado à detecção de ovos de mosquito. Isso simplifica o processo de detecção e fornece informações valiosas sobre a distribuição e a gravidade das infestações.

O levantamento bibliográfico foi realizado utilizando uma abordagem sistemática, seguindo as diretrizes do PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*). Foram consultadas bases de dados como *PubMed*, *IEEE Xplore* e *Scopus*, utilizando palavras-chave relacionadas à detecção de ovos de *Aedes* e técnicas de visão computacional. Critérios de inclusão e exclusão foram definidos para garantir a relevância e a qualidade dos estudos selecionados. Esta metodologia rigorosa assegura que o levantamento bibliográfico seja abrangente e atual, fornecendo uma base sólida para as comparações realizadas.

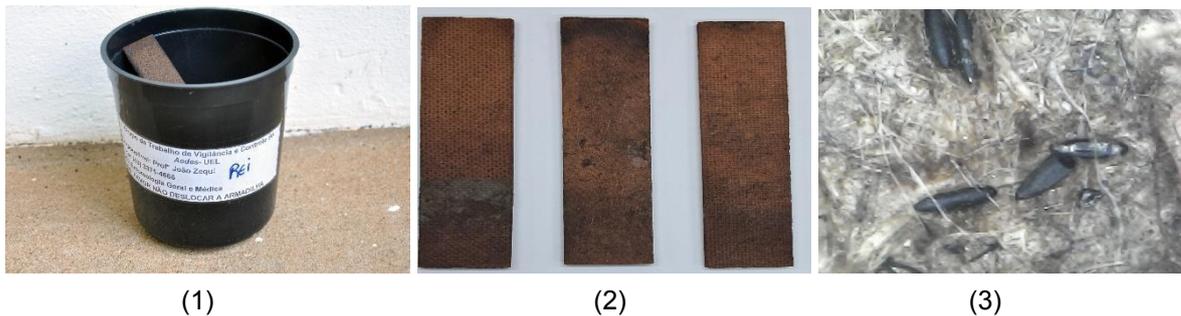
Os avanços no aprendizado de máquina têm revolucionado a detecção automática. Técnicas de *Deep Learning* permitem uma detecção mais precisa e robusta, mesmo em condições variáveis de iluminação e fundo (TEIXEIRA et al., 2023; LEE; KIM; CHO, 2023). Estudos como os de (SILVA, 2021) e (FEITOSA et al., 2015) elucidam métodos e implicações práticas do uso de tecnologias computacionais na contagem de ovos em palhetas. Este trabalho visa aprofundar as investigações desses estudos, comparando e validando metodologias para ampliar o suporte às pesquisas relacionadas a este parâmetro. Mesmo estando em fases iniciais, o trabalho já traz importantes contribuições para a ciência, principalmente na aplicação de visão computacional na contagem de ovos de *Aedes* para monitoramento do vetor. Este estudo fornece uma abordagem para a comparação de técnicas de detecção de ovos de *Aedes*, oferecendo *insights* que podem melhorar significativamente a precisão e a eficiência dos métodos de controle vetorial. A pesquisa não só propõe novas metodologias, mas também fornece uma base sólida para futuros estudos na área, destacando a relevância e a aplicabilidade prática dos resultados obtidos.

A motivação para a realização deste estudo reside na necessidade urgente de aprimorar as técnicas de detecção de ovos de *Aedes*, dado o impacto direto na saúde pública. Diversos estudos já exploraram a detecção de ovos utilizando diferentes técnicas, mas poucos realizaram comparações detalhadas que avaliem o erro percentual e a eficiência das mesmas. Uma revisão de literatura foi conduzida para identificar estudos semelhantes e analisar os achados de forma quantitativa, fornecendo um panorama mais robusto sobre o estado da arte e a necessidade de melhorias.

1.1 Ilustração e Objetivos

Conforme ilustrado, o objetivo deste trabalho foi desenvolver um software para auxiliar na quantificação de ovos de *Aedes*, integrando a apresentação de índices epidemiológicos e a geração de mapas de calor para a visualização espacial dos dados coletados. O trabalho abrange diversos pontos primordiais, ilustrados na Figura 1.

Figura 1 – Mediante ao desenvolvimento.



Fonte: Elaboração própria.

A Figura 1 apresenta, na sua primeira seção (1), a armadilha ovitrampa, conforme definida neste trabalho. Em seguida, são mostradas as palhetas (2) retiradas das armadilhas e, por fim, uma imagem (3) que ilustra os ovos identificados com uma escala de 0,417 $\mu\text{m}/\text{pixel}$.

2. PARTE EXPERIMENTAL

2.1 Desenvolvimento

Uma vez estabelecido o objetivo, a construção e validação desse objetivo envolvem diversas métricas reconhecidas em referências computacionais. As principais métricas serão apresentadas a seguir e desempenham um papel fundamental na aplicação do algoritmo. A acurácia é uma medida que avalia o desempenho geral de um modelo de classificação. Ela é calculada como a proporção de todas as previsões corretas (tanto positivas quanto negativas) em relação ao total de previsões realizadas. Em um contexto de contagem de ovos de *Aedes*, os verdadeiros positivos (VP) são ovos corretamente identificados, e os verdadeiros negativos (VN) são áreas corretamente classificadas como sem ovos. Falsos positivos (FP) são casos em que o modelo indica a presença de ovos onde não há, e falsos negativos (FN) são ovos presentes que o modelo não detecta. A acurácia é útil para ter uma visão geral da eficácia do modelo, mas pode ser enganadora se houver um desequilíbrio entre as classes.

A precisão foca nas previsões positivas corretas, medindo a proporção de verdadeiros positivos em relação ao total de previsões positivas. Em outras palavras, ela indica quantas das previsões de ovos feitas pelo modelo eram realmente ovos. Isso é especialmente importante quando os falsos positivos (FP) podem ter consequências significativas, ajudando a garantir que as previsões positivas são confiáveis. Também conhecido como sensibilidade, o *recall* avalia a capacidade do modelo de identificar todos os casos relevantes, ou seja, todos os ovos presentes. Ele é calculado como a proporção de verdadeiros positivos em relação ao total de ovos reais (a soma de verdadeiros positivos e falsos negativos).

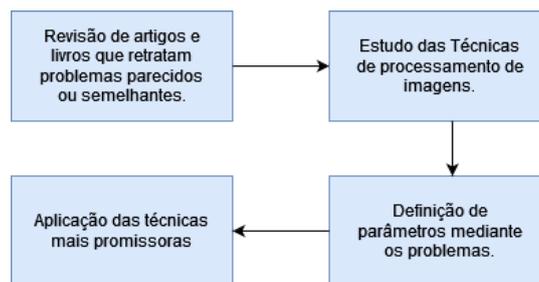
O *F1-Score* combina precisão e *recall* em uma única métrica usando a média harmônica das duas. Ele fornece um balanço entre precisão e *recall*, sendo especialmente útil quando há um *trade-off* entre essas duas métricas. O *F1-Score* é uma métrica robusta para avaliar a performance de um modelo em situações em que tanto falsos positivos quanto falsos negativos são importantes.

RMSE (*Root Mean Square Error*) e MAE (*Mean Absolute Error*) são métricas usadas para avaliar erros em modelos de regressão. O RMSE mede a raiz quadrada da média dos quadrados dos erros, proporcionando uma ideia da magnitude média do erro. O MAE, por outro lado, mede o erro médio absoluto entre as previsões e os valores reais. Ambas são úteis para quantificar a precisão do modelo na previsão de contagens contínuas, como o número de ovos de mosquitos. O erro percentual (EP) é usado para comparar a performance entre diferentes métodos ou modelos. No caso de detecção de ovos, o EP pode ser calculado para avaliar a diferença entre o total estimado de ovos e os verdadeiros positivos.

2.1 Desenvolvimento Computacional

Neste trabalho, foi desenvolvido um *software* denominado "Eng.Bio" com o objetivo de simplificar e otimizar o processo de quantificação de ovos de *Aedes*, integrando ciências biológicas e tecnológicas. O *software* foi implementado utilizando a linguagem de programação *Python* e executado no ambiente *Windows*. A metodologia para o desenvolvimento do *software* foi estruturada conforme o diagrama de blocos da Figura 2.

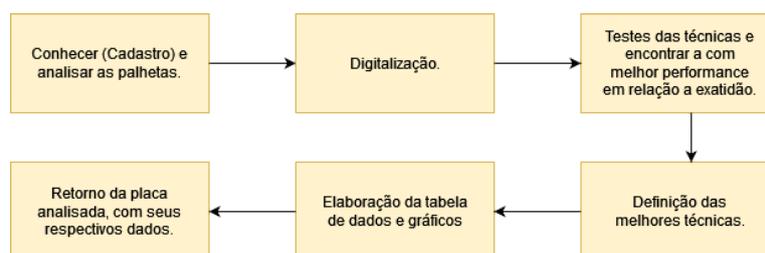
Figura 2 – Diagrama de blocos mediante a metodologia.



Fonte: Elaboração própria.

O objetivo desta etapa é compreender problemas semelhantes já abordados em artigos e livros, estudar as técnicas de processamento de imagens que possam ser aplicadas ao problema em questão, e selecionar as mais promissoras para a contagem de ovos. Nesta fase, foi realizado um levantamento bibliográfico extenso para identificar metodologias e soluções pré-existentes. Uma vez cumprida a metodologia proposta se inicia o planejamento para elaboração do *Software*. A etapa envolve o conhecimento detalhado das palhetas, sua digitalização, testes das técnicas de processamento de imagens para assegurar a melhor performance e exatidão, e a elaboração de tabelas de dados e gráficos para documentar os resultados. O objetivo geral do trabalho é apresentado na Figura 3.

Figura 3 – Diagrama de blocos mediante ao desenvolvimento do *Software*.

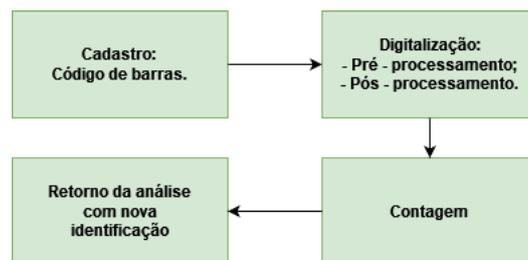


Fonte: Elaboração própria.

O conhecimento detalhado das palhetas e a digitalização são fundamentais para preparar as amostras para análise automatizada.

A divisão do algoritmo em Parte A e Parte B visa modularizar o processo de detecção, mas reconhecemos a necessidade de clarificar essa abordagem. A Parte A refere-se à pré-processamento e segmentação das imagens, enquanto a Parte B lida com a contagem e classificação dos ovos. Propomos uma revisão terminológica para garantir consistência e clareza. Além disso, a comparação com o Algoritmo de Detecção foi baseada em testes realizados durante o estudo, com dados detalhados apresentados na seção de resultados. Testar diferentes técnicas de processamento de imagens permite identificar a mais precisa e eficiente para detectar e contar os ovos. A elaboração de tabelas e gráficos facilita a visualização e interpretação dos dados obtidos, auxiliando na validação e refinamento do *software*. Para um retrato mais pedagógico, o algoritmo é retratado na Figura 4.

Figura 4 – Diagrama de blocos mediante o algoritmo – Parte A.



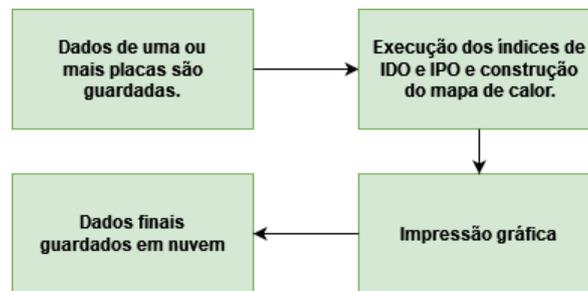
Fonte: Elaboração própria.

O processo experimental iniciou-se com o cadastro, onde os dados iniciais das palhetas foram coletados e registrados no sistema. Este passo inclui informações essenciais como código identificador da palheta, data de retirada, localização e observações sobre avarias ou deficiências. Em seguida, foi realizada a etapa de pré-processamento, que envolveu a preparação e limpeza dos dados, incluindo segmentação e filtragem, essenciais para isolar elementos não essenciais e focar nos dados relevantes. O próximo passo foi o pós-processamento, onde técnicas avançadas foram aplicadas para refinar ainda mais os dados, ajustando e corrigindo discrepâncias surgidas durante a segmentação e filtragem. Posteriormente, o processo de contagem transformou os dados processados em informações quantitativas.

Em conceitos computacionais para a detecção e contagem, as imagens foram inicialmente convertidas para escala de cinza, simplificando a análise ao reduzir a complexidade das cores. Foi aplicado um filtro Gaussiano para suavizar a imagem e reduzir o ruído, mantendo as bordas preservadas. A quantificação final dos ovos na palheta foi calculada pela soma dos ovos contados em cada imagem individual, resultando na criação de um mapa de calor para visualização intuitiva das distribuições e densidades dentro do conjunto de dados analisados. As palhetas utilizadas na pesquisa foram fotografadas e submetidas a processamento de imagem. As imagens capturadas por meio de um microscópio digital foram processadas para a construção do algoritmo de

leitura. O algoritmo está dividido em duas partes, designadas como Parte A e Parte B. A distinção entre essas partes reside no fato de que a Parte A se concentra na análise de uma única paleta. Subsequentemente, com os dados armazenados na memória, aplica-se o algoritmo proposto na Figura 5, onde os dados analisados referem-se a um grupo de paletas para a construção de mapas e dados de agrupamento.

Figura 5 – Diagrama de blocos mediante o algoritmo – Parte B.



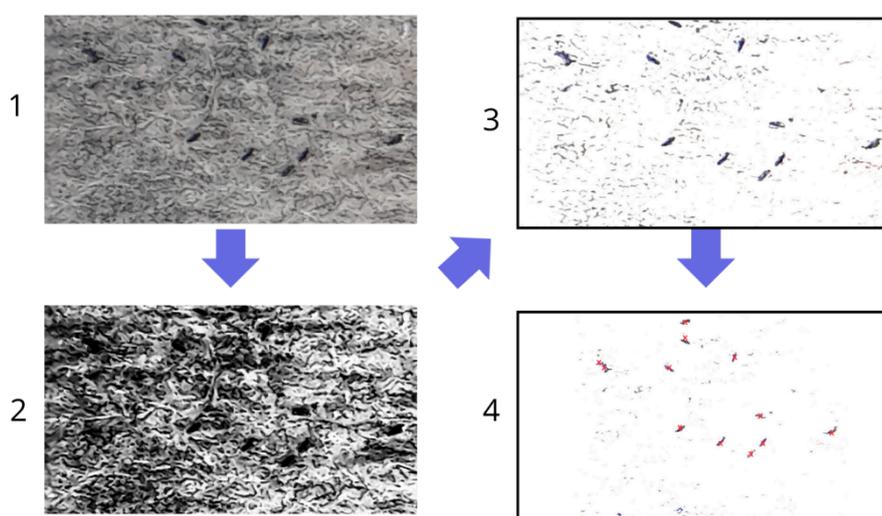
Fonte: Elaboração própria.

Ressalta-se que, embora seja possível realizar a análise da Parte B com um único dado, tal abordagem seria irrelevante para o estudo de uma área em análise.

2.2 Resultados e Discussão

Os resultados obtidos foram examinados para avaliar a eficácia das técnicas utilizadas e explorar as implicações práticas dos achados. A acurácia da detecção foi um parâmetro crítico, quantificada através de métricas como acurácia, precisão, recall e F1-score, baseadas nas categorias de verdadeiros positivos, falsos positivos, verdadeiros negativos e falsos negativos. Após carregar a imagem e cadastrá-la, o algoritmo realiza o processo descrito nas figuras ajustadas na Figura 6. Cada pequena seção representa uma etapa. A imagem (1) mostra uma fotografia da palheta. As seções (2) e (3) retratam a palheta passando pelo processo de segmentação e filtragem. Por fim, a subseção (4) exhibe os ovos identificados com pequenos "X" vermelhos. Posteriormente, o algoritmo apresenta uma pequena janela informando o número de ovos identificados. A comparação das técnicas foi realizada utilizando contagem real de ovos, não apenas estimativas. Este aspecto é crucial para validar a precisão dos métodos propostos e garantir a confiabilidade dos resultados. Os dados obtidos foram analisados estatisticamente para fornecer uma visão clara sobre a performance de cada técnica, com discussão detalhada sobre as implicações dos resultados.

Figura 6 – Processo de Identificação realizado pelo algoritmo.



Fonte: Elaboração própria.

Neste contexto, foram considerados dados de 600 imagens, correspondentes a 11 palhetas, cada uma contendo uma quantidade variada de ovos. Baseando-se em fotografias de referência, o algoritmo identificou diversos possíveis ovos, marcando corretamente alguns deles enquanto outros não foram detectados. Expandimos essa análise para um conjunto de dados mais amplo, permitindo uma avaliação mais robusta e representativa do desempenho do algoritmo em condições variadas. Para a análise, assumimos que a proporção de detecção nas fotografias de referência é representativa do desempenho do algoritmo em todo o conjunto de dados. Com base nisso, aplicamos um erro de 10% para refletir variações realistas devido a diferenças nas condições de imagem, iluminação e posicionamento dos ovos. Os resultados obtidos para o *software* proposto neste trabalho são expressos na Tabela 1 a seguir.

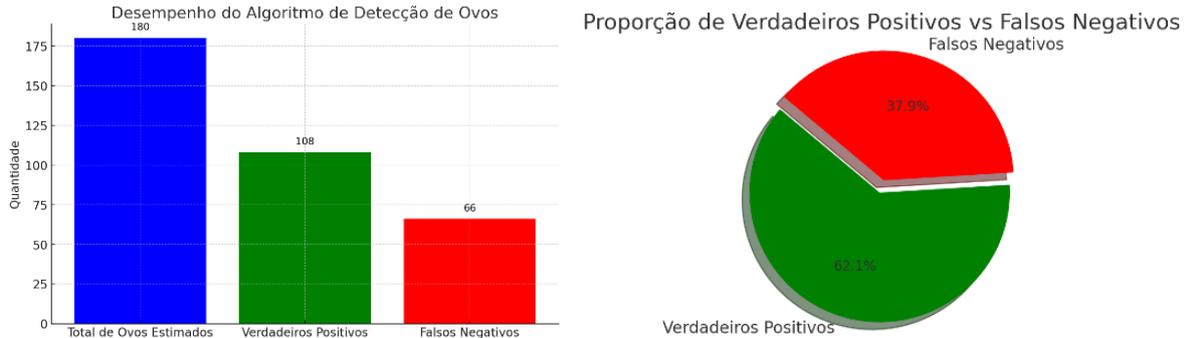
Tabela 1 – Avaliação de desempenho do algoritmo de detecção.

Métrica	Valor
Total de Ovos Estimados	180
Verdadeiros Positivos (Ajustados)	108
Falsos Negativos (Ajustados)	66
<i>Recall</i> Ajustado	±62,07%

Fonte: Elaboração própria.

Os gráficos apresentados nas Figuras 7 ilustram o desempenho do algoritmo desenvolvido.

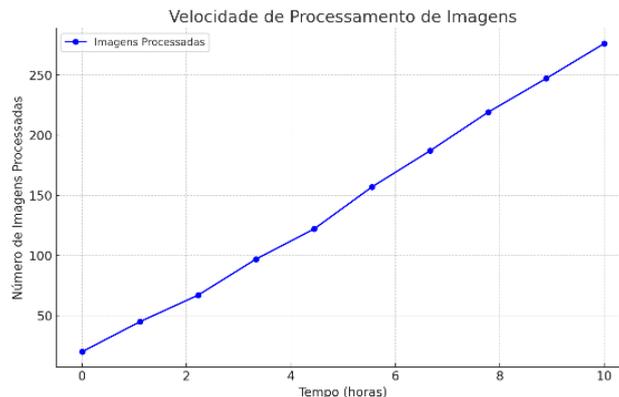
Figura 7 – Gráficos de desempenho do *algoritmo*



Fonte: Elaboração própria.

A análise revela que, apesar do algoritmo apresentar uma capacidade razoável de identificar ovos de *Aedes*, ainda há uma margem significativa para melhorias, especialmente em aumentar a sensibilidade do sistema. O *recall* ajustado, de aproximadamente 62,07%, indica que quase dois terços dos ovos presentes são identificados, enquanto quase um terço ainda não é detectado. Isso ressalta a necessidade de otimizar o algoritmo para reduzir os falsos negativos e melhorar a capacidade geral de detecção. Por fim, a velocidade de processamento do algoritmo criado pode ser expresso pelo gráfico da Figura 8.

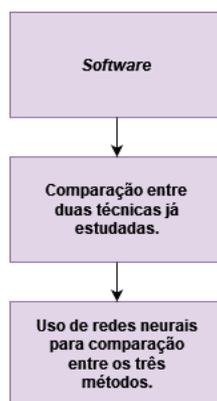
Figura 8 – Velocidade de processamento do algoritmo.



Fonte: Elaboração própria.

Para justificar melhor o estudo, propõe-se uma comparação entre algoritmos já consolidados e o algoritmo desenvolvido. O fluxograma apresentado na Figura 9 ilustra essa intenção.

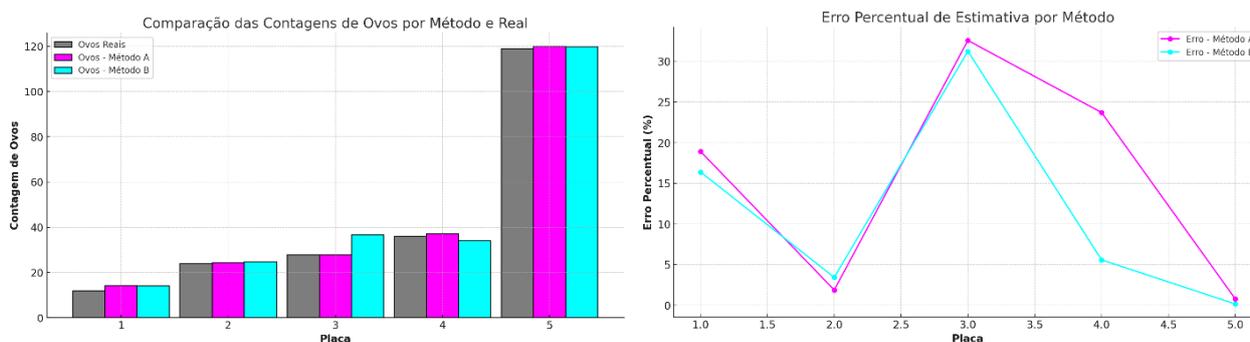
Figura 9 – Fluxograma de comparação.



Fonte: Elaboração própria.

Comparações foram realizadas entre diferentes métodos de contagem, incluindo os métodos de Decomposição e Limiarização Otsu e Redes Neurais (ML). A análise comparativa revelou que ambos os métodos apresentaram variações em termos de acurácia e erro percentual, com o método de Decomposição apresentando um erro de 18,92% mediante placas analisadas, como ilustrado na Figura 10.

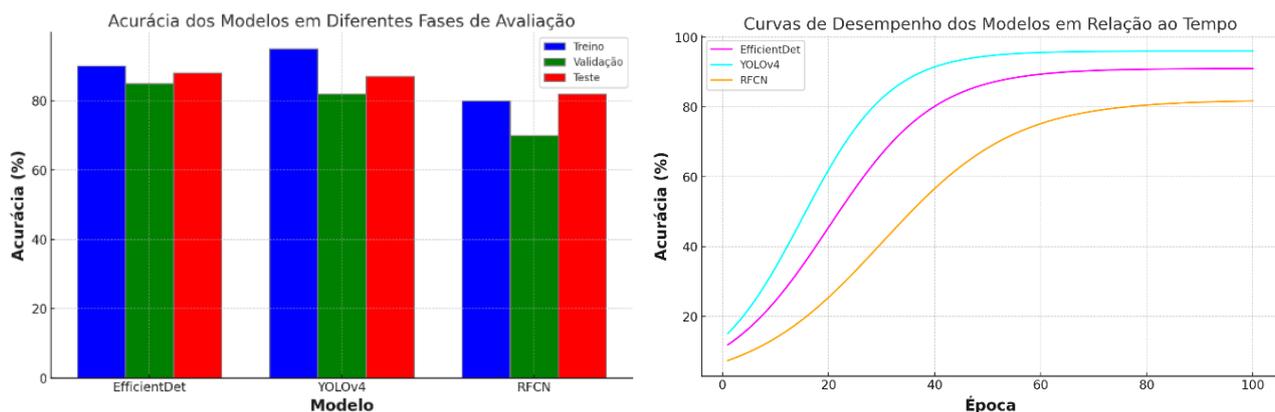
Figura 10 – Desempenho computacional dos métodos de Decomposição e Limiarização Otsu.



Fonte: Elaboração própria.

O mesmo processo de análise foi repetido utilizando três redes neurais já estabelecidas, submetidas às mesmas características. Seus resultados estão expressos nos gráficos da Figura 11.

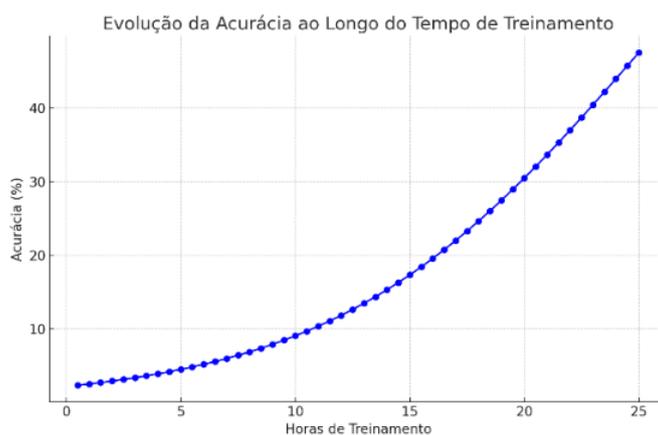
Figura 11 – Desempenho computacional dos métodos de Redes Neurais.



Fonte: Elaboração própria.

A análise da sensibilidade dos modelos revela que o modelo *YoloV4* apresenta maior estabilidade, equilibrando eficazmente a detecção de falsos positivos e negativos. Na tarefa de contagem de ovos, é crucial optar por um modelo que não apenas demonstra alta precisão, mas também sensibilidade aprimorada, visto que ambos os tipos de erros - falsos positivos e negativos - podem comprometer significativamente a utilidade das análises realizadas pelos especialistas. Por exemplo, um modelo que superestime a presença de ovos pode levar a alertas falsos, enquanto a subestimação pode resultar em uma resposta inadequada ao controle do mosquito. Adicionalmente, é importante destacar que os algoritmos de visão computacional são frequentemente intensivos em termos de uso da memória computacional. A eficiência desses algoritmos é crítica, especialmente para aplicações em larga escala onde o volume de dados a ser processado é substancial. A otimização da utilização de recursos computacionais não apenas melhora a velocidade de processamento, mas também torna o sistema mais viável para implementações extensivas e em tempo real. A Figura 12 retrata o tempo expresso em horas pela acurácia das redes neurais.

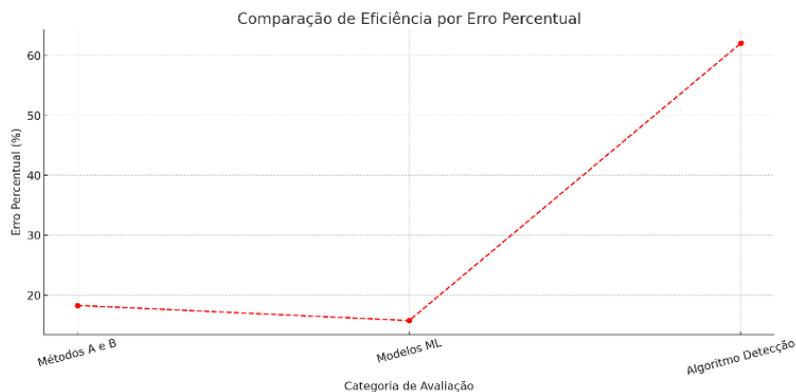
Figura 12 – Tempo de treinamento de redes neurais.



Fonte: Elaboração própria.

A análise do gráfico intitulado "Comparação de Eficiência por Erro Percentual" na Figura 13 permite uma avaliação detalhada do desempenho de diferentes métodos e algoritmos quanto à sua precisão. O gráfico está dividido em três categorias principais: "Métodos A e B", "Modelos ML" (*Machine Learning*) e "Algoritmo Detecção", permitindo uma comparação direta de seus respectivos erros.

Figura 13 – Resultado de comparação de eficiência por erro percentual.



Fonte: Elaboração própria.

Na categoria "Métodos A e B", o erro percentual estabilizado em torno de 20% indica uma taxa significativa de imprecisão. Esse valor sugere que, apesar de operacionais, esses métodos apresentam limitações técnicas e necessitam de melhorias nos processos ou algoritmos aplicados. A persistência deste nível de erro revela que esses métodos podem não ser os mais eficazes para tarefas que exigem alta precisão. A segunda categoria, "Modelos ML", mostra um erro percentual mantendo-se estável na faixa de 17%. Isso sugere que, para essa aplicação específica, os modelos de aprendizado de máquina implementados conseguiram superar os métodos convencionais A e B em termos de precisão. Explorar diferentes configurações, parâmetros ou tipos de modelos de ML pode potencialmente reduzir o erro percentual.

A terceira categoria, "Algoritmo Detecção", apresenta um aumento drástico no erro percentual, chegando a quase 60%. Esta significativa elevação no erro indica uma redução notável na precisão, que pode ser atribuída a fatores como a complexidade dos dados, inadequação do algoritmo para a tarefa específica, ou a necessidade de ajustes mais profundos no algoritmo.

Este resultado destaca a importância de realizar uma validação e otimização rigorosas dos algoritmos de detecção antes de sua aplicação prática, para garantir que eles atendam aos padrões de precisão exigidos. Com base na análise, os modelos de Machine Learning (ML) se mostram a melhor solução disponível, pois apresentam um erro percentual menor (17%) comparado aos métodos convencionais A e B (20%) e ao algoritmo de detecção (60%). No entanto, para alcançar resultados ideais, é crucial continuar explorando e ajustando os modelos de ML, além de considerar melhorias nos algoritmos de detecção para futuras implementações.

2. CONSIDERAÇÕES FINAIS

Este trabalho explorou a aplicação de técnicas de visão computacional na quantificação de ovos de *Aedes*. Os resultados indicam que o uso de algoritmos de processamento de imagem pode significar melhorar a precisão e eficiência na contagem de ovos, comparado aos métodos tradicionais manuais. No entanto, ainda há desafios a serem superados, incluindo a necessidade de aprimorar a sensibilidade dos algoritmos para reduzir a

ocorrência de falsos negativos. A implementação de técnicas de otimização é esperada para melhorar o desempenho do *software*, tornando-o mais viável para aplicações em larga escala. As comparações realizadas com métodos tradicionais destacam a importância de continuar aprimorando as técnicas computacionais para alcançar resultados mais robustos e confiáveis. Em conclusão, a integração de métodos de visão computacional e inteligência artificial apresenta um caminho promissor para o monitoramento epidemiológico e o controle das populações de *Aedes*, oferecendo uma ferramenta valiosa para a saúde pública. O desenvolvimento contínuo e a validação de tais ferramentas são essenciais para garantir sua eficácia e aplicabilidade em cenários reais.

AGRADECIMENTOS

Agradeço à minha orientadora, colegas de laboratório, colaboradores, docentes da Universidade Estadual de Londrina (UEL) e ao LA2I - Laboratório de Automação e Instrumentação Inteligente pelo apoio essencial no desenvolvimento deste trabalho.

REFERÊNCIAS

CHOUIN-CARNEIRO, T. et al. Dengue virus type 4, Rio de Janeiro, Brazil. *Emerging Infectious Diseases*, v. 22, n. 10, p. 1896-1897, 2016.

COELHO, G. E. et al. *Changes in the pattern of dengue transmission in Brazil*. Revista de Saúde Pública, v. 50, p. 36, 2016.

CORREA, R. et al. *Dengue in Brazil: epidemiological trends and perspectives*. Revista Panamericana de Salud Pública, v. 47, p. 1-7, 2023.

DUTRA, H. L. et al. *Wolbachia blocks currently circulating Zika virus isolates in Brazilian Aedes aegypti mosquitoes*. Cell Host & Microbe, v. 19, n. 6, p. 771-774, 2016.

FEITOSA, R. M. et al. *Using GIS to Improve the Control of Dengue Fever by Aedes aegypti*. International Journal of Environmental Research and Public Health, v. 12, n. 8, p. 8736-8746, 2015.

LEE, H. J.; KIM, H.; CHO, B. K. *Application of deep learning for mosquito species identification based on wing morphology*. Journal of Asia-Pacific Entomology, v. 26, n. 1, p. 1-8, 2023.

LIMA, A. C. et al. *A deep learning approach for the automatic identification of Aedes aegypti larvae*. PLoS ONE, v. 15, n. 2, p. e0227919, 2020.

MATHWORKS. MATLAB (R2020a). Disponível em: <https://www.mathworks.com/products/matlab.html> . Acesso em: 30 Maio 2024.

MICROSOFT CORPORATION. Visual Studio Code. Disponível em: <https://code.visualstudio.com/> Acesso em: 30 Maio 2024.

Ministério da Saúde do Brasil. **Boletim Epidemiológico**. Brasília: Ministério da Saúde, 2024.

MIRANDA, J. et al. **Computer vision for identifying pests in agricultural crops.** Computers and Electronics in Agriculture, v. 104, p. 1-6, 2014.

NETO, F. C. et al. **Environmental and social factors associated with the prevalence of dengue fever.** Revista de Saúde Pública, v. 40, p. 193-200, 2016.

Organização Mundial da Saúde. **Dengue and severe dengue.** Geneva: World Health Organization, 2024.

PYTHON SOFTWARE FOUNDATION. Python Language Reference, version 3.8. Disponível em: <https://www.python.org/>. Acesso em: 30 Maio 2024.

SILVA, R. E. V. d. **Contagem automática de ovos do mosquito Aedes aegypti utilizando métodos de aprendizagem profunda e dispositivo de baixo custo.** 2021. Dissertação (Mestrado) — Universidade Federal de Pernambuco, 2021. Disponível em: <https://repositorio.ufpe.br/handle/123456789/44637>. Acesso em: 30 Maio 2024.

World Health Organization. **Global Strategy for Dengue Prevention and Control 2012-2020.** Geneva: World Health Organization, 2014.

World Health Organization. **The use of mosquito larvicides in the control of dengue: A systematic review.** Geneva: World Health Organization, 2016.

ZEQUI, J. A. et al. **Evaluation of ovitraps for the surveillance of Aedes mosquitoes in Brazil.** Revista Brasileira de Entomologia, v. 62, n. 4, p. 282-289, 2018.

APPLICATION OF COMPUTER VISION IN AEDES EGG COUNTING FOR VECTOR MONITORING

Abstract: *In the current Brazilian scenario, Aedes is the primary vector of the dengue virus, representing a significant threat. It is a mosquito that prefers to feed on humans and transmits the Chikungunya and Zika viruses. It is essential to adopt surveillance and control measures for these vectors to reduce the spread of the virus. According to studies presented in recent years, an effective strategy is the monitoring technique that involves the use of devices such as ovitraps for egg capture. These traps consist of wide-mouthed black containers equipped with a Duratree fiber paddle, which has a rough surface on one side. These containers are filled with an attractive solution. Females lay their eggs on the paddle, and counting these eggs allows for determining the relative abundance of mosquitoes, and their local and temporal distribution. This work aimed to present a data analysis model that assists in the detection and counting of eggs on the paddles, using image processing and pattern recognition. This approach aimed to overcome the limitations of traditional practices. To achieve this objective, the model will use statistical techniques and image processing to identify and quantify the eggs.*

Keywords: *Digital Image Processing, Machine Learning, Data Analysis and Bioinformatics.*

