

Sistema de Apoio à Decisão para Classificação de Imagens de *Aedes aegypti*

Caio Rabottini Marchiori^{1,a}, Fábio Luiz Usberti^{2,b}, Pedro Gaspareto Lugão^{3,c}, Luís Tarrataca^{4,a}, Eduardo Ogasawara^{5,a}, Laura Silva de Assis^{6,a}

^aCentro Federal de Educação Tecnológica do Rio de Janeiro (CEFET/RJ), Av. Maracanã, 229, Maracanã, Rio de Janeiro, 20271-110, Rio de Janeiro, Brasil

^bInstituto de Computação, Universidade Estadual de Campinas (UNICAMP), Av. Albert Einstein, 1251, Cidade Universitária, Campinas, 13083-852, São Paulo, Brasil

^c Departamento de Ciência da Computação, Universidade Federal de Juiz de Fora (UFJF), Rua José Lourenço Kelmer, s/n, no Campus Universitário, Bairro São Pedro, Juiz de Fora - MG

¹caiorabottinimarchiori@gmail.com, ²fusberti@ic.unicamp.br,

³pedro.lugao@ufjf.br, ⁴luis.tarrataca@cefet-rj.br,

⁵eduardo.ogasawara@cefet-rj.br, ⁶laura.assis@cefet-rj.br

RESUMO

A dengue é uma das principais arboviroses no Brasil, demandando estratégias contínuas de vigilância do vetor *Aedes aegypti*. A identificação de mosquitos, tradicionalmente realizada por especialistas com base em características morfológicas, pode ser demorada e pouco escalável diante do grande volume de imagens oriundas de armadilhas, laboratórios e ações de campo. Este trabalho propõe um sistema de apoio à decisão para vigilância entomológica, voltado à triagem automatizada e identificação de *Aedes aegypti*. O sistema integra um classificador baseado em redes neurais convolucionais, utilizando a arquitetura MobileNetV2 com aprendizado por transferência, a uma aplicação Web para submissão de imagens e visualização dos resultados. A avaliação foi realizada com bases públicas, em cenários binários e multiclasse. Os resultados indicaram desempenho promissor, com acurácia próxima de 93% no cenário multiclasse e bom equilíbrio entre precisão e sensibilidade. O sistema mostrou-se viável como ferramenta auxiliar à triagem, sem substituir a validação especializada.

PALAVRAS CHAVE. Sistema de apoio à decisão; Vigilância entomológica; Aprendizado profundo.

Tópicos: SA – PO na Área de Saúde, PO&IA – Pesquisa Operacional com Inteligência Artificial.

ABSTRACT

Dengue is one of the main arboviral diseases in Brazil, requiring continuous vector surveillance strategies and control of the *Aedes aegypti*. Mosquito identification, traditionally performed by specialists based on morphological characteristics, can be a time-consuming and poorly scalable step given the growing volume of images from traps, laboratories, and field activities. This work proposes a decision-support system for entomological surveillance, focused on the automated screening and identification of *Aedes aegypti*. The system integrates a convolutional neural network classifier, based on the MobileNetV2 architecture with transfer learning, into a web application that enables image submission and visualization of classification probabilities. The evaluation was conducted using public mosquito image datasets in both binary and multiclass scenarios. Results indicate promising performance, achieving approximately 93% accuracy in the multiclass setting, along with a good balance between precision and recall. The system proved to be a viable tool to support image screening without replacing expert validation.

KEYWORDS. Decision support system; Entomological surveillance; Deep learning.

Paper topics: SA – PO in the Healthcare Area, PO&IA – Operational Research with Artificial Intelligence.

1. Introdução

As arboviroses, como dengue, zika, chikungunya e febre amarela, constituem importantes problemas de saúde pública, sobretudo em regiões tropicais e subtropicais, onde fatores climáticos, urbanos e sanitários favorecem a proliferação de vetores [Wilder-Smith et al., 2017]. Entre elas, a dengue destaca-se por sua elevada incidência e recorrência epidêmica. Na América Latina e no Caribe, a doença apresenta alguns dos maiores índices mundiais, com surtos cíclicos recorrentes. No Brasil, esse cenário foi agravado em 2024, quando o país enfrentou o maior surto já registrado, com cerca de seis milhões de casos confirmados e aproximadamente seis mil óbitos [Pan American Health Organization (PAHO), 2024]. Na Figura 1, observa-se o crescimento expressivo de casos de dengue nas Américas entre 2023 e 2024, com aumento mais acentuado e pico mais precoce em 2024.




Figura 1: Distribuição dos casos regionais de dengue por semana epidemiológica nas Américas, 2023–2024 [Pan American Health Organization, 2026].

O principal vetor da dengue é o mosquito *Aedes aegypti*, também associado à transmissão de zika, chikungunya e febre amarela. Sua elevada adaptação ao ambiente urbano e sua capacidade de reprodução em pequenos acúmulos de água tornam o controle vetorial uma das principais estratégias para mitigar o impacto dessas doenças [Ministério da Saúde, 2025]. Assim, a vigilância entomológica exerce papel central, pois permite monitorar a presença e a distribuição de vetores, subsidiando a definição de prioridades e o planejamento de ações de prevenção e controle. Uma etapa particularmente relevante desse processo é a triagem de imagens de mosquitos provenientes de armadilhas, laboratórios, ações de campo e iniciativas de ciência cidadã [Adhane et al., 2021].

A identificação de mosquitos, tradicionalmente realizada por especialistas a partir de características morfológicas, é uma etapa importante desse processo. Entretanto, trata-se de uma atividade demorada, dependente de conhecimento especializado e pouco escalável diante do volume crescente de imagens e amostras disponíveis [Nolte et al., 2024]. Para enfrentar esse gargalo, abordagens baseadas em visão computacional e aprendizado profundo têm sido exploradas para automatizar tarefas de detecção e classificação de mosquitos [Park et al., 2020]. Nesse contexto, o problema tratado neste trabalho consiste em investigar em que medida a classificação dessas imagens pode apoiar a triagem inicial, a priorização de amostras com maior probabilidade de conter vetores de interesse e o encaminhamento para validação especializada, reduzindo o esforço manual em etapas preliminares da vigilância.

Este trabalho propõe um sistema de apoio à decisão para vigilância entomológica, voltado à triagem automatizada de imagens de mosquitos e à identificação da espécie *Aedes aegypti*. A solução combina um módulo de classificação baseado em redes neurais convolucionais com uma aplicação Web para submissão de imagens, seleção entre os modelos disponíveis e visualização da probabilidade associada à classificação. A saída do classificador é tratada como informação de

apoio à decisão, e não como substituta da validação especializada. O módulo preditivo utiliza a arquitetura MobileNetV2 com aprendizado por transferência, escolhida por sua eficiência computacional e adequação a aplicações com restrições de implantação. A avaliação foi conduzida com dois conjuntos públicos de imagens, o *Aedes Mosquitos Dataset* [Isawasan e Quan, 2020] e o *Dataset of Vector Mosquito Images (Mendeley)* [Pise et al., 2022], considerando configurações com e sem aumento de dados e métricas como acurácia, precisão, sensibilidade e *F1-score*. O classificador foi ainda integrado a uma API em Python e disponibilizado por meio de uma aplicação Web.

As principais contribuições deste trabalho consistem na proposição de um sistema de apoio à decisão para a triagem de imagens de mosquitos em ações de vigilância entomológica, (i) incorporando um módulo de classificação baseado em MobileNetV2 com aprendizado por transferência para identificação de *Aedes aegypti*, (ii) avaliando esse módulo em bases públicas de imagens sob cenários binários e multiclasse, e (iii) integrando o classificador a uma aplicação Web com submissão de imagens, seleção de modelo e visualização das probabilidades de classificação.

O restante do trabalho está organizado da seguinte forma. A Seção 2 apresenta os trabalhos relacionados. A Seção 3 descreve o sistema de apoio à decisão proposto. A Seção 4 apresenta a avaliação computacional do classificador e a verificação funcional do sistema. Por fim, a Seção 5 reúne as considerações finais e indica possibilidades de trabalhos futuros.

2. Trabalhos Relacionados

A identificação automatizada de mosquitos vetores tem sido investigada por meio de diferentes abordagens computacionais, desde técnicas clássicas de processamento de imagens até modelos de aprendizado profundo. De modo geral, a literatura cobre tanto tarefas de identificação de espécies adultas quanto variações do problema voltadas à detecção de larvas, ao uso de modalidades alternativas de sinal e à operação em cenários de campo [Lakyiere et al., 2025; De Los Reyes et al., 2016; Arista-Jalife et al., 2020; Fernandes et al., 2021]. Esse conjunto de estudos evidencia o potencial de métodos computacionais para apoiar tarefas de identificação entomológica, especialmente quando a triagem manual de grandes volumes de amostras se torna custosa ou pouco escalável.

Entre as abordagens baseadas em características morfológicas explícitas, De Los Reyes et al. [2016] utilizaram *Support Vector Machines* (SVMs) combinadas à extração de atributos anatômicos, alcançando 90% de acurácia na identificação de *Aedes aegypti*. Em paralelo, outros trabalhos exploraram variações específicas do problema, como a detecção de larvas de mosquitos [Arista-Jalife et al., 2020], a otimização de hiperparâmetros para classificadores de mosquitos adultos [Motta et al., 2020] e o uso de sinais de áudio produzidos pelo bater de asas [Fernandes et al., 2021]. Em conjunto, esses estudos mostram que a identificação automática pode ser formulada com diferentes tipos de entrada e estratégias de modelagem, mas também indicam que o desempenho depende fortemente do tipo de dados disponíveis e do contexto de aquisição.

Com o avanço das redes neurais profundas, a literatura passou a explorar arquiteturas capazes de aprender características discriminativas diretamente a partir das imagens. Nesse grupo, destacam-se estudos voltados à classificação de espécies em campo com redes neurais convolucionais [Park et al., 2020; Sauer et al., 2024], ao aprendizado por transferência com imagens provenientes de plataformas de ciência cidadã [Adhane et al., 2021] e à detecção de espécies novas ou pouco representadas por meio de estratégias baseadas em ensembles e generalização para classes não vistas [Goodwin et al., 2021]. Em comparação com abordagens clássicas, esses trabalhos ampliam a capacidade de modelar padrões visuais complexos, mas também tornam mais evidente a influência das condições de captura, da composição da base e da variabilidade entre dispositivos sobre a qualidade das previsões.

A capacidade de generalização dos modelos e a disponibilidade de dados também aparecem como fatores centrais para a construção de classificadores confiáveis [Nolte et al., 2025;

Lakyiere et al., 2025]. Nesse sentido, Nolte et al. [2025] introduziram o AMID v1, um repositório abrangente de imagens de mosquitos curado por especialistas, enquanto Nolte et al. [2024] avaliaram a identificação de múltiplas espécies a partir de imagens de corpos e asas capturadas por diferentes dispositivos, incluindo *smartphones* e microscópios, reportando variações expressivas de desempenho conforme a espécie e o tipo de imagem. Essa literatura indica que modelos treinados em bases controladas podem perder desempenho quando expostos a imagens obtidas sob diferentes condições de iluminação, resolução, enquadramento, fundo e dispositivo de captura. Em resposta a esse desafio, estudos recentes também têm investigado arquiteturas leves, mecanismos de atenção, fusão de informações e estratégias orientadas à implantação em campo ou em dispositivos com restrições computacionais [Ong et al., 2025; Falk et al., 2025; Nazari et al., 2026]. Entre as arquiteturas leves, a *MobileNetV2* destaca-se por combinar desempenho competitivo e eficiência computacional, sendo adequada a aplicações com requisitos de baixa latência ou implantação em dispositivos de menor capacidade [Örmekaya e Yağanoğlu, 2026].

Embora a literatura apresente avanços relevantes na classificação automática de mosquitos, a ênfase dominante permanece no desempenho preditivo dos modelos e estabilidade da identificação sob diferentes condições de captura [Lakyiere et al., 2025; Nolte et al., 2024]. Em aplicações de vigilância, entretanto, a classificação automática tende a compor apenas uma etapa de um processo mais amplo, que envolve triagem de imagens, priorização de amostras e encaminhamento para validação especializada. Nesse contexto, o presente trabalho diferencia-se por propor um sistema de apoio à decisão para vigilância entomológica, no qual um classificador baseado em *MobileNetV2* é integrado a uma aplicação Web. O sistema permite a submissão de imagens, a seleção do modelo de classificação e a visualização da probabilidade associada à espécie *Aedes aegypti*, preservando a interpretação dos resultados como apoio à decisão, e não como diagnóstico definitivo.

3. Sistema de Apoio à Decisão Proposto

Nesta seção, descreve-se o sistema de apoio à decisão proposto para a triagem automatizada de imagens de mosquitos em ações de vigilância entomológica. Metodologicamente, o sistema é organizado em três componentes: um módulo preditivo baseado em aprendizado profundo, uma camada de apoio à decisão e uma infraestrutura computacional com aplicação Web. Essa organização é detalhada nas subseções a seguir e sintetizada pelas Figuras 2 e 3. A saída do classificador é tratada como informação de apoio à decisão, sem substituir a validação por profissionais da área.

3.1. Visão Geral do Problema e do Fluxo Decisório

O problema abordado neste trabalho consiste na triagem automatizada de imagens de mosquitos vetores, com ênfase na identificação da espécie *Aedes aegypti*. Em vez de considerar a classificação como uma decisão final e autônoma, o sistema proposto interpreta a saída do modelo como um indicador probabilístico que pode apoiar o processo de vigilância entomológica. Assim, imagens com maior probabilidade de conter *Aedes aegypti* podem ser priorizadas para validação especializada, enquanto imagens com menor probabilidade podem receber menor prioridade no fluxo de análise. Casos intermediários podem ser tratados como incertos, demandando nova captura, revisão manual ou análise complementar.

Formalmente, considera-se um conjunto de dados rotulado $\{(x_i, y_i)\}_{i=1}^N$, em que $x_i \in X$ representa uma imagem de entrada e $y_i \in \mathcal{Y} = \{1, \dots, C\}$ corresponde ao rótulo da classe associada. O objetivo do módulo preditivo é aprender uma função $f_\theta : X \rightarrow [0, 1]^C$, parametrizada pelos pesos θ de uma rede neural convolucional, que associe a cada imagem uma distribuição de probabilidade sobre as classes consideradas. Para uma imagem x , a probabilidade estimada para a classe *Aedes aegypti*, denotada por $p_{Aedes}(x)$, corresponde à componente de $f_\theta(x)$ associada à classe de interesse e é utilizada como medida de apoio à triagem e à priorização de amostras.

Esse problema apresenta desafios relevantes do ponto de vista computacional e prático, uma vez que as imagens podem apresentar elevada variabilidade intra-classe e inter-classe, decorrente de diferentes condições de iluminação, ângulos de captura, resoluções, ruído, oclusões e heterogeneidade dos dispositivos utilizados. Além disso, a distinção visual entre espécies de mosquitos pode ser sutil, exigindo a extração de características discriminativas estáveis e informativas. Nesse contexto, o sistema deve ser interpretado como uma ferramenta de apoio ao processo decisório, fornecendo evidências quantitativas ao usuário, mas preservando a necessidade de validação especializada em situações críticas ou incertas [Nolte et al., 2024].

3.2. Módulo de Classificação

O módulo de classificação baseia-se na arquitetura *MobileNetV2* [Sandler et al., 2018], selecionada em função de sua eficiência computacional e desempenho consolidado em tarefas de classificação de imagens. Essa arquitetura é particularmente adequada para cenários com restrições de recursos, como dispositivos de borda (*edge devices*) e aplicações Web com requisitos de baixa latência. A abordagem adotada utiliza aprendizado por transferência, em que o modelo é inicializado com pesos pré-treinados em bases de dados de larga escala e, posteriormente, ajustado (*fine-tuned*) para o problema específico de classificação de mosquitos [Weiss et al., 2016; Perez e Wang, 2017].

A Tabela 1 descreve a arquitetura da *MobileNetV2*. O pipeline começa com uma convolução inicial, composta por blocos residuais invertidos, que combinam expansão de canais, convolução *depthwise* e projeção. Em seguida, os recursos passam por gargalos lineares que buscam reduzir a perda de informação, culminando em camadas finais responsáveis pela classificação da imagem de entrada. A arquitetura também permite o ajuste de parâmetros como resolução da imagem e multiplicador de largura, controlando o equilíbrio entre desempenho e eficiência computacional.

Tabela 1: Arquitetura *MobileNetV2*. t é um fator de expansão aplicado à entrada. c é o número de canais de saída. n é o número de repetições seguidas do operador na arquitetura. s é o *stride* aplicado na primeira camada de cada sequência, com demais camadas tendo *stride* igual a 1. Todos *kernels* da arquitetura são 3×3 .

Tamanho da entrada	Operador	t	c	n	s
$224^2 \times 3$	conv2d	-	32	1	2
$112^2 \times 32$	bottleneck	1	16	1	1
$112^2 \times 16$	bottleneck	6	24	2	2
$56^2 \times 24$	bottleneck	6	32	3	2
$28^2 \times 32$	bottleneck	6	64	4	2
$14^2 \times 64$	bottleneck	6	96	3	1
$14^2 \times 96$	bottleneck	6	160	3	2
$7^2 \times 160$	bottleneck	6	320	1	1
$7^2 \times 320$	conv2d 1x1	-	1280	1	1
$7^2 \times 1280$	avgpool 7x7	-	-	1	-
$1 \times 1 \times 1280$	conv2d 1x1	-	k	-	-

A maneira como a *MobileNetV2* se integra ao módulo preditivo pode ser vista na Figura 2. Durante a etapa de treinamento, a camada de saída original da *MobileNetV2* é substituída por uma camada totalmente conectada composta por C neurônios. A distribuição de probabilidade produzida na saída é dada por $p_k(x) = \exp(z_k) / \sum_{j=1}^C \exp(z_j)$, enquanto o treinamento minimiza a perda *categorical cross-entropy*, $L(x, y) = - \sum_{k=1}^C y_k \log p_k(x)$, por meio de um algoritmo de otimização baseado em gradiente com hiperparâmetros definidos empiricamente.

3.3. Camada de Apoio à Decisão

A camada de apoio à decisão utiliza a saída probabilística do classificador para organizar a interpretação dos resultados pelo usuário. Seja $p_{Aedes}(x)$ a probabilidade estimada pelo modelo de




Figura 2: Arquitetura utilizada no trabalho.

que a imagem x pertença à classe *Aedes aegypti*. Dados limiares $0 \leq \tau_1 < \tau_2 \leq 1$, a imagem recebe baixa prioridade se $p_{Aedes}(x) < \tau_1$, prioridade intermediária se $\tau_1 \leq p_{Aedes}(x) < \tau_2$ e alta prioridade se $p_{Aedes}(x) \geq \tau_2$. Essa regra organiza a interpretação operacional apresentada na Tabela 2.

Tabela 2: Interpretação operacional da saída probabilística do classificador.

Faixa da probabilidade estimada	Interpretação para a triagem	Encaminhamento sugerido
Alta probabilidade de <i>Aedes aegypti</i>	Indício forte de presença da espécie de interesse	Priorizar a imagem para validação especializada
Probabilidade intermediária	Evidência insuficiente para uma classificação conclusiva	Encaminhar para revisão manual, solicitar nova imagem ou manter em fila de análise
Baixa probabilidade de <i>Aedes aegypti</i>	Baixo indício de presença da espécie de interesse	Atribuir menor prioridade no fluxo de triagem, sem descarte automático

A definição de limiares específicos para cada faixa de probabilidade pode ser ajustada de acordo com o contexto de uso, a disponibilidade de especialistas e o custo relativo de falsos positivos e falsos negativos. Em aplicações de vigilância entomológica, por exemplo, falsos negativos podem ser mais críticos quando levam à não priorização de uma amostra contendo vetor de interesse. Por essa razão, o sistema foi concebido para apoiar a decisão humana, fornecendo informações probabilísticas de forma clara, sem automatizar de maneira definitiva a identificação entomológica.

3.4. Métricas de Avaliação do Módulo Preditivo

Para avaliar o desempenho do módulo de classificação, foram utilizadas métricas padrão em problemas de classificação supervisionada: (i) acurácia, (ii) precisão, (iii) sensibilidade e (iv) *F1-score* [Bishop, 2016]. Para cada classe k , consideram-se a precisão $P_k = TP_k / (TP_k + FP_k)$, a sensibilidade $R_k = TP_k / (TP_k + FN_k)$ e o *F1-score* $F1_k = 2P_kR_k / (P_k + R_k)$, enquanto a acurácia global é dada por $Acc = \sum_{k=1}^C TP_k / N$.

Adicionalmente, foram utilizados relatórios de classificação (*classification reports*) para consolidar as métricas por classe, incluindo médias macro e ponderadas. Matrizes de confusão foram empregadas como ferramenta complementar para visualizar padrões de acertos e erros entre as classes. No contexto do sistema de apoio à decisão, essas métricas são importantes não apenas para medir o desempenho preditivo do classificador, mas também para avaliar a confiabilidade das informações utilizadas na triagem das imagens.

3.5. Arquitetura Computacional do Sistema

A arquitetura computacional do sistema foi concebida com foco em modularidade, facilidade de implantação e integração entre o módulo preditivo e a interface de uso. O *back-end* foi implementado em Python, linguagem amplamente utilizada em aplicações de aprendizado

de máquina e ciência de dados. Para a comunicação entre os módulos, foi utilizado o `Flask`, um *microframework* leve empregado na implementação de uma *API REST*. Essa API gerencia o fluxo de entrada e saída do sistema, recebendo as imagens enviadas pelo usuário, executando o pré-processamento necessário, aplicando o classificador selecionado e retornando as respostas no formato estruturado `JSON`, contendo as previsões do classificador e suas respectivas probabilidades.

No contexto de implantação (*deployment*), o serviço foi hospedado na plataforma `Render`, que oferece suporte a aplicações em `Python` e integração contínua a partir de repositórios `Git`. Essa escolha permite que novas versões do modelo ou da aplicação sejam disponibilizadas de forma simplificada e reprodutível. A camada de *front-end* da aplicação Web foi desenvolvida utilizando `React`, uma biblioteca `JavaScript` voltada à construção de interfaces de usuário baseadas em componentes reutilizáveis e reativos [React, 2024]. Para a estilização da interface, foi utilizado o `Tailwind CSS`, um *framework* baseado em classes utilitárias que permite a construção de interfaces responsivas [Tailwind CSS, 2024]. A comunicação entre o *front-end* e o *back-end* é realizada por meio de requisições `HTTP`, utilizando a função nativa `fetch` do `JavaScript`, responsável pelo envio das imagens selecionadas pelo usuário e pelo recebimento dos resultados de classificação. A aplicação *front-end* foi hospedada na plataforma `Vercel`, que oferece suporte ao *deploy* de aplicações Web modernas e integração com repositórios `Git`.

O fluxo de funcionamento do sistema é ilustrado na Figura 3. Inicialmente, o usuário seleciona um dos modelos disponíveis e submete uma imagem por meio da interface Web. Em seguida, a imagem é enviada ao *back-end*, onde são realizadas as etapas de pré-processamento e inferência. Por fim, o sistema retorna a probabilidade associada à classe *Aedes aegypti*, que é apresentada ao usuário como informação de apoio à triagem.

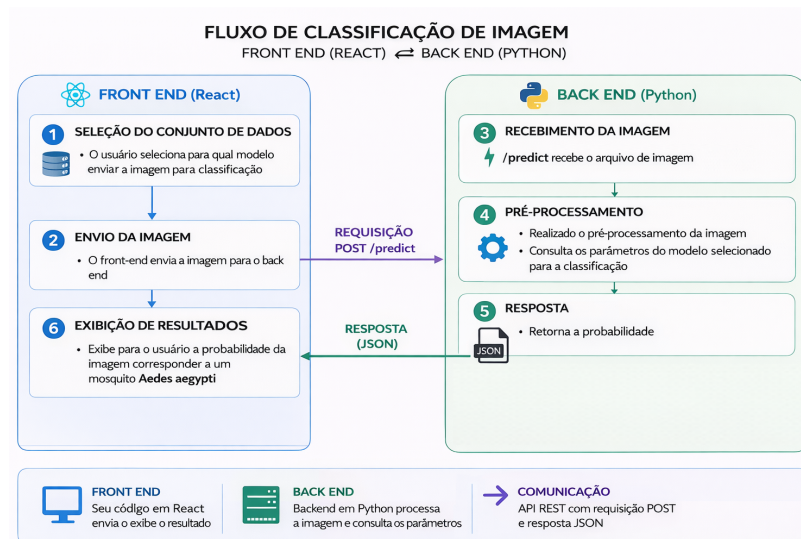


Figura 3: Fluxograma de funcionamento do sistema de apoio à decisão.

3.6. Interface do Usuário

A interface do usuário foi projetada com foco em usabilidade, clareza das informações e apoio à interpretação dos resultados. A aplicação Web é organizada em seções que fornecem:

Informação sobre o mosquito: conteúdo informativo sobre o mosquito *Aedes aegypti*, seu papel na transmissão de arboviroses e a importância do controle vetorial.

Informação sobre as doenças: descrição breve das principais doenças associadas ao vetor, incluindo dengue, zika, chikungunya e febre amarela, com dados epidemiológicos, orientações de prevenção e sintomas, baseados em fontes oficiais como o Ministério da Saúde.

Classificador: área dedicada à submissão de imagens, na qual o usuário pode selecionar um dos modelos disponíveis e carregar uma imagem para análise.

Exibição dos resultados: área destinada a apresentar o resultado da classificação, incluindo a probabilidade associada à espécie *Aedes aegypti*, de forma gráfica e textual.

A navegação entre as seções é realizada a partir de uma barra superior com as funcionalidades disponíveis. Além disso, a aplicação apresenta informações adicionais sobre os conjuntos de dados utilizados, uma explicação breve sobre o funcionamento da classificação de imagens e uma descrição de como a inteligência artificial pode auxiliar processos de vigilância entomológica. A Figura 4 ilustra o layout da aplicação, mostrando a página com informações sobre a dengue ¹



Figura 4: Exemplo da seção com informações sobre a dengue.

4. Avaliação Computacional e Verificação Funcional do Sistema

Esta seção apresenta os resultados da avaliação computacional do módulo preditivo e verificação funcional do sistema de apoio à decisão. A análise empírica foi conduzida em duas frentes complementares: o desempenho do classificador em bases públicas de imagens de mosquitos e o funcionamento integrado da aplicação Web. Para isso, foram considerados o *Aedes Mosquitos Dataset*, em cenário binário, e o *Dataset of Vector Mosquito Images (Mendeley)*, em cenário multiclasse.

4.1. Avaliação do Módulo Preditivo

Os experimentos avaliaram diferentes configurações de treinamento, variando o conjunto de dados, o uso de aumento de dados (*data augmentation*), o número de épocas, considerando 110, 650 e 1000 épocas, e a combinação dos conjuntos de dados em um único treinamento. Em algumas configurações, o treinamento com poucas épocas não apresentou convergência satisfatória, o que motivou a extensão para 1000 épocas. Entretanto, no caso do *Aedes Mosquitos Dataset* sem aumento de dados, observaram-se indícios de *overfitting*, com elevada acurácia de treinamento e desempenho inferior em validação e teste. Esse comportamento sugere que, nesse cenário binário, a variabilidade adicional introduzida pelo aumento de dados contribui para reduzir a sensibilidade do modelo a padrões específicos da base e para tornar o treinamento mais estável.

Os melhores comportamentos foram obtidos com o *Aedes Mosquitos Dataset* com aumento de dados e com o *Dataset of Vector Mosquito Images (Mendeley)*. A seleção desses dois modelos para compor o sistema considerou o desempenho em teste, o equilíbrio entre precisão e sensibilidade nas classes de interesse e o comportamento da convergência ao longo do treinamento.

¹ Sistema de apoio à decisão para classificação de *Aedes aegypti*.

Nesses casos, a convergência ocorreu de forma mais estável, em geral entre 600 e 650 épocas, o que permitiu adotar 650 épocas nos experimentos finais. As Figuras 5, 6a, 6b e as Tabelas 3 e 4 apresentam os resultados dos dois modelos selecionados.





Figura 5: Gráfico comparativo da evolução do treinamento com 650 épocas do *Aedes Mosquitos Dataset* com aumento de dados e *Dataset of Vector Mosquito Images (Mendeley)*.



(a) *Aedes Mosquitos Dataset*.

(b) *Dataset of Vector Mosquito Images (Mendeley)*.

Figura 6: Matriz de confusão do treinamento.

Tabela 3: Relatório de classificação com o *Aedes Mosquitos Dataset*.

Classe	Precision	Recall	F1-score	Support
aegypti	0.95	0.93	0.94	408
albopictus	0.93	0.95	0.94	408
Accuracy			0.94	816
Macro avg	0.94	0.94	0.94	816
Weighted avg	0.94	0.94	0.94	816

Tabela 4: Relatório de classificação com o *Dataset of Vector Mosquito Images (Mendeley)*.

Classe	Precision	Recall	F1-score	Support
Aedes Aegypti	0.94	0.92	0.93	180
Anopheles Stephensi	0.94	0.94	0.94	108
Culex Quinquefasciatus	0.94	0.95	0.94	240
Accuracy			0.94	528
Macro avg	0.94	0.94	0.94	528
Weighted avg	0.94	0.94	0.94	528

De modo geral, as curvas (Figura 5) indicam crescimento rápido da acurácia nas primeiras épocas, seguido de estabilização em patamares elevados, enquanto as perdas diminuem e se mantêm baixas. As matrizes de confusão apresentam diagonais bem destacadas, sugerindo predominância de classificações corretas em ambos os cenários. Ainda assim, a interpretação dos resultados não deve se limitar à acurácia global. No cenário binário, o modelo treinado com aumento de dados alcança equilíbrio entre precisão e sensibilidade para *Aedes aegypti* e *Aedes albopictus*, indicando capacidade adequada de discriminação entre espécies visualmente semelhantes. No cenário multi-classe, a manutenção de acurácia global de 0.94 e de métricas por classe também próximas de 0.94 é particularmente relevante, pois sugere que o módulo preditivo preserva desempenho competitivo mesmo diante de uma tarefa mais exigente, com maior diversidade de espécies vetorais. Para o objetivo do trabalho, esse resultado é importante porque sustenta o uso da classificação como apoio à triagem inicial, em vez de restringi-la a um cenário binário mais simples.

4.2. Verificação Funcional e Discussão

A verificação funcional da versão de prova de conceito consistiu em testar o fluxo completo da aplicação Web: seleção entre os modelos disponíveis, envio da imagem pelo usuário, processamento no *back-end*, execução da inferência e apresentação do resultado na interface. Os testes confirmaram a comunicação adequada entre o *front-end* e a *API REST*, bem como o retorno das probabilidades de classificação em formato estruturado. Assim, o sistema permite que o usuário submeta uma imagem e visualize a probabilidade associada à classe *Aedes aegypti*, convertendo a saída do classificador em informação utilizável no fluxo de triagem e priorização de imagens para eventual análise especializada.

Durante esses testes, observou-se que o modelo treinado com o *Dataset of Vector Mosquito Images (Mendeley)* apresentou respostas mais consistentes para as imagens submetidas pela aplicação, com menor sensibilidade aparente a padrões de fundo. Esse comportamento complementa os resultados quantitativos, pois mostra que desempenho semelhante em acurácia não implica necessariamente o mesmo comportamento quando o modelo é exposto a imagens no fluxo funcional do sistema. Por outro lado, o modelo baseado no *Aedes Mosquitos Dataset* mostrou maior sensibilidade a características do fundo das imagens de treinamento, o que pode levar a previsões inadequadas quando a imagem submetida apresenta padrões visuais semelhantes aos da base original. Essa limitação reforça a importância de interpretar a saída do classificador como apoio à decisão, e não como identificação entomológica definitiva.

Em conjunto, os resultados indicam que o módulo preditivo pode ser incorporado a um sistema de apoio à decisão voltado à triagem de imagens de mosquitos, respondendo de forma favorável à questão de pesquisa formulada. A classificação automática mostrou desempenho compatível com a priorização inicial de amostras, e a integração à aplicação Web mostrou que esse resultado pode ser convertido em apoio efetivo ao fluxo de análise. Ainda assim, a aplicação em cenários reais de campo requer validação adicional com imagens coletadas em diferentes condições, bem como a inclusão de amostras negativas ou inconclusivas. Dessa forma, o sistema deve ser entendido como uma ferramenta auxiliar para organização do fluxo de análise e priorização de casos, preservando a necessidade de validação especializada em situações críticas ou incertas.

5. Considerações Finais

Os resultados obtidos sustentam, de forma favorável, o uso da classificação de imagens como apoio à triagem inicial em processos de vigilância entomológica. A integração entre o módulo preditivo baseado em *MobileNetV2* e a aplicação Web converte o desempenho do classificador em suporte efetivo à priorização de amostras e à organização do fluxo de análise. Entre os modelos integrados ao sistema, o treinado com o *Dataset of Vector Mosquito Images (Mendeley)* apresentou

o comportamento mais consistente nos testes funcionais, enquanto o modelo treinado com o *Aedes Mosquitos Dataset* evidenciou maior sensibilidade a características do fundo das imagens.

Em conjunto, esses resultados reforçam a contribuição do trabalho ao combinar avaliação do módulo preditivo em cenários binário e multiclasse com a implementação funcional de um sistema de apoio à decisão voltado à triagem de imagens de mosquitos. Entretanto, o sistema não substitui a identificação realizada por especialistas, devendo ser interpretado como uma ferramenta auxiliar para organizar o fluxo de análise, priorizar amostras e sinalizar casos que demandam revisão manual.

Cabe destacar que os valores de acurácia obtidos neste trabalho refletem a avaliação em bases públicas de imagens, predominantemente obtidas em condições controladas, e não devem ser diretamente extrapolados para cenários reais de campo. Variações de iluminação, fundo, qualidade da imagem, orientação dos espécimes e condições de aquisição podem introduzir uma possível mudança de domínio, reduzindo o desempenho de modelos treinados em imagens laboratoriais. Assim, a validação com imagens coletadas em condições reais constitui uma etapa essencial para avaliar a robustez e a capacidade de generalização do sistema. Outra oportunidade de trabalhos futuros é expandir o conjunto de espécies consideradas, incorporar classes negativas ou inconclusivas, calibrar as probabilidades produzidas pelo classificador e definir limiares de decisão para diferentes políticas de triagem. Também se pode desenvolver uma versão para dispositivos móveis e investigar estratégias de atualização contínua do modelo a partir de novas imagens validadas por especialistas.

Agradecimentos

O presente trabalho foi realizado com apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) (processos nº 311907/2023-7, 102199/2024-8).

Referências

- Adhane, G., Dehshibi, M. M., e Masip, D. (2021). A Deep Convolutional Neural Network for Classification of *Aedes Albopictus* Mosquitoes. *IEEE Access*, 9:72681 – 72690. ISSN 21693536.
- Arista-Jalife, A., Nakano, M., Garcia-Nonoal, Z., Robles-Camarillo, D., Perez-Meana, H., e Arista-Viveros, H. A. (2020). *Aedes* mosquito detection in its larval stage using deep neural networks. *Knowledge-Based Systems*, 189. ISSN 09507051.
- Bishop, C. M. (2016). *Pattern Recognition and Machine Learning*. Springer New York. ISBN 978-1-4939-3843-8.
- De Los Reyes, A. M. M., Reyes, A. C. A., Torres, J. L., Padilla, D. A., e Villaverde, J. (2016). Detection of *Aedes Aegypti* mosquito by digital image processing techniques and support vector machine. In *2016 IEEE Region 10 Conference (TENCON)*, p. 2342–2345.
- Falk, M., Garriga, J., Eritja, R., Sanpera-Calbet, I., Pou, E., Richter-Boix, A., Palmer, J. R., e Bartumeus, F. (2025). Augmenting community-driven vector surveillance with automated image classification: Lessons from the Artificial Intelligence Mosquito Alert (AIMA) system. *Epidemics*, 53:100863. ISSN 17554365.
- Fernandes, M. S., Cordeiro, W., e Recamonde-Mendoza, M. (2021). Detecting *Aedes aegypti* mosquitoes through audio classification with convolutional neural networks. *Computers in Biology and Medicine*, 129. ISSN 00104825.
- Goodwin, A., Padmanabhan, S., Hira, S., Glancey, M., Slinowsky, M., Immidiseti, R., Scavo, L., Brey, J., Sai Sudhakar, B. M. M., Ford, T., Heier, C., Linton, Y.-M., Pecor, D. B., Caicedo-Quiroga, L., e Acharya, S. (2021). Mosquito species identification using convolutional neural networks with a multitiered ensemble model for novel species detection. *Scientific Reports*, 11:13656. ISSN 2045-2322.
- Isawasan, P. e Quan, O. S. (2020). *Aedes* mosquitos dataset. URL <https://www.kaggle.com/datasets/pradeepisawasan/aedes-mosquitos>.
- Lakyiere, A. B., Gyening Mensah, R.-M. O., Agbenor-Efunam, N. Y., Yamba, E., e Badu, K. (2025). Trends and advances in image-based mosquito identification and classification using machine learning models: A systematic review. *Computers in Biology and Medicine*, 193:110373. ISSN 00104825.

- Ministério da Saúde (2025). *Aedes aegypti*. URL <https://www.gov.br/saude/pt-br/assuntos/saude-de-a-a-z/a/aedes-aegypti>.
- Motta, D., Bandeira Santos, A. Á., Souza Machado, B. A., Vicente Ribeiro-Filho, O. G., Arriaga Camargo, L. O., Valdenegro-Toro, M. A., Kirchner, F., e Badaró, R. (2020). Optimization of convolutional neural network hyperparameters for automatic classification of adult mosquitoes. *PLoS ONE*, 15:e0256101. ISSN 19326203.
- Nazari, M. Z., Zarchi, M. S., Emadi, S., e Poormohammadi, H. (2026). A novel deep learning approach for mosquito species classification via a dual-head structure and calibration-aware fusion architecture. *Scientific Reports*, 16. ISSN 20452322.
- Nolte, K., Agboli, E., Garcia, G. A., Badolo, A., Becker, N., Loc, D. H., Dworak, T. V., Eguchi, J., Eisenbarth, A., de Freitas, R. M., Doumna-Ndalembouly, A. G., Heitmann, A., Jansen, S., Jöst, A., Jöst, H., Kiel, E., Meyer, A., Pfitzner, W.-P., Saathoff, J., Schmidt-Chanasit, J., Sulesco, T., Tokatlian, A., Velavan, T. P., Villacañas de Castro, C., Wehmeyer, M. L., Zahouli, J., Sauer, F. G., e Lühken, R. (2025). Comprehensive Mosquito Wing Image Repository for Advancing Research on Geometric Morphometric- and AI-Based Identification. *Scientific Data*, 12. ISSN 20524463.
- Nolte, K., Sauer, F. G., Baumbach, J., Kollmannsberger, P., Lins, C., e Lühken, R. (2024). Robust mosquito species identification from diverse body and wing images using deep learning. *Parasites and Vectors*, 17. ISSN 17563305.
- Ong, S.-Q., Pinoy, N., Lim, M. H., Bjerger, K., Peris-Felipo, F. J., Lind, R., Cuff, J. P., Cook, S. M., e Høye, T. T. (2025). ScannerVision: Scanner-based image acquisition of medically important arthropods for the development of computer vision and deep learning models. *Current Research in Parasitology and Vector-Borne Diseases*, 7:100268. ISSN 2667114X.
- Örmekaya, T. e Yağanoğlu, M. (2026). Deep learning approaches for robust mosquito classification from body and wing images. *Next Research*, 3:101167. ISSN 3050-4759.
- Pan American Health Organization (2026). Epidemiological update for dengue, chikungunya and zika. URL <https://www.paho.org/en/arbo-portal/arbo-bulletins>. Accessed: 2026-01-14.
- Pan American Health Organization (PAHO) (2024). Dengue: Data and analysis - Brazil. URL <https://www.paho.org/en/arbo-portal/dengue-data-and-analysis/dengue-analysis-country>. Acesso em: 12 abr. 2026.
- Park, J., Kim, D. I., Choi, B., Kang, W., e Kwon, H. W. (2020). Classification and Morphological Analysis of Vector Mosquitoes using Deep Convolutional Neural Networks. *Scientific Reports*, 10. ISSN 20452322.
- Perez, L. e Wang, J. (2017). The Effectiveness of Data Augmentation in Image Classification using Deep Learning.
- Pise, R., PATIL, K., Laad, M., e Pise, N. (2022). Dataset of vector mosquito images. URL <https://data.mendeley.com/datasets/88s6fvvgg2p/4>.
- React (2024). Documentação oficial do react. URL <https://react.dev>.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., e Chen, L.-C. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, p. 4510 – 4520. IEEE Computer Society. ISBN 978-1-5386-6420-9.
- Sauer, F. G., Werny, M., Nolte, K., Villacañas de Castro, C., Becker, N., Kiel, E., e Lühken, R. (2024). A convolutional neural network to identify mosquito species (Diptera: Culicidae) of the genus *Aedes* by wing images. *Scientific Reports*, 14:3094. ISSN 2045-2322.
- Tailwind CSS (2024). Documentação oficial do tailwind css. URL <https://tailwindcss.com/docs>.
- Weiss, K., Khoshgoftaar, T. M., e Wang, D. (2016). A survey of transfer learning. *Journal of Big Data*, 3.
- Wilder-Smith, A., Gubler, D. J., Weaver, S. C., Monath, T. P., Heymann, D. L., e Scott, T. W. (2017). Epidemic arboviral diseases: priorities for research and public health. *The Lancet Infectious Diseases*, 17:e101 – e106. ISSN 14733099.