Computational Models for Identifying *Aedes aegypti* Breeding Sites in Aerial Images: A Systematic Review

Rafaela R. Farias*, André G. C. Silva, Geovana de S. Rodrigues, Eduardo R. M. Magalhães, Milena B. B. da Mota, Mariane S. Oliveira, Camilly V. L. da Silva, Hélder S. Lima*

[1]Instituto Federal do Norte de Minas Gerais (IFNMG) – Campus Januária
Fazenda São Geraldo, S/N Km 06 – 39480-000 – Januária – MG – Brasil

*Correspondentes: rrf11@aluno.ifnmg.edu.br, helder.seixas@ifnmg.edu.br

Abstract. *Arboviral diseases transmitted by Aedes aegypti mosquito pose significant public health challenges, particularly in tropical regions. This article presents a Systematic Literature Review on the use of models for breeding site identification from aerial images. Following the PRISMA guidelines, 11 studies published between 2020 and 2026 were selected. The results indicate a predominance of deep learning approaches, especially convolutional models such as YOLO, with consistent performance. The observed limitations and the most robust studies are discussed to support future research.*

Resumo. *As arboviroses transmitidas pelo mosquito Aedes aegypti representam desafios à saúde pública, principalmente em regiões tropicais. Este artigo apresenta uma Revisão Sistemática da Literatura sobre o uso de modelos para identificação de criadouros a partir de imagens aéreas. Seguindo as diretrizes PRISMA, foram selecionados 11 estudos publicados entre 2020 e 2026. Os resultados indicam predominância do uso de deep learning, especialmente modelos convolucionais como YOLO, com desempenho consistente. São discutidos as limitações observadas e os trabalhos mais robustos da área.*

1. Introdução

As arboviroses dengue, chikungunya e zika, transmitidas pelo mosquito *Aedes aegypti*, figuram entre os principais desafios da saúde pública no Brasil, em razão de sua elevada incidência e recorrentes surtos epidêmicos [Codeco et al. 2018]. O manejo inadequado de resíduos sólidos e a desorganização do espaço urbano contribuem para a manutenção de ambientes propícios à reprodução do mosquito. Isso ocorre porque qualquer recipiente capaz de acumular água parada, como pneus, caixas d'água destampadas, piscinas, vasos e resíduos sólidos, pode se tornar um potencial criadouro [Scott and Takken 2012].

Modelos de visão computacional vêm sendo empregados para detectar recipientes e ambientes favoráveis à oviposição do *Aedes aegypti* [Sutanto and Ansharullah 2025, Carrasco-Escobar et al. 2022]. Revisões recentes têm explorado esse campo sob diferentes perspectivas. Sutanto e Ansharullah (2025) realizaram uma revisão narrativa técnica sobre o papel da inteligência artificial na prevenção, controle e manejo da dengue, mencionando, entre outras aplicações, estudos que utilizam imagens aéreas e arquiteturas convolucionais para detecção de criadouros. Já Carrasco-Escobar et al. (2022) analisaram especificamente o uso de drones na vigilância e controle de mosquitos vetores, destacando modelos de aeronaves e algoritmos empregados, incluindo técnicas de aprendizado profundo.

Apesar dessas contribuições, ainda não há, até onde se tem conhecimento, uma Revisão Sistemática da Literatura (RSL) que consolide e analise de forma estruturada os estudos que utilizam imagens aéreas, coletadas por drones ou satélites, associadas a modelos de visão computacional para classificação, detecção ou segmentação de potenciais criadouros do *Aedes aegypti*. Assim, este trabalho tem como objetivo realizar uma RSL para mapear o estado da arte dessas abordagens, identificando os principais modelos de aprendizado de máquina empregados, os métodos de coleta de dados, as bases de dados utilizadas, as estratégias de treinamento adotadas e o desempenho e a robustez dos métodos propostos. Ao sistematizar essas evidências, busca-se fornecer subsídios para o avanço científico e para o desenvolvimento de soluções tecnológicas aplicáveis à vigilância em saúde.

2. Metodologia

2.1. Abordagem Metodológica

Esta pesquisa foi estruturada como uma RSL, visando mapear o panorama atual das soluções que empregam modelos de visão computacional para a identificação de potenciais criadouros do *Aedes aegypti* por meio de imagens aéreas, sejam elas captadas via drones ou satélites. O protocolo metodológico fundamentou-se nas diretrizes estabelecidas pelo PRISMA [Moher et al. 2010].

2.2. Protocolo de Coleta de Dados

A coleta de dados concentrou-se na busca de literatura científica primária em bases conceituadas nas áreas de saúde, engenharia e computação. Assim, a investigação bibliográfica foi conduzida nas seguintes bases: PubMed (`https://pubmed.ncbi.nlm.nih.gov/`), IEEE Xplore (`https://ieeexplore.ieee.org`), ACM Digital Library (`https://dl.acm.org/`), Scopus (`https://www.elsevier.com/products/scopus`) e Springer Nature (`https://link.springer.com`).

A *string* de busca consistiu em: *("Aedes aegypti" OR mosquito OR dengue OR Zika OR Chikungunya) AND (drone OR UAV OR "remote sensing" OR georeferencing OR satellite) AND (detection OR identification OR classification) AND (breeding OR focus) AND ("machine learning" OR "deep learning" OR "image processing" OR "computer vision" OR algorithm OR model).*

O recorte temporal adotado compreendeu os estudos publicados nos 6 anos anteriores à coleta de dados. Considerando que a busca foi realizada em maio de 2026, esta RSL abrange trabalhos publicados entre janeiro de 2020 e maio de 2026.

2.3. Protocolo de Seleção

2.3.1. Critérios de Elegibilidade

Como parte do protocolo de seleção, foram estabelecidos critérios de elegibilidade, organizados em critérios de inclusão e exclusão. Dois critérios de inclusão foram definidos: (1) artigos completos em inglês ou português revisados por pares e disponíveis na íntegra para verificação; e (2) estudos primários publicados nos últimos 6 anos (a partir de 2020) que empregaram técnicas de aprendizado de máquina para identificação de criadouros do *Aedes aegypti* por meio de imagens aéreas.

Também se estabeleceu que qualquer artigo que se enquadrasse em ao menos 1 dos 8 critérios de exclusão seria removido da análise, a saber: (1) documentos duplicados, quando há múltiplas versões do mesmo estudo com objetivos de pesquisa equivalentes, sendo considerada apenas a versão mais recente ou mais completa; (2) literatura cinza, compreendendo estudos que não passaram por processo de revisão por pares, como relatórios técnicos ou trabalhos disponíveis apenas na forma de resumo; (3) estudos em idiomas distintos do inglês ou português; (4) estudos não disponíveis integralmente ou cujo acesso ao texto completo não tenha sido possível; (5) estudos secundários ou terciários, tais como revisões da literatura; (6) estudos que não empregaram técnicas de aprendizado de máquina; (7) estudos que não aplicaram métodos para identificação (classificação, detecção ou segmentação) de criadouros do *Aedes aegypti*; e (8) estudos que não utilizaram imagens aéreas, obtidas por drones ou satélites, para o treinamento dos modelos.

2.3.2. Processo de Seleção

Após a identificação inicial dos estudos por meio da *string* de busca aplicada às bases de dados descritas na Seção 2.2, o processo de triagem foi conduzido em 4 etapas sequenciais: (1) avaliação do título; (2) avaliação do resumo; (3) leitura exploratória do texto completo; e (4) leitura integral e detalhada do artigo.

Todos os 8 autores desta RSL atuaram como revisores ao longo das 4 etapas de triagem. Em cada fase, os artigos foram distribuídos aleatoriamente para 2 revisores em avaliações independentes. A exclusão de um estudo em determinada etapa ocorria somente quando ambos os revisores concordavam que ele se enquadrava em pelo menos um dos critérios de exclusão previamente estabelecidos. Na etapa final, todos os artigos remanescentes foram obrigatoriamente avaliados pelo pesquisador de maior senioridade científica, a quem coube a decisão conclusiva quanto à inclusão ou exclusão do estudo na RSL. Esse procedimento foi adotado com o objetivo de mitigar vieses individuais, assegurar consistência nas decisões e fortalecer o rigor metodológico do processo de seleção. Ao término das quatro etapas, os estudos remanescentes foram considerados elegíveis por atenderem integralmente aos critérios de inclusão definidos no protocolo.

2.4. Protocolo de Verificação da Qualidade

Os dados extraídos dos estudos selecionados foram organizados por meio de um formulário, elaborado para garantir consistência na coleta e comparabilidade das informações relevantes para esta RSL. Tais dados descrevem as bases de dados utilizadas e também aspéctos metodológicos e de aplicação dos modelos empregados nos trabalhos.

A qualidade dos estudos foi avaliada por meio de 9 critérios. Cada critério recebeu uma pontuação de acordo com a escala: 0 (não atende), 0,5 (atende parcialmente) e 1 (atende plenamente). A pontuação final de cada estudo foi obtida pela soma das notas dos 9 critérios. A Tabela 1 apresenta os critérios utilizados na avaliação.

Para os critérios Q3 e Q9, atribuiu-se atendimento parcial quando o estudo informa que os dados e o código-fonte, respectivamente, podem ser disponibilizados mediante solicitação. No caso do critério Q9, também se considerou atendimento parcial quando o artigo apresenta informações suficientemente detalhadas sobre o modelo, os dados, os hiperparâmetros e os procedimentos experimentais, permitindo sua reprodução.

Tabela 1. Critérios para avaliação da qualidade metodológica dos estudos

	Critério de qualidade
Q1	O estudo descreve detalhadamente o conjunto de dados utilizado, incluindo número de imagens por classe, resolução espacial ou *Ground Sample Distance* (GSD), origem das imagens (satélite ou drone), localização geográfica, estratégia de divisão dos dados e resolução da imagem?
Q2	Para estudos que utilizam drones, o trabalho apresenta informações sobre aquisição das imagens, incluindo modelo do drone, tipo de sensor e altitude de voo?
Q3	O conjunto de dados utilizado está publicamente disponível para *download*?
Q4	O estudo descreve de forma clara e completa o *pipeline* de treinamento e avaliação do modelo, incluindo algoritmos empregados, divisão dos dados, pré-processamento, estratégia de validação, principais hiperparâmetros e métricas de avaliação?
Q5	O estudo realiza avaliação comparativa adequada, utilizando modelos *baseline* ou métodos de referência e apresentando análise crítica dos resultados?
Q6	O estudo utiliza uma estratégia de validação apropriada, com separação clara entre dados de treinamento e teste, evitando vazamento de dados (*data leakage*)?
Q7	O modelo é avaliado quanto à sua capacidade de generalização, utilizando dados independentes provenientes de diferentes regiões, períodos ou sensores?
Q8	O estudo realiza análise de ablação ou avaliação da contribuição dos principais componentes do modelo, demonstrando o impacto individual desses elementos no desempenho final?
Q9	O código-fonte do modelo necessário para reprodução dos experimentos estão disponíveis publicamente?

3. Resultados e Discussão

A Figura 1 apresenta os processos de coleta e seleção empregados nesta RSL. As buscas nas bases de dados científicas resultaram inicialmente em 430 estudos. Observa-se que a base Springer Nature concentrou aproximadamente 81% dos trabalhos recuperados.

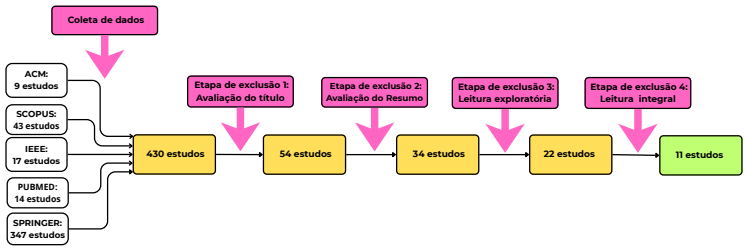


Figura 1. Fluxo dos processos de coleta e seleção dos artigos

Na primeira etapa de triagem, correspondente à análise dos títulos, foram excluídos 376 estudos, permanecendo 54 para a etapa subsequente. Nessa fase, a maioria das exclusões foi pelo critério 7 (estudos que não aplicaram métodos para identificação de criadouros do *Aedes aegypti*), indicando que muitos dos trabalhos recuperados abordavam temáticas correlatas, mas não diretamente alinhadas ao objetivo desta RSL.

Após as 4 etapas de exclusão, foram selecionados 11 estudos que atenderam plenamente a todos os critérios de inclusão definidos no protocolo. Esses artigos são listados na Tabela 2 e compõem o *corpus* final desta RSL, tendo seus dados extraídos, organizados e sistematizados para análise, conforme apresentado ao longo desta seção.

3.1. Análise das Bases de Dados

A Tabela 3 apresenta as principais características dos conjuntos de dados utilizados nos estudos selecionados nesta RSL. A análise desses aspectos permite compreender o contexto dos experimentos realizados e avaliar a qualidade dos dados empregados para identificação de criadouros do *Aedes aegypti* por meio de imagens aéreas.

3.1.1. Método de Coleta das Imagens

Dez estudos selecionados empregam imagens obtidas por meio de drones. O drone DJI Phantom 4 foi o equipamento mais frequentemente empregado, sendo que as bases de dados de 6 estudos foram coletadas por ele. Destaca-se ainda que Deb et al. (2023) desenvolveram um drone próprio a partir da estrutura do DJI S550.

Tabela 2. Síntese dos estudos selecionados

Nº	Título	Referência	Modelos empregados	Aplicação	Métricas avaliadas
1	Drones vs Dengue: A Drone-Based Mosquito Control System for Preventing Dengue	[Amarasinghe and Wijesuriya 2020]	SVM	Classificação	Precisão e revocação
2	Computer Vision System for Automatic Identification of Potential *Aedes aegypti* Mosquito Breeding Sites Using Drones	[Lima et al. 2021]	YOLOv4 em comparação com o YOLOv3	Detecção	Revocação e mAP@0.5
3	Creating a Yolov3 Custom Model for Aerial Surveillance	[Pinto et al. 2021]	YOLOv3	Detecção	Verdadeiros Positivos
4	Deep Learning for Arbitrary-Shaped Water Pooling Region Detection on Aerial Images	[Mylvaganam and Dissanayake 2022]	Mask-RCNN, YOLOv4	Detecção e segmentação	mAP (limiar IoU não explicitado), precisão e revocação
5	A Real-time Automatic Dengue Breeding Zone Detection and Prevention Scheme based on MobileNetV2 Enabled Autonomous Drone	[Deb et al. 2023]	MobileNet-SSDv2	Detecção	IoU médio e acurácia
6	Weighted Ensemble Algorithm for Aerial Imaging Based Mosquito Breeding Sites Classification	[Thevarasa et al. 2023]	CNN (RGB), CNN (LAB), SVM, FSL e *ensemble* ponderado	Classificação	Acurácia
7	YOLOV7 for Mosquito Breeding Grounds Detection and Tracking	[Laranjeira et al. 2023]	YOLOv7	Detecção	Verdadeiros positivos, falsos positivos, falsos negativos, revocação e acurácia
8	Detection of Potential Breeding Sites Based on AAV Remote Sensing Imagery and MultiDCCSP-YOLO Network	[Gao et al. 2025]	MultiDCCSP-YOLO (baseado no YOLOv9) em comparação com YOLOv5, YOLOv9, SSD e Faster R-CNN	Detecção	Precisão, revocação, mAP@0.5, FLOPs e número de parâmetros do modelo
9	Smart system for real time monitoring and diagnosis of dengue surfaces in Bangladesh	[Apu et al. 2025]	CBAM-enhanced YOLOv9 em comparação com YOLOv8 e YOLOv9	Detecção	Precisão, revocação, mAP@0.5, mAP@0.5-0.95 e número de parâmetros do modelo
10	Enhancing *Aedes aegypti* breeding site detection: A deep learning approach to tire identification in unmanned aerial vehicle imagery from urban Indonesia	[Hassan et al. 2026]	U-Net++ e DeepLabV3+	Segmentação	F1 *Score*, MCC (*Matthews Correlation Coefficient*), acurácia, precisão e revocação
11	High-resolution UAV dataset for identification of breeding sites for malaria and dengue vectors in rural and peri-urban Tanzania	[Nyambo et al. 2026]	Gemma 3N E4B	Detecção, descrição de contexto e geração de recomendação	Função de perda (*loss*), sem especificar qual função de perda foi utilizada

Tabela 3. Bases de dados empregadas nos estudos selecionados

Nº	Origem	GSD	Modelo (drone)	Altura do voo	Qtd. imagens	Qtd. classes	Resolução	Localização
1	Drone	N/I	DJI Phantom 4	10m acima de edifícios	900	2	N/I	Sri Lanka
2	Drone	0,30 a 2,45 cm/px	DJI Phantom 3 e 4	3 a 70 m	500	2	4.000x3.000 px, 3.000x2.250 px	Brasil
3	Internet e satélite	5 a 20 m/inch	N/A	N/A	150 (Internet) e 72 (satélite)	1	4K/Full-HD (Internet)	Brasil e EUA
4	Drone	$\geq$ 7 cm/px	N/I	Baixa altitude	600	2	N/I	N/I
5	N/I (treino) e drone (testes)	N/I	Fabricação própria	N/I	1.000 (treino) e N/I (testes)	1	N/I	Bangladesh
6	Drone	7 cm/px	DJI Mavic 2 Pro	15 a 24 m	347	2	256x256 px	N/I
7	Drone	N/I	DJI Phantom Vision 4 PRO	10 a 40 m	79.562	6	3.840x4.096 px	Brasil
8	Drone	0,82 cm/px	DJI Phantom4 Pro V2	30 m	1.891	9	960x960 px	China
9	Drone	N/I	DJI Matrice 300 RTK	10 a 50 m	1.500	1	800x600 px	Bangladesh
10	Drone	3 cm/px	DJI Phantom 4 RTK	100 m	500	1	N/I	Indonésia
11	Drone	N/I	DJI Phantom 4 Pro	40 m	471	19	20 MP	Tanzânia

Nº: número do trabalho definido em Tabela 2, N/I: não informado e N/A: não aplicável.

A altitude de voo adotada para a aquisição das imagens variou entre 3 e 100 metros em relação ao solo. Embora a maioria dos estudos não informe o GSD, os trabalhos que reportaram essa informação apresentaram valores entre 0,30 e 7 cm/pixel. A resolução das imagens também é frequentemente negligenciada pelos autores. Entre os estudos que disponibilizaram essa informação, observou-se uma ampla variação, desde imagens com resolução de 256×256 pixels até imagens de alta resolução com 4.000×3.000 pixels.

Apenas Pinto et al. (2021) utilizaram imagens provenientes de satélites. Além disso, os autores usaram como conjunto de treinamento imagens de piscinas coletadas na plataforma Unsplash (`https://unsplash.com/`).

3.1.2. Volume dos Dados

Observa-se variação no volume de dados entre os estudos. Laranjeira et al. (2023) empregam a base de dados *Mosquito Breeding Grounds* (MBG) [Passos et al. 2022], que representa o maior conjunto de dados utilizado entre os trabalhos incluídos nesta RSL. A base MBG é composta por 79.562 *frames*, extraídos de 13 vídeos, os quais foram manualmente inspecionados, resultando na anotação de 88.281 objetos. As instâncias rotuladas abrangem diferentes tipos de potenciais criadouros do *Aedes aegypti*, incluindo garrafas, baldes, piscinas, poças, pneus e caixas d'água [Laranjeira et al. 2023].

Gao et al. (2025) também trabalharam com uma base robusta, inicialmente composta por 1.891 imagens captadas por drone abrangendo 9 classes distintas. Após aplicação de técnicas de aumento de dados e reamostragem híbrida, a base foi expandida para 23.227 imagens. De forma semelhante, Deb et al. (2023) ampliaram sua base inicial de cerca de 1.000 para 3.000 imagens por meio de técnicas de aumento de dados. Outros estudos também relatam o uso de estratégias de aumento de dados, porém sem informar o volume adicional de imagens geradas [Lima et al. 2021, Hassan et al. 2026].

De modo geral, observa-se que a obtenção de *datasets* extensos ainda representa um desafio para a área. Mais da metade dos estudos analisados utilizam menos de 1.000 imagens, evidenciando as dificuldades associadas à coleta e anotação de imagens aéreas de potenciais criadouros do *Aedes aegypti*. Além disso, o treinamento de modelos em conjuntos de dados de grande escala demanda recursos computacionais significativos, constituindo um fator adicional que pode limitar a utilização de bases mais volumosas.

3.1.3. Classes

Verifica-se variação no nível de detalhamento das classes-alvo. Nyambo et al. (2026) apresentam o maior grau de detalhamento, rotulando 19 classes distintas. Porém, observa-se uma base de dados desbalanceada, com apenas 3 classes (sem criadouro, poça temporária e arrozais) acumulando cerca de 80% das instâncias rotuladas [Nyambo et al. 2026]. Gao et al. (2025) também apresentam significativo detalhamento, rotulando 9 classes distintas (baldes, pias, tigelas, tampas, frascos, lixeiras, caixas, vasos e plantas aquáticas). O terceiro e último trabalho multiclasse foi Laranjeira et al. (2023), com 6 categorias (balde, caixa d'água, garrafa, piscina, pneu e poça d'água).

Entretanto, a maioria dos estudos optou por rotulagem simplificada. Deb et al. (2023), Lima et al. (2021) e Apu et al. (2025) agruparam diferentes criadouros em uma única classe. Pinto et al. (2021) rotularam apenas piscinas e Hassan et al. (2026) apenas pneus. Outra abordagem foi a classificação binária [Mylvaganam and Dissanayake 2022, Amarasinghe and Wijesuriya 2020, Thevarasa et al. 2023].

3.1.4. Localização Geográfica

O Brasil constitui o cenário empírico de 3 estudos selecionados, realizados na Região Metropolitana de São Paulo/SP [Lima et al. 2021], em Vitória/ES [Pinto et al. 2021] e no Rio de Janeiro/RJ [Laranjeira et al. 2023]. A Ásia concentra o maior número de investigações, totalizando 5 estudos conduzidos em Dhaka e Gazipur, no Bangladesh [Deb et al. 2023, Apu et al. 2025], em Xangai, na China [Gao et al. 2025], em Ambalangoda, no Sri Lanka [Amarasinghe and Wijesuriya 2020], e em Makassar, na Indonésia [Hassan et al. 2026]. Por sua vez, Nyambo et al. (2026) realizaram um estudo na África, utilizando imagens coletadas nos distritos de Masasi e Igunga, na Tanzânia.

3.2. Análise dos Modelos Empregados

3.2.1. Modelos e Tipos de Aplicação

O YOLO (*You Only Look Once*), uma arquitetura de detecção de objetos de estágio único baseada em aprendizado profundo, foi o modelo mais empregado entre os estudos selecionados para identificação de potenciais criadouros do *Aedes aegypti* em imagens aéreas. Seis dos 11 trabalhos analisados usam alguma versão dessa arquitetura. Além das versões convencionais, alguns autores propuseram extensões da arquitetura original. Gao et al. (2025) e Apu et al. (2025), por exemplo, desenvolveram os modelos MultiDCCSP-YOLO e CBAM-YOLO, respectivamente, ambos baseados no YOLOv9.

Quanto ao tipo de aplicação, observa-se uma clara predominância de abordagens voltadas para detecção de objetos. Oito dos 11 estudos analisados enquadram-se nessa categoria, incluindo os 6 trabalhos baseados em YOLO, o estudo de Deb et al. (2023), que emprega uma versão do SSD (*Single Shot Detector*), outro detector de estágio único, e o trabalho de Nyambo et al. (2026), que explora o uso de um modelo generativo para identificação de potenciais criadouros.

Em contraste com as abordagens baseadas em aprendizado profundo para detecção, Amarasinghe e Wijesuriya (2020) adotam uma estratégia clássica de aprendizado de máquina, combinando Máquinas de Vetores de Suporte (SVM) com o descritor *Histogram of Oriented Gradients* (HOG) para classificar imagens contendo acúmulo de água. Outra aplicação de classificação foi proposta por Thevarasa et al. (2023), utilizando arquiteturas baseadas em redes neurais convolucionais (CNNs), SVM e *ensemble*.

Por fim, apenas Mylvaganam e Dissanayake (2022) e Hassan et al. (2026) abordam o problema sob a perspectiva da segmentação de imagens. Diferentemente das abordagens de detecção, que delimitam os objetos por meio de caixas delimitadoras, esses estudos buscam identificar precisamente os contornos dos potenciais criadouros, produzindo máscaras de segmentação *pixel* a *pixel*.

3.2.2. Estratégias de Treinamento

De modo geral, os estudos analisados adotam a abordagem supervisionada tradicional, com particionamento do conjunto de dados em subconjuntos distintos para treinamento, validação e teste. Contudo, estratégias alternativas foram empregadas visando viabilizar o aprendizado em cenários caracterizados por limitação amostral.

Thevarasa et al. (2023) trabalharam com uma base composta por apenas 347 imagens. Para contornar limitações decorrentes de dados de treino reduzidos, os autores adotaram o paradigma de *Few-Shot Learning* (FSL), estruturando o treinamento de forma iterativa, com conjuntos de suporte (*support set*) com 20 amostras por classe e conjuntos de consulta (*query set*) com 5 amostras por classe.

Conforme discutido na Seção 3.1.2, estudos também recorrem a técnicas de aumento de dados para reduzir problemas associados à limitação amostral durante o treinamento [Gao et al. 2025, Deb et al. 2023, Lima et al. 2021, Hassan et al. 2026].

Outro desafio recorrente refere-se à desproporção entre o tamanho dos objetos de interesse e a predominância de regiões de fundo nas imagens aéreas, o que dificulta a capacidade de detecção de objetos de pequenas dimensões. Para enfrentar esse problema, Gao et al. (2025) empregam a função de perda *Adaptive Threshold Focal Loss* (ATFL).

De forma semelhante, Hassan et al. (2026) combinam uma função de perda especializada com a estratégia de *curriculum learning*, na qual o modelo é treinado inicialmente com exemplos mais simples e, gradualmente, exposto a amostras mais complexas, favorecendo a estabilidade do processo de aprendizagem e a detecção de padrões difíceis.

Por sua vez, Apu et al. (2025) integra o *Convolutional Block Attention Module* (CBAM) ao YOLOv9. Essa estratégia busca direcionar o foco do modelo para regiões mais relevantes da imagem, reduzindo a influência do fundo e melhorando a detecção de objetos pequenos, um desafio frequente em aplicações baseadas em imagens aéreas.

3.2.3. Desempenho dos Modelos

Não é possível realizar uma comparação direta entre os estudos incluídos nesta RSL, uma vez que eles empregam conjuntos de dados distintos, utilizam métricas de avaliação diferentes e abordam problemas variados, como classificação, detecção e segmentação de objetos. Ainda assim, observa-se que as métricas mais frequentemente utilizadas foram revocação, precisão, acurácia e mAP@0.5. Cabe destacar que alguns trabalhos apresentam limitações em suas estratégias de avaliação, seja pela ausência de métricas amplamente adotadas para a tarefa considerada, seja pela utilização de um conjunto restrito de indicadores de desempenho [Amarasinghe and Wijesuriya 2020, Pinto et al. 2021, Deb et al. 2023, Thevarasa et al. 2023, Nyambo et al. 2026].

De modo geral, os estudos reportam resultados satisfatórios, indicando o potencial das técnicas de aprendizado de máquina para identificação de potenciais criadouros do *Aedes aegypti* em imagens aéreas. Entre os trabalhos que realizam análises comparativas, Gao et al. (2025) demonstram que o modelo MultiDCCSP-YOLO alcançou mAP@0.5 de 95%, superando arquiteturas amplamente utilizadas na literatura, como YOLOv5, SSD e Faster R-CNN. De forma semelhante, Apu et al. (2025) obtiveram mAP@0.5 de 99,5% com o modelo CBAM-YOLO, desempenho superior ao observado para as versões YOLOv8 e YOLOv9 avaliadas pelos autores.

Na tarefa de segmentação, Hassan et al. (2026) verificaram que o modelo U-Net++ apresenta desempenho superior ao DeepLabV3++, alcançando F1 *score* de 0,87, contra 0,82 obtido pelo modelo concorrente na segmentação de pneus.

Mylvaganam e Dissanayake (2022) comparam os modelos Mask R-CNN e YOLOv4, evidenciando maior precisão e revocação para o Mask R-CNN. Contudo, o YOLOv4 apresenta melhor desempenho computacional, com tempo médio de aproximadamente 1 segundo por imagem nos testes, enquanto o Mask R-CNN demanda cerca de 5 segundos para a mesma tarefa, indicando um *trade-off* entre acurácia e eficiência.

Em imagens de satélite, Pinto et al. (2021) reportam taxas de verdadeiros positivos na detecção de piscinas variando entre aproximadamente 50% e 94% para imagens de maior resolução espacial (5 m/inch). Por outro lado, em imagens de menor resolução (20 m/inch), os valores oscilam entre 0% e 21% [Pinto et al. 2021].

Por fim, Thevarasa et al. (2023) encontraram que o modelo CNN operando no espaço de cor LAB apresenta desempenho superior quando comparado à mesma arquitetura no espaço RGB, além de superar abordagens baseadas em SVM e FSL.

3.3. Análise da Robustez Metodológica dos Trabalhos

A Tabela 4 apresenta os resultados da avaliação da qualidade metodológica dos estudos selecionados. Entre os critérios analisados, o Q6 (estratégia de validação) é o mais frequentemente atendido, indicando uma preocupação recorrente dos autores em estabelecer separação adequada entre os conjuntos de treinamento e teste, reduzindo o risco de vazamento de dados e de superestimação do desempenho dos modelos.

Tabela 4. Critérios de qualidade verificados para os estudos selecionados

Nº	Q1	Q2	Q3	Q4	Q5	Q6	Q7	Q8	Q9	Nota final
1	0,5	0,5	0	0,5	0,5	1	1	0	0	4,0
2	1	1	0,5	1	1	1	0	0	0,5	6,0
3	0,5	N/A	0	0,5	0	0	1	0	1	3,0
4	0,5	0,5	0	0,5	0,5	1	0	0	0,5	3,5
5	0,5	0,5	0	0,5	0	1	1	0	0	3,5
6	0	1	0	0,5	1	0,5	0	0	0,5	3,5
7	0,5	1	1	0,5	0	1	0	0	0,5	4,5
8	1	1	0,5	1	1	1	0	1	0,5	7,0
9	0,5	1	0,5	1	1	1	0	1	0,5	6,5
10	0,5	1	0,5	1	0,5	1	0	0	1	5,5
11	0,5	1	1	0,5	0	1	0	0	0,5	4,5

Nº: número do trabalho definido em Tabela 2, Q#: critério de qualidade definido em Tabela 1 e N/A: não aplicável.

Por outro lado, os critérios Q7 (avaliação de generalização) e Q8 (estudo de ablação) são os menos contemplados pelos trabalhos analisados. Esse resultado sugere que a literatura ainda dedica pouca atenção à avaliação da capacidade dos modelos de generalizar para novos cenários e à investigação da contribuição individual dos componentes dos modelos.

A reprodutibilidade também se mostra uma limitação relevante. Conforme se observa na Tabela 4, apenas 2 estudos atendem plenamente aos critérios Q3 (disponibilidade dos dados) e Q9 (disponibilidade do código-fonte).

Entre os trabalhos analisados, Gao et al. (2025), Apu et al. (2025) e Lima et al. (2021) obtêm as maiores pontuações de qualidade. Em contrapartida, 5 estudos alcançam menos da metade da pontuação máxima possível. Observa-se que todos esses trabalhos com menor pontuação foram publicados em eventos científicos, os quais frequentemente impõem restrições de espaço que podem limitar o detalhamento metodológico, a descrição dos experimentos e a disponibilização de informações necessárias para a reprodutibilidade dos resultados.

3.4. Desafios e Oportunidades

Do ponto de vista prático, os resultados indicam oportunidades para a adoção e adaptação de modelos robustos em cenários locais. Entre os trabalhos analisados, destacam-se o MultiDCCSP-YOLO [Gao et al. 2025] e o CBAM-YOLO [Apu et al. 2025], que apresentam metodologias com elevado rigor científico e obtiveram boa performance. Além disso, a base de dados MBG [Passos et al. 2022], utilizada por Laranjeira et al. (2023), constitui um recurso relevante para pesquisas futuras, por disponibilizar um grande volume de imagens rotuladas compatíveis com o contexto urbano brasileiro.

Apesar dos avanços observados, diversos desafios permanecem em aberto. Embora imagens de satélite representem uma fonte potencialmente atrativa para aplicações em larga escala, apenas um dos estudos selecionados explora esse tipo de dado. Os resultados obtidos por Pinto et al. (2021) sugerem que a viabilidade dessa abordagem depende fortemente da resolução espacial disponível. Enquanto imagens de maior resolução apresentam desempenho satisfatório para a detecção de piscinas, imagens de menor resolução mostram limitações significativas para a tarefa.

A disponibilidade restrita de imagens orbitais de alta resolução é uma barreira para a expansão dessa linha de pesquisa. Ademais, o objeto investigado por Pinto et al. (2021), piscinas, apresenta dimensões maiores do que outros criadouros frequentemente encontrados em ambientes urbanos, como pneus, baldes e garrafas. Essa diferença de escala torna a identificação desses objetos menores particularmente desafiadora em imagens de satélite, contribuindo para a predominância do uso de drones entre os estudos analisados.

Por outro lado, a dependência de drones também impõe limitações importantes. O DJI Phantom 4, equipamento mais utilizado nos estudos, possui custo elevado, o que pode restringir sua adoção por grupos de pesquisa e órgãos públicos com recursos limitados. Soma-se a isso a escassez de bases de dados publicamente disponíveis. Embora alguns autores informem a possibilidade de compartilhamento dos dados mediante solicitação, apenas uma pequena parcela dos trabalhos disponibiliza seus conjuntos de dados de forma aberta. A ampliação da disponibilidade de dados públicos é fundamental para fortalecer a reprodutibilidade, favorecer comparações entre métodos e acelerar o avanço da área.

Outra oportunidade de aprimoramento para pesquisas futuras trata-se da avaliação da robustez metodológica. Em particular, observou-se que poucos estudos realizaram análises de generalização utilizando dados provenientes de diferentes regiões geográficas, períodos de coleta ou sensores. Da mesma forma, estudos de ablação foram raramente empregados para quantificar a contribuição individual dos componentes propostos. Dessa forma, recomenda-se que trabalhos futuros incorporem avaliações mais abrangentes de generalização e análises de ablação, contribuindo para uma compreensão mais aprofundada da robustez e da aplicabilidade prática dos modelos desenvolvidos.

Por fim, a aplicação de modelos generativos para a identificação de potenciais criadouros do *Aedes aegypti* desponta como uma promissora linha de pesquisa. Entre os estudos analisados, Nyambo et al. (2026) apresentam uma das primeiras iniciativas nessa direção. Contudo, o trabalho apresenta limitações metodológicas importantes, especialmente no que se refere à avaliação experimental, o que dificulta uma análise mais conclusiva sobre a efetividade e o potencial dessa abordagem em comparação com os métodos tradicionais de detecção de objetos.

3.5. Limitações

As principais limitações foram não ter incluído artigos em espanhol e bases de dados regionais como SciELO e LILACS na estratégia de busca. A heterogeneidade dos *datasets*, métricas e aplicações também limita as comparações entre os trabalhos desta RSL.

4. Conclusões

Esta RSL analisou o estado da arte das aplicações para identificação de potenciais criadouros do *Aedes aegypti* em imagens aéreas. Onze trabalhos foram selecionados, os quais mostraram que a área apresenta sinais de amadurecimento com modelos capazes de alcançar desempenhos satisfatórios, ainda que existam lacunas metodológicas relevantes. Observou-se ainda que as pesquisas se concentram predominantemente em países tropicais e subtropicais da América do Sul, Ásia e África, regiões fortemente impactadas por arboviroses transmitidas pelo *Aedes aegypti*, o que demonstra o interesse da comunidade científica em desenvolver soluções tecnológicas para apoiar ações de vigilância vetorial.

A análise dos estudos selecionados permitiu identificar trabalhos metodologicamente robustos, com destaque para Gao et al. (2025) e Apu et al. (2025). Entretanto, a RSL também revelou desafios que ainda limitam o avanço da área, incluindo as restrições do uso de imagens de satélite para detecção de objetos de pequenas dimensões, os custos associados à aquisição de drones, a escassez de bases de dados disponibilizadas publicamente e a limitada adoção de avaliações de generalização e estudos de ablação.

Por fim, a revisão identificou o surgimento de abordagens baseadas em modelos generativos para a identificação de potenciais criadouros do *Aedes aegypti*. Embora ainda incipiente, essa linha de pesquisa apresenta potencial para complementar os métodos atualmente empregados, constituindo uma direção promissora para investigações futuras.

Agradecimentos

Os autores agradecem ao CNPq, à FAPEMIG e ao {cidic} - Grupo de Pesquisa em Ciência de Dados e Inteligência Computacional.

Materiais Suplementares

A planilha desta RSL está disponível para download: `tinyurl.com/rslaedes`.

Referências

Amarasinghe, A. and Wijesuriya, V. B. (2020). Drones vs dengue: A drone-based mosquito control system for preventing dengue. In *Proceedings - 2020 RIVF International Conference*.

Apu, M. S. H., Ahmed, S., and Ahmed, M. T. (2025). Smart system for real time monitoring and diagnosis of dengue surfaces in bangladesh. *Array*.

Carrasco-Escobar, G., Moreno, M., Fornace, K., Herrera-Varela, M., Manrique, E., and Conn, J. E. (2022). The use of drones for mosquito surveillance and control. *Parasites & vectors*, 15(1):473.

Codeco, C., Coelho, F., Cruz, O., Oliveira, S., Castro, T., and Bastos, L. (2018). Infodengue: A nowcasting system for the surveillance of arboviruses in brazil. *Revue*

d'Épidémiologie et de Santé Publique, 66:S386. European Congress of Epidemiology "Crises, epidemiological transitions and the role of epidemiologists".

Deb, A., Ahmed, S. I., Islam, A., Haque, M., Fattah, S. A., and Shahnaz, C. (2023). A real-time automatic dengue breeding zone detection and prevention scheme based on mobilenetv2 enabled autonomous drone. In *26th International Conference on Computer and Information Technology (ICCIT)*, pages 1–6.

Gao, Z. et al. (2025). Detection of potential breeding sites based on aav remote sensing imagery and multidccsp-yolo network. *IEEE Access*, 13.

Hassan, M. M., Chamberlin, A. J., Tarpenning, M. S., Weber, W. C., Coombe, K. D., De Leo, G. A., Junaid, M., Soma, A. S., Ansariadi, and Rosser, J. I. (2026). Enhancing aedes aegypti breeding site detection: A deep learning approach to tire identification in unmanned aerial vehicle imagery from urban indonesia. *Remote Sensing Applications: Society and Environment*.

Laranjeira, C., Andrade, D., and dos Santos, J. A. (2023). Yolov7 for mosquito breeding grounds detection and tracking. In *IEEE International Conference on Image Processing Challenges and Workshops (ICIPCW)*, pages 1–5.

Lima, G. A., Cotrin, R. O., Belan, P. A., and de Araújo, S. A. (2021). Computer vision system for automatic identification of potential aedes aegypti mosquito breeding sites using drones. *RISTI - Revista Iberica de Sistemas e Tecnologias de Informacao*.

Moher, D., Liberati, A., Tetzlaff, J., Altman, D. G., Group, P., et al. (2010). Preferred reporting items for systematic reviews and meta-analyses: the prisma statement. *International journal of surgery*, 8(5):336–341.

Mylvaganam, P. and Dissanayake, M. B. (2022). Deep learning for arbitrary-shaped water pooling region detection on aerial images. In *MERCon 2022 - Moratuwa Engineering Research Conference*.

Nyambo, D., Lyimo, T. M., and Sauli, E. (2026). High-resolution uav dataset for identification of breeding sites for malaria and dengue vectors in rural and peri-urban tanzania: An experimental approach with gemma 3n e4b architecture. *Data in Brief*.

Passos, W. L., Araujo, G. M., de Lima, A. A., Netto, S. L., and da Silva, E. A. (2022). Automatic detection of aedes aegypti breeding grounds based on deep networks with spatio-temporal consistency. *Computers, Environment and Urban Systems*, 93:101754.

Pinto, A. O., Ciarelli, P. M., and Sarcinelli-Filho, M. (2021). Creating a yolov3 custom model for aerial surveillance. *IEEE*.

Scott, T. W. and Takken, W. (2012). Feeding strategies of anthropophilic mosquitoes result in increased risk of pathogen transmission. *Trends in parasitology*, 28(3):114–121.

Sutanto, H. and Ansharullah, B. A. (2025). The role of artificial intelligence for dengue prevention, control, and management: A technical narrative review. *Acta Tropica*, 268:107741.

Thevarasa, N., Ananthajothy, G., Navaratnam, R., and Dissanayake, M. B. (2023). Weighted ensemble algorithm for aerial imaging based mosquito breeding sites classification. In *2023 IEEE 17th International Conference*.