

DETECÇÃO DE POTENCIAIS CRIADOUROS DE AEDES AEGYPTI EM IMAGENS AÉREAS POR MEIO DA TRANSFORMADA CIRCULAR DE HOUGH

**DETECTION OF POTENTIAL AEDES AEGYPTI BREEDING SITES IN AERIAL
IMAGES USING THE CIRCULAR HOUGH TRANSFORM**

Ciências Exatas e da Terra, Engenharias • 05/10/2026

REGISTRO DOI: [10.70773/revistatopicos/790862745](https://doi.org/10.70773/revistatopicos/790862745)

Marcelo Musci¹

Mauricio Quelhas Antolin²

Giancarlo Cordeiro da Costa³

RESUMO

O mosquito *Aedes aegypti* é responsável por doenças como dengue, Zika, chikungunya e febre amarela, que afetam milhões de pessoas anualmente. A principal estratégia de controle consiste em prevenir a reprodução do mosquito por meio da identificação e da eliminação de criadouros, sendo esse um dos pontos destacados pela Organização Mundial da Saúde (OMS) entre as medidas eficazes de controle de vetores. Veículos Aéreos Não Tripulados (Unmanned Aerial Vehicles - UAV), ou drones, têm se mostrado ferramentas valiosas para a vigilância em saúde, pois possibilitam a captura de imagens aéreas de alta resolução para a localização de criadouros; no entanto, a análise dessas imagens ainda é realizada manualmente na maior parte dos casos, o que se mostra demorado e pouco eficiente. A Transformada de Hough, técnica amplamente empregada em visão computacional para a detecção de formas geométricas como linhas e círculos, é aplicada neste estudo em sua variante para círculos, buscando detectar possíveis criadouros do mosquito *Aedes aegypti* como método auxiliar à abordagem baseada em outras técnicas como redes neurais convolucionais profundas (deep CNNs), com o objetivo de otimizar a identificação de criadouros e melhorar a eficácia das operações de controle de vetores.

Palavras-chave: Transformada de Hough; Veículos Aéreos Não Tripulados; Visão Computacional.

ABSTRACT

The mosquito *Aedes aegypti* is the vector of diseases such as dengue, Zika, chikungunya, and yellow fever, which affect millions of people annually. The primary control strategy consists of preventing mosquito reproduction through the identification and elimination of breeding sites. This approach is highlighted by the World Health

Organization (WHO) as one of the effective measures for vector control. Unmanned Aerial Vehicles (UAVs), or drones, have proven to be valuable tools for public health surveillance because they enable the acquisition of high-resolution aerial images for locating potential breeding sites. However, in most cases, these images are still analyzed manually, making the process time-consuming and inefficient. The Hough Transform, a technique widely used in computer vision to detect geometric shapes such as lines and circles, is applied in this study through its circular variant, seeking to detect potential breeding sites of the mosquito *Aedes aegypti* as a complementary method to the approach based on other techniques such as deep convolutional neural networks (deep CNNs), aiming to optimize the identification of breeding sites and improve the effectiveness of vector-control operations.

Keywords: Hough Transform; Unmanned Aerial Vehicles; Computer Vision.

1. INTRODUÇÃO

De acordo com Bravo et al. (2021), a redução de potenciais criadouros de mosquitos é uma medida preventiva importante para enfrentar o fardo dessas doenças e avançar em direção à sua eliminação. No entanto, as autoridades de saúde frequentemente se veem sobrecarregadas por esse desafio, especialmente em áreas onde uma parte considerável da população não tem acesso a estruturas habitacionais adequadas nem a serviços básicos bem gerenciados, como água, saneamento e coleta de resíduos sólidos, fatores determinantes para o risco de transmissão de doenças transmitidas por mosquitos (Barrera et al., 1995; WHO, 2017). Além disso, à medida que a população global se urbaniza cada vez mais, a consolidação socioeconômica e física de assentamentos humanos

vulneráveis continua sendo um desafio persistente (UN-HABITAT, 2016), tornando crucial o desenvolvimento de novas técnicas que possam apoiar o controle de vetores em cidades caracterizadas por alta complexidade espacial e social.

Neste contexto, pode-se utilizar o uso de imagens e vídeos capturados por um Veículo Aéreo Não Tripulado (Unmanned Aerial Vehicles - UAV), também conhecido como drone, para apoiar os agentes de saúde locais na localização de possíveis áreas de risco. A partir dessas imagens, pode-se utilizar um sistema para automatizar o processo de análise, aplicando técnicas de aprendizado de máquina e visão computacional para auxiliar o especialista na localização de focos relevantes de mosquitos (Passos et al., 2022). Para esse fim, no trabalho de Passos et al. (2022), foi construído um banco de dados de vídeos anotados, adquiridos por um UAV que voa a diferentes altitudes e segue trajetórias predefinidas em formato de serpentina. Utilizando esse banco de dados, foi desenvolvido um sistema capaz de detectar potenciais criadouros produtivos, processando todos os quadros do vídeo na arquitetura Faster R-CNN (Ren et al., 2017). Estudos mostram que concentrar esforços nos criadouros mais produtivos, como pneus e caixas d'água, é quase tão eficaz quanto direcionar a busca para todas as classes de objetos que constituem potenciais criadouros do mosquito, com a vantagem de otimizar os recursos relacionados a tempo e custo (Tun-Lin et al., 2009). Como pneus e caixas d'água possuem formas circulares, um algoritmo de visão computacional, a Transformada de Hough Circular (Duda; Hart, 1972) e seu equivalente aprimorado (Atherton; Kerbyson, 1999), pode ser aplicado para a obtenção de resultados na análise dos quadros de vídeo.


Com base nesse cenário, o objetivo deste trabalho é investigar a aplicação da Transformada de Hough Circular na detecção de pneus e caixas d'água em imagens aéreas, de forma a auxiliar a detecção principal desses objetos, realizada pela arquitetura Faster R-CNN.

2. REVISÃO BIBLIOGRÁFICA

2.1. A Transformada de Hough Circular Aprimorada

A Transformada de Hough para Círculos (CHT) (Duda; Hart, 1972) tem como objetivo encontrar formações circulares de um raio R dado dentro de uma imagem. Em sua forma convencional, um conjunto de pontos de borda da imagem original contribui, cada um, com um círculo de raio R para um espaço acumulador de saída; esse espaço apresenta um pico no ponto em que os círculos contribuídos se sobrepõem, correspondente ao centro do círculo original (Figura 1).

Figura 1. Transformada de Hough para Círculos.



Fonte: Adaptado de Atherton e Kerbyson (1999).

A inclusão da direção da borda em um detector de círculos sensível a uma faixa de raios ("anel de orientação") resulta em picos amplos, porém com boa tolerância ao ruído. A introdução da fase radial logarítmica no CHT, também sensível a uma faixa de raios, resulta em larguras de pico mais estreitas, mas com baixa tolerância ao

ruído. A combinação dessas características (direção da borda, faixa de raios e fase radial logarítmica) resulta em larguras de pico estreitas e tolerância ao ruído significativamente melhorada, sendo essa versão do CHT formalmente equivalente a um núcleo de invariância. Os resultados indicam que o núcleo de invariância gera picos na matriz acumuladora ligeiramente mais largos do que o CHT combinado, porém com desempenho superior em relação ao ruído (Atherton; Kerbyson, 1999).

2.2. Utilização da Função `imfindcircles` do MATLAB®

A função `imfindcircles` do MATLAB® utiliza um algoritmo baseado na Transformada Circular de Hough Aprimorada para encontrar círculos em imagens, sendo empregada devido à sua robustez na presença de ruído, oclusão e iluminação variável. Embora a CHT não seja um algoritmo rigorosamente especificado, havendo diferentes abordagens possíveis para sua implementação, três etapas são comuns à maioria delas: (i) cálculo da matriz do acumulador, na qual pixels de primeiro plano de alto gradiente são designados como candidatos e lançam votos em um padrão circular ao seu redor; (ii) estimação do centro, em que os votos tendem a se acumular na célula correspondente ao centro real do círculo, permitindo detectá-lo pelos picos no acumulador; e (iii) estimativa do raio, necessária quando o mesmo acumulador é utilizado para mais de um valor de raio.

A função oferece dois algoritmos, *phase-coding* (padrão) e *two-stage*, que compartilham características computacionais comuns: o uso de um array acumulador 2D, ao invés do *array* 3D exigido pela Transformada de Hough clássica, o que reduz o custo de armazenamento e o tempo de processamento, e o uso de pixels de

borda, limitando os pixels candidatos àqueles com gradiente de magnitude elevado; e o uso de informações de orientação da borda, restringindo os votos a um intervalo ao longo da direção do gradiente. Detalhes adicionais sobre o algoritmo podem ser encontrados em Atherton e Kerbyson (1999), Yuen et al. (1990) e Davies (2005).

A sintaxe da função é $[centers, radii] = imfindcircles(A, radiusRange)$, podendo ainda retornar a métrica de confiança de cada detecção (*metric*). O parâmetro *A* corresponde à imagem de entrada (matriz 2D em escala de cinza ou 3D em RGB) e *radiusRange* define o intervalo mínimo e máximo de raio dos círculos a serem detectados. Entre os parâmetros nome-valor mais relevantes estão *Sensitivity*, que ajusta a sensibilidade da detecção no intervalo $[0, 1]$ (padrão de 0,85, sendo que valores mais altos detectam mais círculos, mas aumentam o risco de falsos positivos); *EdgeThreshold*, que define o limiar para a detecção de bordas; e *ObjectPolarity*, que especifica se os círculos são mais claros (*bright*) ou mais escuros (*dark*) do que o fundo.

2.3. Base de Dados

De acordo com Barrera et al. (1995), um banco de dados ideal para detecção e classificação de objetos em vídeos aéreos deve atender a requisitos técnicos como: controle rigoroso dos parâmetros de gravação; amostragem significativa para cada classe de objeto; diversidade de fundo, posição dos objetos, condições de iluminação e altura de captura; ausência de distorções óticas introduzidas pela câmera; e anotações precisas de localização e classificação dos objetos.

Com base nesses critérios, Passos et al. (2022) desenvolveram um banco de dados de vídeos aéreos anotados MBG (Mosquito Breeding Grounds Database), disponível publicamente em MBG (2021), voltado especificamente à detecção de criadouros de mosquitos. O banco inclui informações de telemetria do drone (altitude, latitude, longitude e velocidade de voo), permitindo a geolocalização precisa dos objetos de interesse por meio de suas respectivas bounding boxes. Os vídeos foram capturados com o drone comercial Phantom 4 PRO, da DJI (2021), equipado com câmera de alta definição e estabilização passiva e ativa (*gimbal*) (Barrera et al., 1995).

O MBG é composto por 13 sequências de vídeo, adquiridas em 11 locais distintos do município do Rio de Janeiro, onde três são correspondentes a áreas urbanas reais e os demais a cenários com objetos inseridos manualmente em posições aleatórias. O drone executa, de forma autônoma, um padrão de varredura em serpentina sobre a área de interesse, com ajustes automáticos de câmera desativados, foco fixado no infinito e vídeos gravados em resolução de 3840×2160 ou 4096×2160 pixels, a 24 quadros por segundo. Antes de cada voo é gravado um vídeo de calibração com padrão de tabuleiro de xadrez, permitindo a correção de distorções ópticas da lente pelo método de Zhang (2000). A altitude é mantida constante ao longo de cada vídeo, havendo gravações em 10, 25 e 40 metros (com variação de $\pm 0,5$ m), e a velocidade do drone é de aproximadamente 15 km/h. As cenas abrangem vegetação, ruas, edificações, terrenos baldios e áreas urbanas, e a anotação dos vídeos é realizada manualmente, quadro a quadro, com o software CVAT (Sekachev et al., 2020). Exemplos de quadros anotados do MBG são apresentados nas Figuras 2 e 3.

Figura 2. Quadro selecionado de sequência de vídeo do banco de dados MBG, exibindo bounding boxes anotadas de caixas d'água.



Fonte: MBG (2021).

Figura 3. Quadro selecionado de sequência de vídeo do banco de dados MBG, exibindo bounding boxes anotadas de pneus.




Fonte: MBG (2021).

2.4. Avaliação de Objetos

Segundo Passos (2019), é fundamental avaliar o modelo quanto à localização dos objetos, processo que consiste em mensurar a proximidade entre o contorno do objeto detectado e o ground truth. Para essa análise emprega-se a métrica *Intersection over Union* (IoU), amplamente utilizada na avaliação de algoritmos que geram *bounding boxes* e derivada do índice de Jaccard. Dada uma *bounding box* predita (A) e uma *bounding box* de referência (B), o

IoU é definido pela razão entre a área de interseção e a área de união dessas caixas (Figura 4):

Figura 3. Quadro selecionado de sequência de vídeo do banco de dados MBG, exibindo bounding boxes anotadas de pneus.



Fonte: O Autor (2025).

O resultado varia entre 0 e 1:

- IoU = 0: não existe sobreposição;
- IoU = 1: as caixas coincidem perfeitamente;
- $IoU \geq 0,5$: critério frequentemente usado para considerar a detecção um verdadeiro positivo.

$$IoU = \text{área}(A \cap B) / \text{área}(A \cup B) \quad (1)$$

As detecções do modelo são classificadas como verdadeiros positivos (*True Positive* - TP) quando o IoU entre a *bounding box* predita e o *ground truth* é igual ou superior a um limiar estabelecido, comumente 50%, embora limiares mais rigorosos, de até 95%, também sejam relatados na literatura, e como falsos positivos (FP) caso contrário. Um falso negativo (FN) ocorre quando um objeto presente no ground truth não é detectado pelo modelo;

no contexto da detecção de objetos, a definição de verdadeiros negativos não é aplicável (Passos, 2019).

A precisão (*precision*) indica a proporção de verdadeiros positivos em relação ao total de detecções positivas do modelo:

$$Pr = \frac{TP}{TP+FP} \quad (2)$$

A revocação (*recall*), ou taxa de verdadeiros positivos, mede a capacidade do modelo de identificar todos os positivos existentes:

$$Rc = \frac{TP}{TP+FN} \quad (3)$$

O F1-Score combina precisão e revocação em uma única métrica, sendo igual a zero caso qualquer um dos dois componentes seja nulo, o que penaliza valores extremamente baixos de qualquer uma das medidas:

$$F_1 = 2 \frac{Pr \times Rc}{Pr + Rc} \quad (4)$$

3. METODOLOGIA

O trabalho foi desenvolvido em diferentes etapas, cada uma composta por diversos experimentos, cujos resultados permitiram a validação das técnicas aplicadas e da metodologia definida.

3.1. Detecção de Caixas D'água em Imagens

Para essa finalidade foi utilizada a função `imfindcircles` do MATLAB, aplicando-se previamente um pré-processamento das imagens para realçar as características circulares dos objetos de interesse, como conversão para escala de cinza, filtragem de suavização (por

exemplo, filtros Gaussianos) e realce de bordas (operadores de Sobel ou Canny). A aplicação direta da função em imagens em tons de cinza mostrou-se pouco eficiente na detecção das caixas d'água, além de computacionalmente custosa. Optou-se, então, por analisar o espectro de cores no espaço HSV (*hue, saturation, value*) correspondente aos objetos de interesse, tendo sido identificados 160 objetos com faixas de cores diferentes no conjunto de quadros analisados, com matiz variando de 0,1 a 0,6 e saturação de 0,35 a 0,92. Essas componentes foram utilizadas na construção de um filtro passa-faixa para transformar os quadros de vídeo em imagens monocromáticas, o que acelerou significativamente o processamento. Técnicas de suavização de bordas (erosão) e de remoção de áreas maiores e menores que os objetos de interesse foram também aplicadas antes da detecção de círculos.

Na etapa de detecção, os principais parâmetros definidos foram: raio mínimo e máximo dos círculos esperados, de acordo com os objetos observados nos quadros de vídeo; polaridade (*bright*), uma vez que as imagens monocromáticas apresentam círculos claros; e sensibilidade de 0,92, valor definido empiricamente para maximizar a detecção. A função *imfindcircles* retorna, para cada círculo detectado, as coordenadas do centro (*centers*), o raio (*radii*) e uma medida de confiança (*metrics*).

Na etapa de pós-processamento, a variável *metrics* foi utilizada para eliminar círculos sobrepostos e áreas de sombra erroneamente detectadas como objetos, causadas pela iluminação solar, por meio do seguinte algoritmo: (i) identificação de todos os círculos que se interceptam em um quadro, registrados em uma matriz V; (ii) eliminação da correspondência biunívoca entre pares já contabilizados; (iii) para círculos internos a um círculo de maior raio,

eliminação dos internos caso a magnitude do acumulador do maior seja superior; e (iv) para os demais pares que se interceptam, eliminação do círculo de menor magnitude de acumulador. Os resultados podem ser vistos na Figura 5. Ainda assim, em alguns casos a área de sombra de determinados objetos foi detectada como falso positivo, além disso, outros falsos positivos e falsos negativos foram tratados com a técnica de análise temporal ao longo dos diversos quadros de vídeo, onde a solução empregada foi a análise temporal ao longo dos quadros do vídeo, conforme discutido na Seção 3.3.

Figura 5. Eliminação de múltiplos objetos e áreas de sombra causados pela iluminação solar.



Fonte: O Autor (2025).

3.2. Detecção de Pneus em Imagens

A abordagem de pré-processamento utilizada para as caixas d'água mostrou-se ineficiente para a detecção de pneus, dado que esses objetos são consideravelmente menores e, com frequência, parcialmente encobertos pela vegetação. Optou-se, portanto, por um pré-processamento mais simples, restrito à conversão dos quadros para escala de cinza. Os objetos foram previamente

analisados quanto ao tamanho, considerando a diversidade de dimensões dos pneus e a altura de captura do drone; nos experimentos, foram analisados apenas os vídeos com altura de filmagem de 40 m, por apresentarem objetos de menor dimensão e, portanto, maior dificuldade de detecção.

Os parâmetros definidos para a detecção foram: raio do pneu entre 10 e 50 pixels, para vídeos a 40 m (contemplando pneus comuns e de caminhão); área entre 600 e 10.000 pixels, considerando a possibilidade de pneus adjacentes ou sobrepostos; sensibilidade do acumulador de 0,85; e limiar de borda de 0,3 — valores definidos de forma empírica. Assim como na detecção de caixas d'água, a função `imfindcircles` retornou os centros, raios e métricas de confiança dos objetos detectados.

No pós-processamento, a dificuldade principal consistiu em diferenciar pneus de outros objetos circulares presentes na imagem. Partiu-se da premissa de que pneus possuem uma abertura em seu centro, implementando-se o seguinte algoritmo: detecção de todos os objetos circulares dentro da faixa de raio correspondente a um pneu, considerando a altura do drone; extração da borda do pneu a partir de seu centro (estimada em 60% do raio); cálculo da média dos valores de pixel da borda e do centro, desprezando-se valores abaixo de um limiar correspondente a áreas de sombra; e, caso a razão entre a diferença média da borda e a área do centro ultrapasse uma tolerância definida, considera-se que há grande probabilidade de o objeto ser um pneu. A aplicação desse algoritmo eliminou os falsos positivos e permitiu a identificação correta dos pneus, conforme ilustrado na Figura 6.

Figura 6. Resultado da aplicação do algoritmo de detecção de pneus, com eliminação de falsos positivos.



Fonte: O Autor (2025).

3.3. Análise Temporal Como Estratégia Complementar de Redução de Falsos Positivos e Negativos

Como apontado na Seção 3.1, uma limitação da abordagem baseada exclusivamente na análise quadro a quadro é a ocorrência de falsos positivos (por exemplo, sombras confundidas com objetos de interesse) e de falsos negativos (por oclusões momentâneas, causadas pela vegetação ou pelo próprio movimento do drone). Como estratégia complementar ao pós-processamento descrito nas Seções 3.1 e 3.2, foi incorporada uma técnica de consistência temporal, que avalia a persistência de um objeto ao longo de uma sequência de quadros, em vez de decidir sua validade a partir de um único quadro isolado.

Para reduzir falsos positivos decorrentes de detecções isoladas ao longo da sequência de vídeo, foi empregado um mecanismo de votação majoritária temporal em janela deslizante (*sliding-window temporal majority voting*). Essa abordagem explora a redundância temporal existente entre quadros consecutivos, permitindo que decisões pontuais inconsistentes sejam filtradas por meio da análise

conjunta de uma sequência temporal (Chang et al., 2018). Neste trabalho, foi utilizada uma janela de 10 quadros consecutivos, sendo o objeto validado apenas quando sua detecção ocorreu na maioria dos quadros considerados. Dessa forma, detecções transitórias associadas a ruídos ou falsos positivos de curta duração tendem a ser rejeitadas.

4. RESULTADOS E DISCUSSÕES

O banco de dados utilizado (MBG) está disponível publicamente em (MBG, 2021), sendo composto atualmente por 13 sequências de vídeo adquiridas por uma plataforma de drones, gravadas em 11 locais diferentes.

A Tabela 1 mostra, uma parte da sequência de vídeo MBG, a quantidade de objetos de cada tipo e o número correspondente de caixas delimitadoras anotadas, para as classes de objetos em análise.

Tabela 1. Número de tipos de objetos anotados por vídeo MBG (rotulados como únicos), juntamente com o número correspondente de caixas delimitadoras anotadas.

Vídeo	Caixas d'água		Pneu	
10	exclusivo	bboxes	exclusivo	Bboxes
Total	312	25967	49	4390

Fonte: Adaptado de Passos (2022).

Foi realizado um experimento para avaliar a detecção automática de caixas-d'água e pneus em vídeos aéreos. Os vídeos foram decompostos em quadros individuais (*frames*), nos quais os objetos

de interesse foram identificados por meio de caixas delimitadoras (*bounding boxes*). O conjunto analisado continha 195 caixas-d'água e 28 pneus, correspondendo, respectivamente, a 490 e 1.950 ocorrências de *bounding boxes* ao longo dos diferentes quadros dos vídeos (para cada objeto foram utilizados 10 *bounding boxes*). A diferença entre o número de objetos e o número de caixas delimitadoras ocorre porque um mesmo objeto pode permanecer visível e ser anotado em vários quadros consecutivos.

Para verificar se uma detecção correspondia corretamente a um objeto anotado, utilizou-se a métrica *Intersection over Union* (IoU), adotando-se o limiar de 0,5. Dessa forma, uma detecção foi considerada verdadeiro positivo (TP) quando a sobreposição entre a caixa delimitadora prevista pelo modelo e a caixa de referência apresentou $\text{IoU} \geq 0,5$. As detecções que não alcançaram esse limiar, que indicaram objetos inexistentes ou que constituíram detecções duplicadas foram classificadas como falsos positivos (FP). Por sua vez, os objetos de referência não identificados pelo modelo foram contabilizados como falsos negativos (FN).

O desempenho do modelo foi avaliado por meio das métricas precisão, revocação e escore F_1 . A precisão representa a proporção de detecções realizadas pelo modelo que estavam corretas, enquanto a revocação indica a proporção dos objetos de referência que foram efetivamente detectados. O escore F_1 corresponde à média harmônica entre precisão e revocação, permitindo avaliar conjuntamente essas duas medidas.

A utilização de pós-processamento tratou múltiplas detecções e regiões de sombra. Os resultados podem ser vistos na Tabela 2.

Tabela 2. Resultados baseados em caixas delimitadoras, ao nível do frame, no conjunto analisado para as classes de objetos “caixa d’água” e “pneu”, considerando um limiar de IoU de $t=0,5$, após pós-processamento.

Caixas d’água					
TP	FP	FN	Pr	Rc	F_1
180	80	15	0,69	0,92	0,79

⚠ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em: <https://revistatopicos.com.br/artigos/deteccao-de-potenciais-criadouros-de-aedes-aegypti-em-imagens-aereas-por-meio-da-transformada-circular-de-hough?noblockage>

Fonte: O Autor (2025).

Esses resultados mostram que o modelo conseguiu localizar a maior parte das caixas-d’água presentes nas amostras avaliadas, como demonstra a elevada revocação. Entretanto, a precisão mais baixa revela a ocorrência de quantidade relevante de falsas detecções. Portanto, para essa classe, o principal ponto a ser aperfeiçoado é a redução dos falsos positivos, possivelmente por meio do ajuste do limiar de confiança, da inclusão de exemplos negativos no treinamento e da melhoria da diversidade das imagens utilizadas.

A utilização das componentes HSV permitiu restringir a busca a regiões compatíveis com os objetos de interesse e reduzir o custo da etapa de detecção circular.

Os resultados indicam que aproximadamente 71% das detecções classificadas como pneus estavam corretas e que o modelo conseguiu identificar cerca de 71% dos pneus presentes nas amostras avaliadas. Como os valores de precisão e revocação foram iguais, o escore (F_1) também atingiu 71,43%, demonstrando equilíbrio entre a capacidade do modelo de evitar falsas detecções e sua capacidade de localizar os objetos existentes.

Apesar do desempenho moderado, a ocorrência de oito falsos positivos e oito falsos negativos mostra que o modelo ainda apresenta limitações na detecção de pneus em imagens aéreas. Essas dificuldades podem estar relacionadas às pequenas dimensões dos objetos, à variação de escala, à resolução dos quadros, às oclusões e à semelhança visual dos pneus com outros elementos encontrados no ambiente.

O desempenho inferior pode estar relacionado às pequenas dimensões dos pneus nas imagens aéreas, à variação de escala, à oclusão, à semelhança visual com outros objetos e ao desequilíbrio entre as classes.

Ainda assim, a abordagem evidencia uma característica útil da Transformada de Hough Circular: a possibilidade de incorporar conhecimento geométrico sobre os objetos e restringir a detecção por raio, polaridade e características da borda. Em contrapartida, os resultados também mostram dependência do pré-processamento, da escala dos objetos e das condições de iluminação e oclusão

De modo geral, o modelo apresentou desempenho superior na detecção de caixas-d'água, especialmente em termos de revocação. Para os pneus, os valores de precisão, revocação e F_1 demonstram a

necessidade de aperfeiçoamento do conjunto de treinamento e do processo de detecção. A análise também evidencia que uma quantidade elevada de *bounding boxes* não garante, isoladamente, melhor desempenho, pois a diversidade das amostras, a qualidade das anotações e o número efetivo de objetos independentes exercem influência direta sobre a capacidade de generalização do modelo.

5. CONCLUSÃO

Os resultados obtidos mostram que a Transformada de Hough Circular consegue detectar corretamente a maior parte da classe caixa d'água presente nos quadros de vídeo analisados, respondendo ao objetivo proposto de utilizá-la como método auxiliar à detecção realizada pela arquitetura Faster R-CNN. Esse desempenho é evidenciado pela revocação de 0,92 e pelo score F_1 de 0,79 obtidos para essa classe, indicando que a maior parte dos objetos presentes no conjunto avaliado foi corretamente localizada, ainda que a precisão de 0,69 aponte para uma parcela relevante de falsos positivos a serem tratados em etapas futuras de refinamento do algoritmo. Contudo, a metodologia empregada para a detecção de pneus ainda carece de aprimoramentos para alcançar um melhor desempenho. Para essa classe, os valores de precisão, revocação e F_1 (0,71) foram inferiores aos obtidos para caixas d'água, refletindo as dificuldades relacionadas às pequenas dimensões dos pneus, à variação de escala e à sua semelhança visual com outros elementos do ambiente, além disso, a incorporação da técnica de janela deslizante, com o uso de 10 quadros consecutivos, mostrou-se uma estratégia complementar eficaz na detecção dos objetos de interesse após sua aplicação, o que reforça o potencial da análise temporal como mecanismo de reforço da robustez do sistema

diante de detecções isoladas e ruidosas. De modo geral, os resultados reforçam a viabilidade de empregar a Transformada de Hough Circular como método auxiliar de baixo custo computacional na detecção de objetos, contribuindo para tornar a análise de imagens aéreas mais ágil e para apoiar, de forma mais eficiente, as ações de vigilância e controle de vetores do mosquito *Aedes aegypti*.

REFERÊNCIAS BIBLIOGRÁFICAS

ATHERTON, T. J.; KERBYSON, D. J. Size invariant circle detection. *Image and Vision Computing*, v. 17, n. 11, p. 795-803, 1999. Disponível em: [https://doi.org/10.1016/S0262-8856\(98\)00160-7](https://doi.org/10.1016/S0262-8856(98)00160-7). Acesso em: 12 set. 2026.

BARRERA, R.; NAVARRO, J. C.; MORA RODRÍGUEZ, J. D.; DOMÍNGUEZ, D.; GONZÁLEZ, G. J. E. Public service deficiencies and *Aedes aegypti* breeding sites in Venezuela. *Bulletin of the Pan American Health Organization (PAHO)*, v. 29, n. 3, sept. 1995.

BRAVO, D. T.; LIMA, G. A.; ALVES, W. A. L.; COLOMBO, V. P.; DJOGBÉNOU, L.; PAMBOUKIAN, S. V. D.; QUARESMA, C. C.; ARAUJO, S. A. Automatic detection of potential mosquito breeding sites from aerial images acquired by unmanned aerial vehicles. *Computers, Environment and Urban Systems*, v. 90, p. 101692, 2021. Disponível em: <https://doi.org/10.1016/j.compenvurbsys.2021.101692>. Acesso em: 12 set. 2026.

CHANG, C.-Y. et al. Improvement of fall detection using consecutive-frame voting. In: 2018 International Workshop on Advanced Image Technology (IWAIT), Chiang Mai, 2018. IEEE, 2018. DOI: 10.1109/IWAIT.2018.8369696.

DAVIES, E. R. Machine vision: theory, algorithms, practicalities. 3. ed. [S.l.]: Morgan Kaufmann Publishers, 2005. Cap. 10.

DJI. Phantom 4 Pro specifications. 2021. Disponível em: <https://www.dji.com/phantom-4-pro>. Acesso em: 2 set. 2021.

DUDA, R. O.; HART, P. E. Use of the Hough transformation to detect lines and curves in pictures. Communications of the ACM, v. 15, n. 1, p. 11-15, 1972.

MBG. Mosquito Breeding Grounds Database. 2021. Disponível em: <https://www.smt.ufrj.br/~tvdigital/database/mosquito>. Acesso em: 12 set. 2026.

PASSOS, W. L. Automatic Aedes aegypti breeding grounds detection using computer vision techniques. 2019. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-graduação em Engenharia Elétrica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2019.

PASSOS, W. L.; ARAUJO, G. M.; LIMA, A. A. de; NETTO, S. L.; SILVA, E. A. B. da. Automatic detection of Aedes aegypti breeding grounds based on deep networks with spatio-temporal consistency. Computers, Environment and Urban Systems, v. 93, p. 101754, 2022. Disponível em: <https://doi.org/10.1016/j.compenvurbsys.2021.101754>. Acesso em: 12 set. 2026.

REN, S.; HE, K.; GIRSHICK, R.; SUN, J. Faster R-CNN: towards real-time object detection with region proposal networks. IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 39, n. 6, p. 1137-1149, 2017.

SEKACHEV, B.; MANOVICH, N.; ZHILTSOV, M.; ZHAVORONKOV, A.; KALININ, D. opencv/cvat v1.1.0. 2020. Disponível em: <https://doi.org/10.5281/zenodo.4009388>. Acesso em: 1 set. 2021.

TUN-LIN, W.; LENHART, A.; NAM, V. S.; REBOLLAR-TÉLLEZ, E.; MORRISON, A. C.; BARBAZAN, P.; COTE, M.; MIDEGA, J.; SANCHEZ, F.; MANRIQUE-SAIDE, P.; KROEGER, A.; NATHAN, M. B.; MEHEUS, F.; PETZOLD, M. Reducing costs and operational constraints of dengue vector control by targeting productive breeding places: a multi-country noninferiority cluster randomized trial. *Tropical Medicine & International Health*, v. 14, n. 9, p. 1143-1153, 2009.

UN-HABITAT. World cities report 2016: urbanization and development — emerging futures. [S.l.]: UN-Habitat, 2016. Disponível em: <https://unhabitat.org/world-cities-report>. Acesso em: 19 fev. 2021.

WHO – WORLD HEALTH ORGANIZATION. Keeping the vector out: housing improvements for vector control and sustainable development. 2017. Disponível em: https://www.who.int/social_determinants/publications/keeping-the-vector-out/en/. Acesso em: 19 fev. 2021.

YUEN, H. K.; PRINCEN, J.; ILLINGWORTH, J.; KITTLER, J. Comparative study of Hough transform methods for circle finding. *Image and Vision Computing*, v. 8, n. 1, p. 71-77, 1990. Disponível em: [https://doi.org/10.1016/0262-8856\(90\)90059-E](https://doi.org/10.1016/0262-8856(90)90059-E). Acesso em: 12 set. 2026.

ZHANG, Z. A flexible new technique for camera calibration. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 22, n. 11, p. 1330-1334, 2000.

¹ Doutor em Engenharia Elétrica. Professor Assistente da Universidade do Estado do Rio de Janeiro (UERJ). E-mail: [acesse o artigo original para visualizar o e-mail](#)

² Doutor em Engenharia Nuclear. Professor Assistente da Universidade do Estado do Rio de Janeiro (UERJ). E-mail: [acesse o artigo original para visualizar o e-mail](#)

³ Doutor em Engenharia Mecânica Computacional. Professor Assistente da Universidade do Estado do Rio de Janeiro (UERJ). E-mail: [acesse o artigo original para visualizar o e-mail](#)