

Acerca da Detecção Automática de Focos do Mosquito *Aedes aegypti*

Wesley L. Passos¹, Tayana M. Dias², Henrique M. Alves Junior², Bettina D. Barros¹, Gabriel M. Araujo², Amaro A. Lima², Eduardo A. B. da Silva¹, Sergio L. Netto¹.

Resumo— Todos os anos, milhares de pessoas são afetadas por doenças como dengue, chikungunya, zika e febre amarela. Todas essas doenças possuem um único vetor em comum, o mosquito *Aedes aegypti*, que se reproduz em água limpa e parada, usualmente acumulada em recipientes como pneus, garrafas, caixas d'água etc. O uso de ferramentas inteligentes pode auxiliar o trabalho dos agentes de fiscalização dos focos de mosquito, aumentando a eficiência e área de cobertura. Esse trabalho aborda o problema de detecção automática de focos de mosquitos baseado em técnicas de visão computacional e aprendizado de máquinas. Nesse contexto, descreve-se uma base de dados de sequências de vídeos aéreos, adquiridos com um veículo aéreo não tripulado, contendo alguns desses objetos em múltiplos cenários: diferentes localidades, altitudes e disposições dos objetos. Os vídeos são devidamente calibrados para amenizar distorções da câmera e manualmente anotados quadro a quadro, viabilizando o desenvolvimento de um detector automático de objetos de interesse.

Palavras-Chave— Imagens Aéreas, Visão Computacional, *Aedes aegypti*.

Abstract— Every year, thousands of people are contaminated with diseases such as dengue, chikungunya, zika, and yellow fever. These diseases have a common vector, the mosquito *Aedes aegypti*, which usually reproduces in containers with accumulated clean water, such as tires, bottles, water tanks, etc. The use of intelligent tools can be employed to assist health agents in a search for these objects, providing more efficiency and coverage in this process. This work addresses the problem for the automatic detection of such mosquito breeding grounds based on computer vision and machine learning techniques. In this manner, a database of aerial videos is devised including the objects of interest in different scenarios: different backgrounds, altitudes, object displacement, and so on. Videos are calibrated in order to compensate for camera distortions and manually annotated, in a frame-by-frame level, enabling one to develop an automatic detector for the target objects.

Keywords— Aerial Images, Computer Vision, *Aedes aegypti*.

I. INTRODUÇÃO

O mosquito *Aedes aegypti* é o principal vetor de diversas doenças, como dengue, zika, chikungunya e, mais recentemente no Brasil, a febre amarela urbana. A doença do vírus zika pode ser bastante perigosa para gestantes, pois há ligação com malformação congênita de bebês infectados. Já a dengue é a que causa mais mortes, com cerca de 390 milhões de infecções por ano no mundo [1]. A febre amarela também possui alto índice de letalidade e a chikungunya pode incapacitar os infectados por longos períodos de tempo.

¹PEE/COPPE/DEL/POLI, Universidade Federal do Rio de Janeiro, Cx. P. 68504, Rio de Janeiro, RJ, 21945-970, Brasil. ²Centro Federal de Educação Tecnológica, Nova Iguaçu, RJ, 26041-271, Brasil. E-mails: wesley.passos@smt.ufrj.br, {mtayanaa, henrique.menezesjr}@gmail.com, bettina.barros@smt.ufrj.br, {gabriel.araujo, amaro.lima}@cefet-rj.br, {sergioln, eduardo}@smt.ufrj.br.

Em 2012, a Organização Mundial da Saúde (OMS) lançou uma estratégia global para o controle e prevenção da dengue [2] em que uma das metas é reduzir em 25% os casos da doença até 2020. Mas, infelizmente, as ferramentas de combate ainda são muito limitadas: a vacina contra a dengue continua em fase de aprimoramento e os fumacês contra os mosquitos são ineficazes [3]. Sendo assim, a melhor forma de combate atual é através da fiscalização e eliminação de possíveis focos de proliferação do mosquito, que atua diretamente na prevenção de todas essas doenças. Uma vez que o *Aedes aegypti* se reproduz em água limpa e parada, os principais focos de mosquito são caixas d'água abertas, calhas, pneus, garrafas, vasos de planta e qualquer recipiente que possa acumular água. Em virtude disso, a fiscalização sem suporte de tecnologia é custosa, lenta e, conseqüentemente, ineficiente. Aliar o conhecimento do especialista com uma ferramenta que acelere e guie um trabalho mais acurado, se mostra de extrema importância no cenário atual.

Através de imagens e vídeos capturados por um veículo aéreo não-tripulado (VANT), mais conhecido como *drone*, com diversos sensores e câmeras, o objetivo é identificar regiões e objetos com alto potencial para compor um criadouro de mosquito. Existem organizações que fazem uso desse tipo de ferramenta para inspecionar terrenos e/ou locais de difícil acesso com o intuito de localizar potenciais criadouros. Nesse processo, os vídeos são examinados por um especialista em solo, o que torna o procedimento demorado e cansativo, podendo acarretar falhas. Técnicas de aprendizagem de máquina podem ser empregadas para automatizar esse tipo de análise e auxiliar a tomada de decisão do especialista [4]. Após essa análise, potenciais criadouros podem ser tratados ou removidos por uma equipe de agentes.

Sabe-se, por meio de um estudo local, que é possível identificar os recipientes de maior produtividade, e tratar apenas estes é quase tão efetivo quanto tratar todos os existentes [5], reduzindo drasticamente o potencial de desenvolvimento de epidemias. No caso de Nova Iguaçu, um município situado no estado do Rio de Janeiro, os reservatórios listados com alto potencial de emergência foram, de acordo com [6], caixas d'água, garrafas de vidro e plástico, baldes, pneus, ralos externos, entre outros. O objetivo, então, torna-se reconhecer automaticamente a maior quantidade possível desses objetos em um vídeo ou imagem para então fornecer uma ferramenta inteligente de auxílio à tomada de decisão para as equipes de solo, aumentando assim as suas área e capacidade de atuação.

O trabalho descrito nesse artigo possui 5 contribuições principais: i) Descrição do problema de detecção automática de focos de mosquitos a partir de vídeos provenientes de VANTS; ii) Revisão bibliográfica do tema, com o intuito de trazer à luz as diversas técnicas de aprendizagem de máquina que podem

ser empregadas na solução desse problema, conforme visto na Seção II; iii) Uma metodologia para calibrar a câmera de um VANT da marca DJI, modelo Phantom 2 plus, descrita na Seção III. iv) O projeto descrito na Seção IV de uma base de dados que contenha os principais focos do *Aedes aegypti* em diversos cenários; iv) O processo detalhado na Subseção IV.A de anotação manual dessa base de dados (uma base de dados anotada adequadamente é de fundamental importância para a utilização de uma ferramenta de aprendizagem supervisionada).

II. TRABALHOS RELACIONADOS

Sistemas de detecção de água baseados em imagens podem ser úteis para muitas aplicações [7], [8], [9], [10], [11], [12], [13].

O método em [7], por exemplo, usa um sistema de detecção de água para auxiliar na navegação de veículos autônomos *off-road*. O sistema é baseado em diversos tipos de características (incluindo textura e outras extraídas no espaço de cores HSV) e usa um par de câmeras para separar as regiões da imagem que possuem muita reflexão (regiões cuja profundidade é maior que a profundidade da vizinhança). Esse trabalho também apresenta uma regra de fusão para combinar essas características e segmentar a região de interesse contendo água.

Em [8] é possível encontrar uma metodologia para avaliar o desempenho de detectores de água utilizados por veículos não tripulados. Dois tipos de avaliações foram apresentadas: uma que avalia a interseção entre a região de saída dos detectores e o *ground truth* e outra que avalia a precisão do georreferenciamento. Os autores em [9] observaram que para detectar corpos de água, as reflexões do céu são mais úteis em imagens de objetos distantes da câmera. Em mais curto alcance, as cores possuem maior poder discriminativo.

Já em [10] é proposto um descritor de formas em imagens que é invariante a escala, rotação, transformações afins, espelhamento e distorções não rígidas, como o efeito de ondulação. O descritor é comparado quantitativamente e qualitativamente com métodos baseados na invariância ao espelhamento de formas, conseguindo obter os melhores desempenhos.

O trabalho em [11] realiza a detecção de água baseada na reflexão do céu e foi desenvolvido para ser aplicado em veículos terrestres não tripulados. Nesse trabalho, considera-se que corpos de água atuam como espelhos horizontais para grandes ângulos de incidência, de modo que o método proposto procura localizar geometricamente os pixels do céu que estão refletidos num candidato a corpo de água. Baseado na similaridade de cor e características locais do terreno, decide-se então se o candidato, dado que ele está abaixo da linha do horizonte, é realmente água ou não. Testes realizados em áreas rurais abertas com distâncias acima de 7 metros obtiveram 100% de verdadeiro positivos e um máximo de 0,58% de falso positivos para diferentes condições climáticas.

Uma outra forma de detecção de água em vídeos é através da segmentação de texturas dinâmicas [12]. Nesse trabalho, a técnica se propõe a remover a imagem de fundo estática e até objetos dinâmicos presentes na cena utilizando uma medida de entropia computada através fluxo óptico no decorrer de vários quadros para obter a assinatura de água. Para se detectarem as regiões sem movimento, é aplicado um método

de segmentação da imagem baseado na propagação de rótulos. A técnica foi validada em 12 vídeos com câmera estática e em movimento obtendo 95% de verdadeiros positivos e 10% de falsos positivos.

Em [13] apresenta-se uma nova técnica de reconhecimento de reflexão em água. Primeiramente, um novo espaço de características é construído usando momentos invariantes à distorção de movimento em espaço *curvelet* de baixas e altas frequências. Nesse novo espaço de características são aplicados os algoritmos de minimização de custo de reflexão em baixas frequências e discriminação de coeficientes *curvelets* em altas frequências, com o intuito de classificar as imagens de reflexão de água e detectar o eixo de reflexão, obtendo uma taxa de acerto de 80% a 95%.

No caso específico de detecção de focos de mosquito, destacam-se as referências [14], [15], [16]. Em [14] é proposto um sistema que recebe imagens com georreferenciamento geradas pela população, e avalia-se a qualidade das mesmas, a fim de rejeitar imagens com altos níveis de distorções ou artefatos. Cada imagem é convertida, então, em um vetor de características utilizando o modelo de *bag of visual words*, através do descritor SIFT (do inglês *scale-invariant feature transform*). Um classificador, então, do tipo *support-vector machine* (SVM) é treinado para identificar se as imagens possuem ou não potencial para serem um criadouro de mosquitos. Por fim, é gerado um mapa de calor, onde são apontadas as regiões com mais riscos de incidência de habitats do mosquito. Os autores de [15] utilizam uma abordagem para detecção de poças d'água em imagens obtidas por um quadricóptero com um classificador SVM treinado a partir de trechos de vídeos contendo ou não regiões com água. Imagens termais e em níveis de cinza são utilizadas para detectar água parada em [16]. Um vetor de 128 bits é extraído de cada imagem utilizando o descritor SURF (do inglês *speeded-up robust features*). Este vetor é então reduzido para 64 bits através da análise de componentes principais (PCA, do inglês *principal component analysis*) e um conjunto de classificadores do tipo *naive Bayes* é usado para identificar os possíveis focos de mosquitos.

III. CALIBRAÇÃO DE CÂMERA

A calibração de câmera é um processo importante para aplicações de visão computacional. Este passo é fundamental pois informações métricas tridimensionais (3D) podem ser extraídas a partir de imagens se a calibração for bem executada. É através da calibração que os parâmetros intrínsecos da câmera, como distância focal e ponto principal, são encontrados. Muitas técnicas de calibração têm sido desenvolvidas [17], [18], até mesmo para aplicações em fotometria [19], [20].

A principal motivação de utilizar a calibração neste trabalho foi a correção das distorções causadas pela lente da câmera, principalmente a distorção radial. Optou-se pelo método proposto em [21], por sua simplicidade e baixo custo. Esta técnica consiste em extrair pontos característicos (quinas) de imagens com um padrão de calibração, geralmente um tabuleiro de xadrez; estimar os parâmetros da câmera; estimar os coeficientes de distorção; e aplicar a correção.

A. Detecção de Pontos-Chave

Os métodos de Harris [22] e SIFT [23] são métodos clássicos para detecção de pontos-chave de uma imagem.

Entretanto, neste trabalho foi utilizado o método implementado pela função `findChessboardCorners` do OpenCV [24], por esse se mostrar mais robusto em imagens carregadas contendo artefatos oriundos de suavização. Inicialmente proposto por Vladimir Vezhnevets [25], esse método consiste em binarizar a imagem por um limiar, segmentando os quadrados pretos e brancos pertencente ao padrão de calibração. Encontram-se, então, as bordas dos quadrados pretos e aproximam-se esses contornos por quadriláteros, cujos vértices são selecionados e agrupados, em linha, de acordo com o tamanho do objeto de calibração.

Neste trabalho, utilizou-se um vídeo de calibração mostrando um padrão de 10×7 quadrados. A detecção foi realizada a cada 20 quadros desse vídeo. Antes de realizar a detecção, as imagens foram suavizadas, para atenuar ruído, utilizando um filtro gaussiano de tamanho 7×7 , média 0 e desvio padrão 1,4 em ambas as direções. As imagens foram também diminuídas em 40%, para reduzir o tempo de detecção.

B. Algoritmo de Zhang

Com os pontos-chave do padrão de calibração detectados, é possível estimar a matriz de projeção da câmera a partir das coordenadas desses pontos no mundo real e na imagem. Para tal, considera-se que uma câmera mapeia um ponto $\mathbf{M}' = [X, Y, Z, 1]^T$ do espaço no ponto $\mathbf{m}' = [u, v, 1]^T$ da imagem através de uma transformação projetiva da forma [26]

$$s\mathbf{m}' = \mathbf{A}[\mathbf{R} \mid \mathbf{t}]\mathbf{M}', \quad (1)$$

onde s é um fator de escala arbitrário, \mathbf{R} e \mathbf{t} são, respectivamente, a matriz de rotação e o vetor de translação (parâmetros extrínsecos), que relacionam o sistema de coordenadas do mundo real com o sistema de coordenadas da câmera. Nesse caso, \mathbf{A} é a matriz de calibração da câmera (parâmetros intrínsecos), definida por:

$$\mathbf{A} = \begin{bmatrix} \alpha & \gamma & u_0 \\ 0 & \beta & v_0 \\ 0 & 0 & 1 \end{bmatrix}, \quad (2)$$

com $[u_0, v_0]^T$ denotando as coordenadas do ponto principal, α e β os fatores de escala nos eixos u e v da imagem, respectivamente, e γ é a obliquidade (grau de cisalhamento) dos dois eixos da imagem.

Os parâmetros intrínsecos independem da imagem. Então, uma vez determinados, eles podem ser reutilizados para todos os vídeos adquiridos com um mesmo nível de (*zoom*).

1) *Compensação de Distorção Radial*: Câmeras convencionais geralmente possuem significantes distorções de lentes, especialmente distorção radial.

Sejam (u, v) as coordenadas ideais (livre de distorção) do pixel na imagem e (\check{u}, \check{v}) as coordenadas correspondentes reais de imagem observada. Os pontos ideais são as projeções dos pontos do padrão de calibração de acordo com o modelo dado pela Eq. (1). Analogamente, (x, y) e (\check{x}, \check{y}) são as coordenadas normalizadas nas imagens ideal (livre de distorção) e real (distorcida), respectivamente. A distorção radial pode ser modelada como [27]:

$$\check{x} = x + x(k_1 r^2 + k_2 r^4) \quad (3)$$

$$\check{y} = y + y(k_1 r^2 + k_2 r^4), \quad (4)$$

onde k_1 e k_2 são os coeficientes de distorção radial e $r^2 = (x^2 + y^2)$. Modelos mais complexos de distorção não apresentam resultados superiores significativos ou levam à instabilidade numérica [27]. O centro da distorção radial está localizado no ponto principal. De $\check{u} = \alpha\check{x} + \gamma\check{y} + u_0$ e $\check{v} = \beta\check{y} + v_0$, assumindo $\gamma = 0$, pode-se escrever que

$$\check{u} = u + (u - u_0)(k_1 r^2 + k_2 r^4) \quad (5)$$

$$\check{v} = v + (v - v_0)(k_1 r^2 + k_2 r^4). \quad (6)$$

O método de Zhang [21] consiste em fazer, primeiramente, uma estimativa grosseira dos parâmetros intrínsecos e extrínsecos da câmera para depois refiná-la através da estimativa da máxima verossimilhança. Dadas n imagens do padrão de calibração e considerando m pontos neste padrão, assumindo que as imagens dos pontos estão corrompidas por um ruído independente e identicamente distribuído, a estimativa de máxima verossimilhança pode ser obtida minimizando o funcional [27]

$$\sum_{i=1}^n \sum_{j=1}^m \|\mathbf{x}_{ij} - \check{\mathbf{x}}(\mathbf{A}, k_1, k_2, \mathbf{R}_i, \mathbf{t}_i, \mathbf{X}_j)\|^2, \quad (7)$$

onde $\check{\mathbf{x}}(\mathbf{A}, k_1, k_2, \mathbf{R}_i, \mathbf{t}_i, \mathbf{X}_j)$ é a projeção do ponto \mathbf{X}_j , de acordo com a Eq. (1), seguido da distorção modelada de acordo com as Eqs. (5) e (6). Minimizar o funcional em (7) é um problema de otimização não-linear que pode ser resolvido através do algoritmo de Levenberg-Marquardt.


A Fig. 1(a) mostra um exemplo de imagem original (com distorção) obtida, com as quinas detectadas sobrepostas, enquanto que a Fig. 1(b) mostra a imagem correspondente após a remoção da distorção. É interessante notar que o efeito “barril” foi eliminado na imagem, o que fica bastante claro no padrão quadriculado de calibração.

IV. PROJETO DE BASE DE DADOS


A base de dados utilizada no projeto de detecção automática de focos de mosquito está sendo adquirida por um Veículo Aéreo Não Tripulado (VANT) comercial, o Phantom Vision 2 Plus, da empresa DJI Company. Esse VANT possui 20 minutos de autonomia de voo e é capaz de executar um plano de voo previamente estabelecido de maneira automática. Toda a telemetria (altitude, latitude, longitude, velocidade etc.) pode ser recuperada em um arquivo .csv. O quadricóptero possui uma câmera de alta definição com estabilização passiva e ativa (amortecedores e *gimbal*). A câmera possui diversos parâmetros configuráveis e é capaz de filmar em 1080i na taxa de 60 Hz. Como a telemetria possui uma taxa de amostragem diferente da taxa de quadros da câmera, ou seja, é bem maior, uma decimação é empregada nos sinais obtidos através do arquivo .csv com o intuito de associar cada quadro do vídeo à sua respectiva telemetria.

A base projetada possui as seguintes características técnicas:

- Um plano de voo é pré-estabelecido com o auxílio do o auxílio do software Litchi [28]. Esse plano executa uma varredura em zigue-zague sobre toda a área terreno de maneira autônoma. Contudo, por conta da precisão limitada da telemetria e de situações não controladas, como o vento, o VANT não voa em linha reta no percurso entre dois pontos. Por essa mesma razão, uma vez que



(a)



(b)

Fig. 1: Exemplo de correção de distorção radial pelo algoritmo de Zhang: (a) imagem original distorcida com identificação das quinas detectadas no padrão de calibração; (b) imagem retificada.

o VANT alcança um ponto, algum tempo é perdido para que o mesmo se alinhe com a direção do próximo.

- O ajuste automático da câmera é desligado e todos os parâmetros são ajustados manualmente. O campo de visão (FOV, do inglês *field of view*) é diminuído para amenizar o efeito da distorção radial e o foco fixo. A varredura é ajustada para 1080p a 30 fps.
- Antes do voo automático, a câmera é calibrada com um padrão de calibração conforme descrito na Seção III.
- Altitude aproximadamente constante: atualmente, a base conta com varreduras em duas altitudes diferentes, 10 e 25 m, ambas pré-configuradas no plano de voo com o auxílio do Litchi. Pequenas variações de altitude causadas pela precisão limitada da telemetria, vento, etc. estão dentro das faixas aceitáveis.
- Velocidade aproximadamente constante de 7 km/h pré-configurada por intermédio do Litchi. Novamente, as variações são causadas pela precisão limitada do instrumento, vento e interferências de natureza desconhecida e situam-se dentro de limiares aceitáveis.
- A base de dados contempla ainda dois tipos de terreno: vegetação rasteira, para simular o ambiente de um terreno baldio, e asfalto, para simular ambiente urbano, conforme ilustrado na Fig. 2.
- Os vídeos possuem os seguintes objetos dispostos aleatoriamente pelo terreno: pneus, garrafas, objetos que podem acumular água tais como baldes e piscina plástica, conforme visualizado na Fig. 3.

- Após adquiridos, os vídeos são calibrados, conforme descrito na Seção III e manualmente anotados por intermédio do software Zframer, conforme descrito na Seção IV-A.

A base de dados gerada contém diversas sequências de vídeos aéreos mostrando pneus, poças, caixas d'água e diversos outros objetos com água. Atualmente, os vídeos foram adquiridos no Centro de Tecnologia da UFRJ, *campus* da Ilha do Fundão, e no *campus* de Nova Iguaçu do CEFET/RJ.

A. Anotação Manual da Base de Dados

O processo de anotação manual da base é realizado utilizando o *software* Zframer, desenvolvido no Laboratório de Sinais, Multimídia e Telecomunicações (SMT) da COPPE/UFRJ. A anotação quadro a quadro de todas as sequências adquiridas é feita com o sistema Zframer, conforme ilustrado na Fig. 4, pela equipe Bodetronic [29] de robótica do CEFET/RJ de Nova Iguaçu. Com o *software* de marcação é possível anotar os objetos que foram determinados como possíveis criadouros em cada quadro dos vídeos. O programa permite ainda uma interpolação entre um quadro inicial e final das áreas selecionadas, assim não é necessário que todos os quadros em que aparecem os objetos sejam marcados. O resultado é um arquivo contendo informações do quadro e as coordenadas pixel a pixel da *bounding box* do objeto marcado.

V. CONCLUSÕES

Este trabalho descreveu o problema de detecção automática, por técnicas de visão computacional, de focos de mosquito. Foi incluída, então, uma detalhada revisão bibliográfica de trabalhos similares que utilizam técnicas de aprendizado de máquina para este fim. Esse estudo apontou a necessidade da elaboração de uma base de dados própria para se atacar o problema, contendo vídeos com diversos recipientes que acumulam água limpa espalhados em diversos cenários. Para tal, considerou-se o uso de um VANT, que permite a aquisição de vídeos cobrindo de forma rápida uma extensa área geográfica. Antes de iniciar a gravação, os parâmetros da câmera são ajustados manualmente e um procedimento de calibração da mesma é realizado. Logo após, são traçados planos de voos pela área onde os objetos identificados estão localizados. Todos os vídeos são manualmente anotados com o auxílio do *software* livre Zframer, permitindo o treinamento de diferentes algoritmos detectores de objetos críticos para a aplicação de interesse.

REFERÊNCIAS

- [1] S. Bhatt, P. W. Gething, O. J. Brady, J. P. Messina, A. W. Farlow, C. L. Moyes, J. M. Drake, J. S. Brownstein, A. G. Hoen, O. Sankoh *et al.*, "The Global Distribution and Burden of Dengue," *Nature*, vol. 496, no. 7446, p. 504, 2013.
- [2] W. H. Organization *et al.*, "Global Strategy for Dengue Prevention and Control," *Geneva: World Health Organization*, 2012.
- [3] E. A. Newton and P. Reiter, "A Model of the Transmission of Dengue Fever with an Evaluation of the Impact of Ultra-Low Volume (ULV) Insecticide Applications on Dengue Epidemics," *The American Journal of Tropical Medicine and Hygiene*, vol. 47, no. 6, pp. 709–720, 1992.
- [4] G. S. Andrade, T. M. Dias, V. C. Alves, H. M. Alves Junior, L. M. Pinheiro, P. M. C. Silva, R. S. G. Pontes, B. P. Silva, I. B. O. de Macedo, G. M. Araujo, and T. M. Prego, "Fighting back zika, chikungunya and dengue: Detection of mosquito-breeding habitats using an unmanned aerial vehicle," *IEEE CAS Student Design Competition 2017–2018 Finalist project*, may 2018.



Fig. 2: Exemplos de cenários contemplados pela base de dados proposta.



Fig. 3: Exemplos de objetos contidos nos vídeos da base de dados proposta.




Fig. 4: Marcação de um quadro do vídeo utilizando o Zframer.

[5] W. Tun-Lin, A. Lenhart, V. S. Nam, E. Rebollar-Téllez, A. Morrison, P. Barbazan, M. Cote, J. Midega, F. Sanchez, P. Manrique-Saide *et al.*, “Reducing Costs and Operational Constraints of Dengue Vector Control by Targeting Productive Breeding Places: a Multi-Country Non-Inferiority Cluster Randomized Trial,” *Tropical Medicine & International Health*, vol. 14, no. 9, pp. 1143–1153, 2009.

[6] M. T. F. Lagrotta, “Geoprocessamento de Indicadores Entomológicos na Identificação de Áreas, Imóveis e Recipientes “Chaves” no Controle do Aedes Aegypti,” Dissertação de M. Sc., Fundação Oswaldo Cruz, 2006.

[7] A. L. Rankin, L. H. Matthies, and A. Huertas, “Daytime Water Detection by Fusing Multiple Cues for Autonomous Off-Road Navigation,” in *24th US Army Science Conference*. Orlando, FL, USA: WORLD SCIENTIFIC, nov 2006, pp. 177–184.

[8] A. Rankin, J. Tonislav Ivanov, and S. Brennan, “Evaluating the Performance of Unmanned Ground Vehicle Water Detection,” in *10th Performance Metrics for Intelligent Systems Workshop*. New York, NY, USA: ACM, 2010, pp. 305–311.

[9] A. Rankin and L. Matthies, “Daytime Water Detection Based on Color Variation,” in *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. Taipei, Taiwan: IEEE, oct 2010, pp. 215–221.

[10] H. Zhang, X. Guo, and X. Cao, “Water Reflection Detection Using a Flip Invariant Shape Detector,” in *20th IEEE International Conference on Pattern Recognition (ICPR)*. Istanbul, Turkey: IEEE, aug 2010, pp. 633–636.

[11] A. L. Rankin, L. H. Matthies, and P. Bellutta, “Daytime Water Detection Based on Sky Reflections,” in *IEEE International Conference on Robotics and Automation (ICRA)*. Shanghai, China: IEEE, may 2011, pp. 5329–5336.

[12] P. Santana, R. Mendonca, and J. Barata, “Water Detection with Segmentation Guided Dynamic Texture Recognition,” in *IEEE International Conference on Robotics and Biomimetics (ROBIO)*. Guangzhou, China: IEEE, dec 2012, pp. 1836–1841.

[13] S.-H. Zhong, Y. Liu, Y. Liu, and C.-S. Li, “Water Reflection Recognition Based on Motion Blur Invariant Moments in Curvelet Space,” *IEEE*

Transactions on Image Processing (TIP), vol. 22, no. 11, pp. 4301–4313, nov 2013.

[14] A. Agarwal, U. Chaudhuri, S. Chaudhuri, and G. Seetharaman, “Detection of Potential Mosquito Breeding Sites Based on Community Sourced Geotagged Images,” in *Geospatial InfoFusion and Video Analytics IV; and Motion Imagery for ISR and Situational Awareness II*, M. F. Pellechia, K. Palaniappan, S. L. Dockstader, P. J. Doucette, and D. Self, Eds., no. 3, jul 2014, p. 90890M.

[15] M. G. Prasad, A. Chakraborty, R. Chalasani, and S. Chandran, “Quadcopter-based Stagnant Water Identification,” in *5th IEEE National Conference on Computer Vision, Pattern Recognition, Image Processing and Graphics (NCVPRIPG)*. Patna, India: IEEE, dec 2015, pp. 1–4.

[16] M. Mehra, A. Bagri, X. Jiang, and J. Ortiz, “Image Analysis for Identifying Mosquito Breeding Grounds,” in *IEEE International Conference on Sensing, Communication and Networking (SECON Workshops)*. London, UK: IEEE, jun 2016, pp. 1–6.

[17] A. Geiger, F. Moosmann, O. Car, and B. Schuster, “Automatic Camera and Range Sensor Calibration Using a Single Shot,” in *IEEE International Conference on Robotics and Automation (ICRA)*. Saint Paul, MN, USA: IEEE, may 2012, pp. 3936–3943.

[18] W. Zhang, T. Jiang, and M. Han, “Digital Camera Calibration Method Based on PhotoModeler,” in *3rd IEEE International Congress on Image and Signal Processing (CISP)*. Yantai, China: IEEE, oct 2010, pp. 1235–1238.

[19] A. R. Yusoff, M. F. M. Ariff, K. M. Idris, Z. Majid, and A. K. Chong, “Camera Calibration Accuracy at Different UAV Flying Heights,” *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences (ISPRS)*, vol. XLII-2/W3, pp. 595–600, feb 2017.

[20] M. Pérez, F. Agüera, and F. Carvajal, “Digital Camera Calibration Using Images Taken from an Unmanned Aerial Vehicle,” *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences (ISPRS)*, vol. XXXVIII-1, no. C22, pp. 167–171, sep 2012.

[21] Z. Zhang, “A Flexible New Technique for Camera Calibration,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 22, no. 11, pp. 1330–1334, 2000.

[22] C. Harris and M. Stephens, “A Combined Corner and Edge Detector,” in *4th Alvey Vision Conference*, 1988, pp. 147–152.

[23] D. G. Lowe, “Distinctive Image Features from Scale-Invariant Keypoints,” *International Journal of Computer Vision*, vol. 60, no. 2, pp. 91–110, nov 2004.

[24] G. Bradski, “The OpenCV Library,” *Dr. Dobb’s Journal of Software Tools*, 2000.

[25] V. Vezhnevets, “OpenCV Calibration Object Detection,” <http://graphicon.ru/oldgr/en/research/calibration/opencv.html>, 2005.

[26] R. Hartley and A. Zisserman, *Multiple View Geometry in Computer Vision*, 2nd ed. Cambridge, Oxford, UK: Cambridge University Press, 2004.

[27] Z. Zhang, “A Flexible New Technique for Camera Calibration,” Microsoft Research, Redmond, WA, USA, Tech. Rep., 2008.

[28] VC Technology Ltd, “Litchi,” <https://flylitchi.com/>, 2018.

[29] Bodetronic, “Bodetronic – Equipe de robótica do CEFET,” <http://bodetronic.com/>, 2018.