

A Solution for Counting *Aedes aegypti* and *Aedes albopictus* Eggs in Paddles from Ovitrap Using Deep Learning

C. Santana, *Member, IEEE*, A. Firmo, R. Oliveira, P. Buarque, G. Alves, and R. Lima

Abstract—In 2018, the Epidemiological Record 36 of the World Health Organization (WHO) indicates that around 390 million people get infected from Arboviroses or mosquito-borne diseases. Among the transmission vectors of these diseases, the *Aedes aegypti* and *Aedes albopictus* are responsible for a considerable parcel of the infections since they can transmit a broad range of infections (e.g., dengue, yellow fever, and chikungunya). To reduce the number of infections and deaths caused by these mosquitoes, monitor and control the population of these insects is a key factor. In this sense, ovitraps can be employed to monitor the population of *Aedes* mosquitoes. Ovitrap is a dark container filled with water where a porous wooden paddle is inserted to serve as an oviposition substrate. These devices are installed in monitored areas and, periodically technicians collect them to count the number of eggs deposited in the paddles manually. Because the manual egg counting task can be time-consuming and susceptible to human errors, in this work we present a solution that uses deep learning algorithms to automate the counting process. Moreover, to further reduce the human effort in the counting process, hardware that automatically acquires the images of the wooden paddles is also presented. Experiments comparing the proposed solution, the manual counting method, and two other solutions, namely ICount and EggCounter, are performed. The results achieved indicate that the proposed method achieved a superior result than the two other methods. Moreover, the application of the Wilcoxon test with a confidence interval of 95% indicates that the solution presented can be as accurate as of the manual counting method which is currently adopted.

Index Terms—*Aedes aegypti*, *Aedes albopictus*, Ovitrap, Deep learning, Egg counting.

I. INTRODUÇÃO

RECENTES episódios de arboviroses demandam atenção de governos e pesquisadores de várias partes do mundo para a elaboração de métodos que possam ser empregados para prevenir ou reduzir o impacto dessas doenças. A Organização Mundial da Saúde (OMS) estima que cerca de 390 milhões de pessoas sejam infectadas por infecções transmitidas por mosquitos [1]. Por exemplo, em 2017 houve em torno de 220 mil casos confirmados e outros 580 mil suspeitas de infecção

por Zika Vírus (ZKV) em 52 países e territórios nas Américas [2]. O relatório parcial da Organização Pan-Americana de Saúde (APAS) aponta 2,8 milhões de casos confirmados de Dengue em 2019, sendo que destes, o Brasil responde por mais de 70% [3].

Além do ZKV e da Dengue, arboviroses como Chikungunya, Febre Amarela e Febre do Vale do Rift estão presentes em 146 países e territórios ao redor do globo e são transmitidas pelo *Aedes aegypti* e o *Aedes albopictus* [4]. Em outras palavras, em torno de 58% dos países e territórios apresentam casos de, no mínimo, uma dessas doenças. Além disso, em uma lista de 250 nações/territórios, 86% apresentam condições que permitem a instalação e proliferação dos mosquitos transmissores dessas infecções [4].

As arboviroses não só representam uma problema apenas para a saúde, mas também impactam a economia dos países. Em 2016, o governo brasileiro investiu em torno de US\$ 300 milhões em um programa de redução de infecções e mais de US\$ 20 milhões foram utilizados com inseticidas e larvicidas [5]. O custo estimado do tratamento da dengue no Brasil é de cerca de US\$ 169 milhões por ano [6]. Na Colômbia, os investimentos em metodologias para tratamento da Chikungunya foi estimado em cerca US\$ 73,6 milhões em 2014 [7]. Nas Filipinas, os custos médicos diretamente associados com Dengue foram de US\$ 345 milhões em 2015 [8].

Iniciativas e metodologias para combater os problemas provocados pelas infecções transmitidas por mosquitos foram apresentadas pela OMS e governos de países afetados e pesquisadores. Por exemplo, modelos de regressão e inteligência computacional têm sido empregados para prever epidemias de arboviroses e classificar áreas de risco [9]–[12]. O Programa Nacional de Controle da Dengue (PNCD) instaurado no Brasil é um exemplo de uma iniciativa para combater esses problemas. O PNCD argumenta que o controle de vetores de transmissão é a principal abordagem para prevenir e controlar epidemias transmitidas por mosquitos [13]. Diante disso, uma abordagem para monitorar a população de mosquitos é a adoção de armadilhas de oviposição (Ovitrapas). Essas armadilhas são compostas de um reservatório de água com uma palheta de madeira onde os mosquitos podem depositar seus ovos [13]. As ovitrapas são instaladas em diferentes pontos dentro de uma área monitorada e periodicamente são coletadas para se verifique o número de ovos nas palhetas.

A principal desvantagem desse método de monitoramento da população de mosquito é que, atualmente, o número de ovos

C. Santana, University of Exeter (UoE), Exeter, Devon, United Kingdom, e-mail: clodomir@ieee.org.

A. Firmo, Northeast Biotechnology Network (RENORBIO), Recife, PE, Brazil, e-mail: andre.caetano@pickcells.bio.

R. Oliveira, Polytechnic School of University of Pernambuco (POLI - UPE), Recife, PE, Brazil, e-mail: rodrigo@pickcells.bio.

P. Buarque, Polytechnic School of University of Pernambuco (POLI - UPE), Recife, PE, Brazil, e-mail: buarque.pedro@pickcells.bio.

G. Alves, Polytechnic School of University of Pernambuco (POLI - UPE), Recife, PE, Brazil, e-mail: gabriel.alves@pickcells.bio.

R. A. Lima, Polytechnic School of University of Pernambuco (POLI - UPE), Recife, PE, Brazil, e-mail: ricardo.lima@poli.br.

em cada palheta é contado manualmente por um profissional com auxílio de um microscópio. Considerando que dezenas de armadilhas podem ser usadas para monitorar uma área, essa atividade se torna cansativa e demorada. Outra desvantagem reside na possibilidade de introduzir erros e inconsistências na contagem de diferentes profissionais.

A literatura apresenta uma série de trabalhos que propõem soluções para o problema de contagem de ovos de *Aedes aegypti* e *Aedes albopictus* em imagens. O Em 2009, Mello et al. apresentaram uma solução automatizada para contagem de ovos de *Aedes aegypti* em palhetas de ovitrampas [14]. Nessa solução, o profissional utiliza uma câmera digital para obter imagens da palheta. Essas imagens são processadas por um programa de computador que executa uma sequência de técnicas de processamento de imagem para detectar e contar o número de ovos. O primeiro processamento realizado pelo programa é a conversão das imagens de RGB (vermelho, verde, azul) para o espaço de cores YIQ (*Luminance, In-phase, Quadrature*). Em seguida, o componente "I" é binarizado e passa por um algoritmo de componentes conectados e uma série de filtros de redução de ruído. Finalmente, usando a informação da área média de um ovo, o programa estima o número de ovos nas áreas apresentadas na imagem. Os autores realizaram vários experimentos mudando o método de estimativa da quantidade de ovos e, no melhor cenário, eles alcançaram uma taxa de acurácia média de 90%. A principal desvantagem dessa solução está relacionada aos ajustes necessários para obter resultados razoáveis com imagens. Nessa abordagem, fatores como distância entre a câmera e a palheta, ângulo de captura da imagem e seleção dos filtros apropriados podem interferir na performance do método. Além disso, as imagens são capturadas manualmente o que pode gerar uma variabilidade ainda maior nas características dessas imagens.

Uma solução totalmente automatizada foi apresentada em 2011 por da Silva et al. [15]. Essa solução é controlada por um microprocessador e é capaz de capturar as imagens das palhetas e, em seguida, as envia para um computador conectado via porta serial para que seja feita a detecção e contagem dos ovos nas imagens. O algoritmo de contagem de ovos proposto é baseado em filtros de segmentação de imagens e, mais uma vez, a estimativa do número de ovos foi baseada no tamanho médio de um ovo. Após a execução dos experimentos em uma base de dados contendo 100 imagens de palhetas de ovitrampas, o método proposto apresentou uma taxa de erro médio de 2,67%.

Gaburro et al. publicaram, em 2016, um artigo avaliando o desempenho da ferramenta de contagem de ovos de *Aedes aegypti* em imagens: O ICount [16]. Essa ferramenta usa filtros de tamanho e *thresholds* de preto e branco para detectar a presença de ovos nas imagens. O ICount também pode ser utilizada para estimar a densidade de larvas de *Aedes aegypti* em imagens. De acordo com os autores desse estudo, com a configuração adequada, essa ferramenta pode alcançar 98% de precisão. No entanto, vale ressaltar que a taxa de erro aumenta a medida que o a densidade de ovos nas imagens cresce. Por exemplo, para imagens com mais de 200 ovos, a taxa de erro sobe para 12%. Outro problema dessa ferramenta está

na necessidade de se ajustar vários parâmetros para alcançar resultados satisfatórios. Por fim, as imagens apresentadas no artigo apresentam um alto contraste entre a cor dos ovos e a cor do fundo. Em aplicações no mundo real dificilmente se obtém imagens com essas características pois as palhetas apresentam sujeira como areia, fragmentos de folhas secas e restos pequenos insetos mortos.

Em 2018, Yussouf et al. propuseram uma solução que emprega Gabor Wavelets para separar os ovos do fundo (palheta) das imagens [17]. O resultado dessa operação passa por um algoritmo de limiar global baseado no método de Otsu para binarizar a imagem. Em seguida, eles aplicam uma operação de dilatação e depois consideram o primeiro plano como a área que contém os ovos. A estimativa do número de ovos na imagem é realizada a partir da divisão da área do primeiro plano pelo tamanho médio do ovo (definido como 100 *pixels* nesse estudo). Para reduzir a ocorrência de falsos positivos, são desconsiderados todos objetos no primeiro plano que não possuam sua área descrita por uma elipse de excentricidade maior que 0,5. Os resultados de precisão foram de 99,9%, porém apenas 5 imagens foram utilizadas para teste e todas possuíam uma clara separação entre a cor do *background* e a cor dos ovos.

Analisando todas as soluções apresentadas nesta seção, nota-se que apenas uma automatiza completamente o processo de aquisição das imagens, o que é importante já que essa automação produz imagens com um padrão de aquisição e facilita a detecção de ovos. Outro ponto que vale a pena ser mencionado é que a maioria das técnicas descritas precisava ser ajustada manualmente para obter melhor desempenho. Isso aumenta o tempo necessário para a contagem dos ovos e a seleção inadequada de parâmetros afeta o desempenho da solução. Por fim, os experimentos de validação dessas soluções nem sempre refletem as condições encontradas em aplicações no mundo real. Essas condições resultam em complicações como: sobreposição e oclusão de ovos, imagens com *background* ruidosos e problemas de iluminação nas imagens que pode gerar sombras. Entretanto, ressaltam-se importâncias dos trabalhos listados nessa seção para o avanço das técnicas de detecção em objetos em imagens.

Neste trabalho, apresentamos uma solução baseada em redes neurais de aprendizado profundo para contagem de ovos de *Aedes aegypti* e *Aedes albopictus* em palhetas de ovitrampas. Esta solução é composta de hardware que possui uma câmera (microscópio digital) para capturar imagens da palheta, um módulo de inteligência artificial que identifica e quantifica os ovos nas imagens, e uma aplicação web para exibir os relatórios das contagens efetuadas. Além de automatizar todo o processo de contagem de ovos, a solução proposta não possui parâmetros que precisam ser ajustados a cada nova leitura. Destaca-se ainda que os testes para validação foram realizadas com palhetas cujas características condizem com as condições do mundo real.

O restante do artigo está organizado da seguinte forma: a Seção II apresenta a solução proposta; Experimentos e Resultados são apresentados na Seção III, e a Seção IV apresenta as conclusões e os direcionamentos futuros deste trabalho.

II. MATERIAIS E MÉTODOS

Nesta seção, descrevemos a solução desenvolvida para escanear as palhetas de ovitrampas, identificar e contabilizar o número de ovos nas imagens obtidas e, por fim, reportar os resultados para o usuário. Dividimos a descrição em três subseções dedicadas a explicar cada uma desses itens.

A. Esquema para Obtenção de Imagens

Para automatizar o processo de aquisição de imagens, foi desenvolvido um hardware que funciona como um *scanner* 2D. Esse dispositivo se possui câmera (microscópio) para capturar as imagens das palhetas, circuito de controle e uma bandeja onde as palhetas das ovitrampa são colocadas. A bandeja se move no eixo Y, ao passo que o microscópio tem movimento no eixo X. Toda a movimentação é coordenada pelo circuito de controle. Tendo em vista que a palheta é feita de um material com pouca variação na espessura, nessa aplicação, não foi necessário incluir movimento no eixo Z.

Para obter as imagens, selecionamos um microscópio digital de baixo custo com zoom óptico de 500x, interface USB e um mecanismo de foco manual que pode ser usado quando necessário. Ele foi selecionado devido a qualidade das imagens produzidas e a possibilidade de ser controlado usando a interface USB. Além disso, esta câmera também possui uma iluminação embutida que ajuda a obter imagens com qualidade satisfatória mesmo em ambientes mal iluminados.

A câmera produz imagens com uma resolução de 2 megapixels as salva em formato JPEG. Ela possui 8 LEDs para iluminação com ajuste de brilho e é alimentada com 5 volts via conexão USB 2.0. Essa câmera possui um formato cilíndrico com 125 milímetros de altura e 33 milímetros de diâmetro. Após a realização de testes prévios, foi determinado que o valor de brilho a ser usado seria entorno de 50% e a câmera deve ser fixada a uma distância de 12 milímetros da palheta.

A movimentação dos eixos é realizada com o uso de dois motores de passo de 5V com torque de 34,3 mN.m e redução de 1/64. A definição da ferramenta responsável por coordenar os motores e controlar a câmera foi feita após experimentos com duas plataformas: Arduíno [18] e Raspberry Pi [19]. Embora o Arduíno seja uma solução financeiramente mais acessível e com potencial para aplicação em vários problemas do mundo real [20]–[22], selecionamos o Raspberry Pi 3 para controlar o nosso dispositivo devido à sua superior capacidade de processamento, quantidade de bibliotecas disponíveis, diversas interfaces de comunicação integradas (Bluetooth, Wi-Fi, USB e Ethernet) e as opções de armazenamento de dados (RAM e cartão SD).

O projeto da estrutura do dispositivo foi realizado com o auxílio de uma ferramenta de CAD 3D (*Computer Aided Design*). Dentre as especificações adotadas estão restrições de peso e tamanho para que o protótipo seja ser leve, compacto e de fácil transporte. A Figura 1 ilustra o projeto final da solução proposta.

Para capturar as imagens das palhetas foi adotado o movimento em zigue-zague como ilustrado na Figura 2. A palheta foi dividida em 182 seções com 10% sobreposição entre




Fig. 1. Visão projeto 3D do dispositivo para a leitura das palhetas de ovitrampas.

cada uma delas e, para cada seção, o dispositivo captura uma imagem. O código de controle foi desenvolvido com a linguagem de programação Python [23].




Fig. 2. Caminho seguido pela câmera durante a aquisição de imagens das palhetas.

B. Metodologia para Contagem de Ovos

A definição da metodologia de contagem dos ovos do *Aedes* foi realizada após uma revisão da literatura para identificar as técnicas existentes. O resultado da revisão indica a existência de três tipos principais de soluções aplicáveis nesse problema: aplicação de algoritmos de processamento digital de imagem (PDI) padrão e soluções híbridas de PDI com outras técnicas (e.g., redes neurais e técnicas de agrupamento).

Como o problema de contagem de ovos em imagens de ovitrampas pode ser modelado como um problema de detecção de objetos (localização e classificação dos objetos em imagens) [24], nota-se que nessa área técnicas baseadas em Redes Neurais Profundas (RNP) constituem o estado-da-arte. Por exemplo, algoritmos de detecção de objetos foram empregados com sucesso no exame de sedimentos de urina [25] e na detecção da esquistossomose mansônica em imagens de testes parasitológicos [26].

Dentre as várias RNPs presentes na literatura, a *Region-based Fully Convolutional Networks* (R-FCN) foi a selecionada nesse trabalho. Um dos motivos para a escolha desse modelo está relacionado com o custo computacional reduzido quando comparado à outros modelos similares [27]. Além do mais, em trabalhos anteriores a R-FCN apresentou resultados competitivos com outras técnicas de detecção de objetos [27]–[30].

A rede selecionada foi implementada usando a API para detecção de objetos do Tensorflow [31]. Para treinar as redes,

foi utilizado um conjunto de 984 imagens coletadas usando o dispositivo desenvolvido. As imagens foram anotadas manualmente usando uma ferramenta de rotulagem e 80% delas foram usadas para treinar as redes enquanto que os 20% restantes foram empregados para testá-las. A divisão 80/20 foi adotada baseada em recomendações de trabalhos presentes na literatura [32]–[34].

Os experimentos foram realizados em uma máquina com processador Intel Broadwell 2.7GHz, GPU Nvidia K80 com 12 GB de RAM rodando Linux Ubuntu OS e os parâmetros da R-FCN estão descritos na Tabela I e foram baseados nos valores recomendados em [31].

TABELA I
PARÂMETROS USADOS NO TREINO DA R-FCN

Parâmetro	Valor
Num. de Classes	1 (Ovo)
Modelo Base	rfcn_resnet101
Extrator de Características	faster_rcnn_resnet101
Função de Ativação	SOFTMAX
<i>Batch Size</i>	1
<i>Learning Rate</i>	0,0003
<i>Momentum</i>	0,9
Modelo Pré-treinado	R-FCN MS COCO

Em relação a morfologia dos ovos do *Aedes*, de acordo os estudos realizados por Pombo [35], os ovos possuem coloração preta ou castanha e, embora haja pequenas variações nas dimensões em diferentes estudos e regiões, todos os ovos tem comprimento inferior a 1 milímetro. A Tabela II apresenta a caracterização morfológica do ovo realizada em [35].

TABELA II
CARACTERÍSTICAS MORFOLÓGICAS DOS OVOS DO *Aedes*

Atributo	Média	Valor Máximo	Valor Mínimo
Comprimento	581,45 ± 39,73µm	655,20µm	521,40µm
Largura	175,36 ± 11,59µm	199,60µm	156,50µm
Diâmetro	18,75 ± 1,92µm	22,18µm	14,27µm

Os ovos desse mosquito possuem alta capacidade de fixação em diversas superfícies. O local escolhido pelo mosquito fêmea para fazer a oviposição também varia de acordo com a espécie do mosquito. Existem outras diferenças relativas, por exemplo, à presença de rugosidades na casca dos ovos, porém, com o nível de ampliação da câmera utilizada nesse estudo, essas diferenças são imperceptíveis.

C. Interface Gráfica

Um dos requisitos adotados no desenvolvimento da solução é que ela deveria ser fácil de utilizar e apresentar os resultados de forma amigável ao usuário. Para cumprir esse objetivo, desenvolvemos uma aplicação web baseada em Django [36] e React Native [37] que é responsável por exibir os resultados das leituras, permitir que o usuário ajuste as marcações e apresente o histórico de leitura de palhetas. Para isso, foi desenvolvido um servidor web para hospedar esta aplicação e receber as imagens obtidas com o dispositivo.

Embora a Raspberry Pi tenha uma capacidade de processamento razoável, ela não foi capaz de executar a tarefa de controlar os motores, o microscópio digital e executar os modelos de detecção de objetos. Por essa razão, foi realizada a transferência da funcionalidade de contagem de ovos para o servidor da web. Feito isso, todas as operações de processamento das imagens (incluindo a contagem de ovos) é realizado em um serviço de computação em nuvem. Essa mudança concentra as informações em uma aplicação que pode ser acessada por qualquer dispositivo com acesso à internet. A Figura 3 resume a arquitetura completa da solução proposta.




Fig. 3. Arquitetura da solução proposta.

III. RESULTADOS E DISCUSSÃO

Esta seção discute os resultados obtidos durante o desenvolvimento, teste e validação da solução proposta.

Para construir o dispositivo de leitura das palhetas, o projeto 3D apresentado na Seção II foi exportado, impresso em uma impressora 3D e o protótipo final da solução proposta pode ser visto na Figura 4. As dimensões finais do dispositivo montado são: 13,7 cm de largura, 17,1 cm de altura e 31,7 cm de comprimento com a gaveta para a palheta completamente estendida (17,7 cm com a gaveta fechada).




Fig. 4. Vistas do dispositivo construído.

Para validar o dispositivo, bem como a integração com o servidor e a aplicação web, foi realizado um teste inicial com 10 palhetas obtidas em parceria com o Centro de Vigilância Ambiental (CVA) da prefeitura da cidade do Recife-PE, Brasil. A Figura 5 ilustra exemplos de imagens digitalizadas com o dispositivo. Vale a pena ressaltar que a diferença na cor do *background* das imagens se deve ao envelhecimento do material das palhetas. Além disso, a qualidade das imagens permite que os profissionais as inspecionem na tela de um computador e consigam fazer as marcações. Ou seja, o *hardware* desenvolvido apresenta potencial para substituir o microscópio usado pelos profissionais para auxiliar nas marcações.

O modelo treinado da R-FCN no conjunto de 787 imagens foi testado usando as 197 imagens restantes. Como resultado,




Fig. 5. Exemplos de imagens de palhetas capturadas pelo dispositivo desenvolvido.

a R-FCN alcançou 91% de precisão na classificação dos ovos. Destaca-se que esses resultados podem ser melhorados aumentando o número de imagens na base de treino da rede neural. Em outras palavras, o desempenho da solução proposta melhora à medida que mais palhetas são lidas, marcadas e adicionadas ao conjunto de treino. A Figura 6 apresenta o desempenho da detecção em dois cenários diferentes (pouco e muito ruído).




Fig. 6. Exemplos de marcações realizadas pela R-FCN em que os retângulos vermelhos representam os ovos detectados.

A solução proposta também foi comparada com duas outras aplicações de contagem de ovos: EggCounter [17] e ICount [38]. Para isso, foram selecionadas 15 novas imagens que não foram no treino da R-FCN. Antes da execução desses experimentos, outras 5 imagens foram usadas para ajustar os parâmetros da EggCounter e do ICount para que se obtivesse melhores resultados. Os parâmetros adotados para a ICount foram: 36,64 de limiar Preto/Branco, área mínima de caixa de 300 pixels e máxima de caixa de 900 pixels. Para o EggCounter os valores foram: sensibilidade de detecção de ovos de 46 e sensibilidade de partículas de ovos de 45.

Os resultados de comparação são apresentados na Tabela III. O cálculo do erro foi feito utilizando a Equação 1

$$ErroMedio = \frac{1}{N} \sum_{n=1}^N \left| \frac{Real - Estimado}{Real} \right| \quad (1)$$

Em que *Estimado* representa o número de ovos estimado por um dado método de contagem, *Real* é o número correto de ovos existentes na imagem e *N* corresponde ao número de imagens utilizadas. Como pode ser notado, os resultados alcançados indicam a superioridade do R-FCN quando comparados para os outros dois métodos. Além disso, a R-FCN foi a técnica que obteve a menor taxa de erro médio (maior estabilidade).

TABELA III
COMPARAÇÃO DOS RESULTADOS OBTIDOS PELA R-FCN, EGGCOUNTER E ICount

Imagem	Número Real	R-FCN	EggCounter	ICount
Img 1	3	3	1	3
Img 2	4	4	0	3
Img 3	11	10	0	9
Img 4	11	11	0	9
Img 5	10	8	0	8
Img 6	9	7	4	7
Img 7	11	11	4	10
Img 8	5	5	0	5
Img 9	6	5	1	6
Img 10	6	6	0	4
Img 11	5	5	1	5
Img 12	5	5	1	4
Img 13	11	10	0	8
Img 14	8	8	10	6
Img 15	4	4	1	4
Erro Médio	–	0,051	0,816	0,145
STD	–	± 0,079	± 0,223	± 0,114

A diferença de performance do EggCounter e ICount em relação ao seu trabalho original pode estar relacionado com o tipo de imagens usado para testar essas ferramentas. Analisando a Figura 7 (a) e (b), imagens usadas para testar as duas ferramentas, nota-se que elas são muito diferentes das imagens das palhetas usadas nesse trabalho (7 (d)). Nesses trabalhos, a cor do substrato de oviposição contrasta com a cor dos ovos e a uniformidade do fundo também facilita a identificação e contagens dos ovos.




Fig. 7. Comparação de um exemplo de imagem presente na base do trabalho atual com imagens de outros trabalhos na literatura. (a) e (b) presentes em [17] e [16], (c) usada em [39] e [15] e (d) neste trabalho.

O segundo grupo de experimentos foi realizado com a colaboração dos profissionais do Centro de Vigilância Ambiental da Prefeitura de Recife. 20 palhetas adicionais foram selecionadas e o número de ovos nelas foi contabilizado manualmente por um funcionário do CVA. Em seguida, a solução proposta foi usada para contar o número de ovos nas mesmas palhetas. Os resultados deste experimento são apresentados na Tabela IV.

TABELA IV
COMPARAÇÃO DOS RESULTADOS OBTIDOS PELA R-FCN E A CONTAGEM MANUAL DE 8 PALHETAS

Palheta	Contagem Manual	R-FCN
Palheta 1	214	174
Palheta 2	46	56
Palheta 3	33	34
Palheta 4	39	32
Palheta 5	68	78
Palheta 6	200	216
Palheta 7	282	196
Palheta 8	107	91
Erro Médio	–	0.161
STD	–	± 0.078

A aplicação do teste não paramétrico de Wilcoxon [40] nas populações dos dois métodos comparados (Manual e R-FCN), com nível de significância de 5%, não indica diferença estatística entre as amostras ($p\text{-value}=0.53$ e $\text{valor}=13.5$). Esse resultado pode ser interpretado como um indício de que, apesar das diferenças entre a metodologia manual e a proposta, a contagem realizada pela R-FCN apresenta características semelhantes a contagem manual. Como pode ser visto na Figura 9, a curva da solução proposta é semelhante a curva da contagem manual. Além disso, a análise das imagens que levaram à diferença de desempenho entre os métodos avaliados revela que a rede neural apresentou dificuldade nas imagens em que havia sobreposição dos ovos. Além disso, quando os ovos são esmagados ou parcialmente cobertos de sujeira, a R-FCN também apresenta problemas de detecção. Todavia, ressalta-se que os profissionais também têm dificuldades nesses cenários e, nesses casos, recorrem à opinião de seus colegas ou tentam remover a poeira da palheta.

O tempo de leitura de uma palheta é de aproximadamente 2 minutos, porém analisando-se as imagens captadas, nota-se que, na maioria das palhetas utilizadas nesse estudo, certas áreas não continham ovos. Para verificar essa hipótese, foi elaborado o mapa de calor ilustrado pela Figura 8. Nele é possível ver que as regiões próximas ao início e final das palhetas apresentam uma baixa concentração de ovos.




Fig. 8. Mapa de calor médio resultante do mapeamento de 26 palhetas.

Após a realização de testes removendo imagens das seções com baixa densidade de ovos nas palhetas, foi observado que removendo 42% das seções menos densas e aplicando uma correção baseada em uma de erro fixa, é possível obter uma acurácia muito semelhante à alcançada com 100% das imagens (Figura 9). Essa redução no número de imagens obtidas, representa não só uma redução no tempo total de leitura da palheta, mas também uma redução nos custos de armazenamento e processamento das imagens.

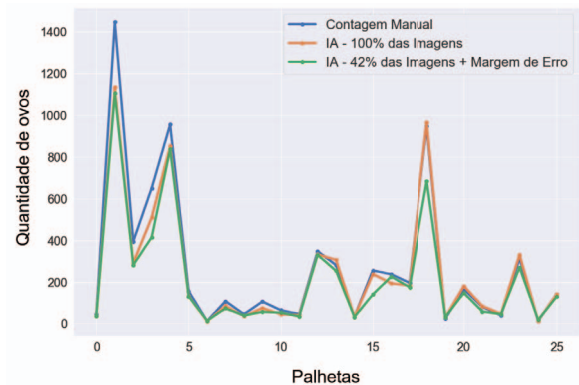


Fig. 9. Comparação da contagem manual com a contagem usando IA com 100% das imagens de uma palheta e a IA com 42% das imagens capturadas das palhetas.

Em relação à aplicação web, a Figura 10 ilustra funcionalidade de visualização dos detalhes de uma realizada. Observe que esta solução pode ser integrada aos sistemas utilizados pelo governo local e federal para monitorar as estatísticas de *Aedes aegypti* e *Aedes albopictus*.

IV. CONCLUSÃO

O uso de ovitrampas pode colaborar para a redução do número de infecções e prevenção de epidemias de arboviroses. Neste trabalho, apresenta-se uma solução para automação do processo de contagem de ovos de *Aedes aegypti* e *Aedes albopictus* em palhetas usadas em ovitrampas. A solução proposta captura automaticamente imagens das palhetas e usa inteligência computacional para detectar e contar a quantidade de ovos nas imagens.

Os experimentos realizados comparando a solução proposta com outras duas ferramentas que contabilizam, indicam a superioridade da solução proposta. Além disso, comparada com o método de contagem manual, a solução apresentada a conseguiu obter resultados semelhantes. Vale a pena salientar que, ao contrário das outras técnicas presentes na literatura, a metodologia proposta não necessita de ajuste paramétricos antes das leituras.

Embora a acurácia média de 91% alcançada pela R-FCN possa ser considerada satisfatória, ainda há espaço para melhorias. Em cenários em que há sobreposição ou oclusão de ovos, a rede apresenta uma queda na performance. Além disso, as redes de aprendizado profundo precisam de uma quantidade grande de imagens para poder aprender os padrões com uma taxa de acurácia satisfatória. Como trabalhos futuros, sugere-se melhorar o desempenho da solução em cenários em que

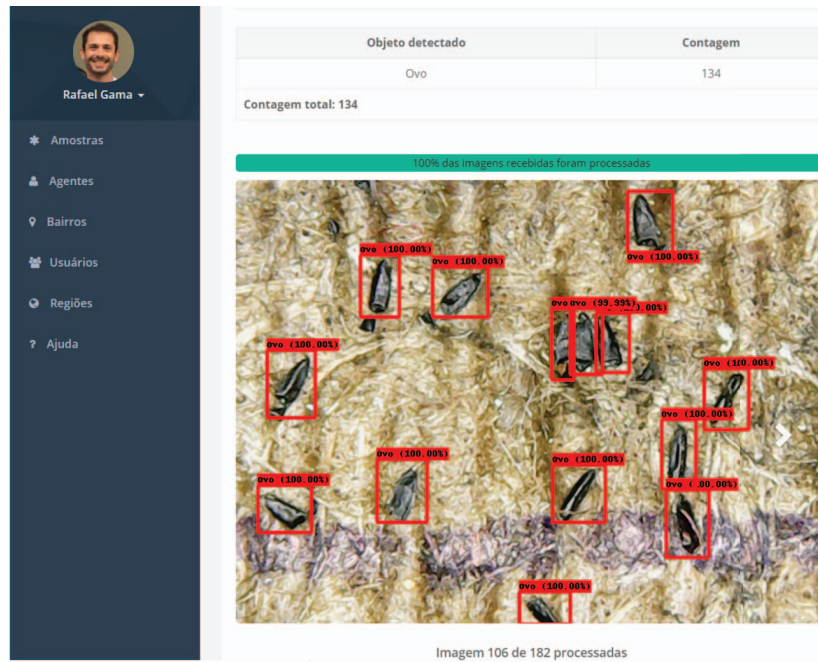


Fig. 10. Tela de visualização dos detalhes de uma leitura na plataforma web desenvolvida.

há sobreposição de ovos, conduzir experimentos com outras técnicas de detecção de objetos e tentar melhorar a performance da R-FCN com ajustes paramétricos ou estratégias de transferência de aprendizado.

AGRADECIMENTOS

Agradecemos à empresa Pickcells pelo apoio financeiro para o desenvolvimento desse trabalho e à Prefeitura do Recife, por meio da Empresa Municipal de Informática (Emprel), pela colaboração para o teste e validação da solução proposta.

REFERÊNCIAS

- [1] W. H. Organization *et al.*, “Dengue vaccine: Who position paper—september 2018,” *Wkly Epidemiol Rec*, vol. 93, pp. 457–476, 2018.
- [2] T. C. Pierson and M. S. Diamond, “The emergence of zika virus and its new clinical syndromes,” *Nature*, vol. 560, no. 7720, pp. 573–581, 2018.
- [3] P. H. I. P. for the Americas. Paho/who data - dengue cases 2019. [Online]. Available: <http://www.paho.org/data/index.php/en/mnu-topics/indicadores-dengue-en/dengue-nacional-en/252-dengue-pais-ano-en.html>
- [4] S. Leta, T. J. Beyene, E. M. De Clercq, K. Amenu, M. U. Kraemer, and C. W. Revie, “Global risk mapping for major diseases transmitted by aedes aegypti and aedes albopictus,” *International Journal of Infectious Diseases*, vol. 67, pp. 25–35, 2018.
- [5] V. Teich, R. Arinelli, and L. Fahham, “Aedes aegypti e sociedade: o impacto econômico das arboviroses no brasil,” *JBES: Brazilian Journal of Health Economics/Jornal Brasileiro de Economia da Saúde*, vol. 9, no. 3, 2017.
- [6] I. P. Godói, L. V. D. da Silva, A. R. Sarkar, I. Megiddo, A. Morton, B. Godman, M. Bennie, and A. A. G. Júnior, “Economic and epidemiological impact of dengue illness in brazil,” in *HTAi Cologne, Germany*, 2019.
- [7] J. A. Cardona-Ospina, W. E. Villamil-Gomez, C. E. Jimenez-Canizales, D. M. Castaneda-Hernandez, and A. J. Rodriguez-Morales, “Estimating the burden of disease and the economic cost attributable to chikungunya, colombia, 2014,” *Transactions of The Royal Society of Tropical Medicine and Hygiene*, vol. 109, no. 12, pp. 793–802, 2015.
- [8] L. D. Pham, N. H. T. Phung, N. T. D. Le, and T. Q. Vo, “Economic report on the cost of dengue fever in vietnam: case of a provincial hospital,” *ClinicoEconomics and outcomes research: CEOR*, vol. 9, p. 1, 2017.
- [9] M. W. Moreira, J. J. Rodrigues, F. H. Carvalho, J. Al-Muhtadi, S. Kozlov, and R. A. Rabêlo, “Classification of risk areas using a bootstrap-aggregated ensemble approach for reducing zika virus infection in pregnant women,” *Pattern Recognition Letters*, vol. 125, pp. 289–294, 2019.
- [10] J. P. Messina, O. J. Brady, N. Golding, M. U. Kraemer, G. W. Wint, S. E. Ray, D. M. Pigott, F. M. Shearer, K. Johnson, L. Earl *et al.*, “The current and future global distribution and population at risk of dengue,” *Nature microbiology*, p. 1, 2019.
- [11] M. Akhtar, M. U. Kraemer, and L. M. Gardner, “A dynamic neural network model for predicting risk of zika in real-time,” *bioRxiv*, p. 466581, 2019.
- [12] T. Chakraborty, S. Chattopadhyay, and I. Ghosh, “Forecasting dengue epidemics using a hybrid methodology,” *Physica A: Statistical Mechanics and its Applications*, vol. 527, p. 121266, 2019.
- [13] L. Santos França, C. M. Alves de Macedo, S. N. Sales Vieira, A. Teixeira Santos, G. de Jesus Cruz Sanches, J. Melo Silva, M. Bahiense Almeida, and R. de Barros Silva, “Challenges for the control and prevention of the aedes aegypti mosquito,” *Journal of Nursing UFPE/Revista de Enfermagem UFPE*, vol. 11, no. 12, 2017.
- [14] C. A. Mello, W. P. dos Santos, M. A. Rodrigues, A. L. B. Candeias, C. M. Gusmao, and N. M. Portela, “Automatic counting of aedes aegypti eggs in images of ovitraps,” in *Recent Advances in Biomedical Engineering*. IntechOpen, 2009, pp. 211–221.
- [15] M. da Silva, M. Rodrigues, and R. De Araujo, “Aedes aegypti egg counting system,” in *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE, 2011, pp. 6810–6812.
- [16] J. Gaburro, J.-B. Duchemin, P. N. Paradkar, S. Nahavandi, and A. Bhatti, “Assessment of icount software, a precise and fast egg counting tool for the mosquito vector aedes aegypti,” *Parasites & vectors*, vol. 9, no. 1, p. 590, 2016.
- [17] W. N. J. H. Wan Yussof, M. Man, M. S. Hitam, A. A. K. A. Hamid, E. A. Awalludin, and W. A. W. A. Bakar, “Wavelet-based auto-counting tool of aedes eggs,” in *Proceedings of the 2018 International Conference on Sensors, Signal and Image Processing*. ACM, 2018, pp. 56–59.
- [18] M. Banzi and M. Shiloh, *Getting started with Arduino: the open source electronics prototyping platform*. Maker Media, Inc., 2014.
- [19] L. F. D. Haro, R. Cordoba, J. I. R. Rivero, J. D. de la Fuente, D. A. Peces, and J. M. B. Mera, “Low-cost speaker and language recognition

- systems running on a raspberry pi," *IEEE Latin America Transactions*, vol. 12, no. 4, pp. 755–763, 2014.
- [20] M. S. Perez and E. Carrera, "Time synchronization in arduino-based wireless sensor networks," *IEEE Latin America Transactions*, vol. 13, no. 2, pp. 455–461, 2015.
- [21] V. Vimos and E. J. S. Cabrera, "Results of the implementation of a sensor network based on arduino devices and multiplatform applications using the standard opc ua," *IEEE Latin America Transactions*, vol. 16, no. 9, pp. 2496–2502, 2018.
- [22] F. J. Jimenez, F. R. Lara, and M. D. Redel, "Api for communication between labview and arduino uno," *IEEE Latin America Transactions*, vol. 12, no. 6, pp. 971–976, 2014.
- [23] T. E. Oliphant, "Python for scientific computing," *Computing in Science & Engineering*, vol. 9, no. 3, pp. 10–20, 2007.
- [24] J. G. A. Barbedo, "A review on methods for automatic counting of objects in digital images," *IEEE Latin America Transactions*, vol. 10, no. 5, pp. 2112–2124, 2012.
- [25] Y. Liang, Z. Tang, M. Yan, and J. Liu, "Object detection based on deep learning for urine sediment examination," *Biocybernetics and Biomedical Engineering*, vol. 38, no. 3, pp. 661–670, 2018.
- [26] R. F. de Oliveira, M. S. Ferro, B. J. Fernandes, and C. J. Bastos-Filho, "Avaliando técnicas de aprendizado profundo para detecção de esquistossomose mansoni em imagens de exames parasitológicos," vol. 23. Brazilian Congress on Computational Intelligence, Niteroi, RJ Brazil, 2017, pp. 1–12.
- [27] J. Dai, Y. Li, K. He, and J. Sun, "R-fcn: Object detection via region-based fully convolutional networks," in *Advances in neural information processing systems*, 2016, pp. 379–387.
- [28] Z. Li, Y. Chen, G. Yu, and Y. Deng, "R-fcn++: Towards accurate region-based fully convolutional networks for object detection," in *Thirty-Second AAAI Conference on Artificial Intelligence*, 2018.
- [29] J. Si, J. Lin, F. Jiang, and R. Shen, "Hand-raising gesture detection in real classrooms using improved r-fcn," *Neurocomputing*, 2019.
- [30] Q. Liang, L. Mei, W. Wu, W. Sun, Y. Wang, and D. Zhang, "Automatic basketball detection in sport video based on r-fcn and soft-nms," in *Proceedings of the 2019 4th International Conference on Automation, Control and Robotics Engineering*. ACM, 2019, p. 9.
- [31] J. Huang, V. Rathod, D. Chow, C. Sun, M. Zhu, A. Fathi, and Z. Lu, "Tensorflow object detection api," *Code: github.com/tensorflow/models/tree/master/object_detection*, 2017.
- [32] S. P. Mohanty, D. P. Hughes, and M. Salathé, "Using deep learning for image-based plant disease detection," *Frontiers in plant science*, vol. 7, p. 1419, 2016.
- [33] W. A. Hussien, Y. M. Tashtoush, M. Al-Ayyoub, and M. N. Al-Kabi, "Are emoticons good enough to train emotion classifiers of arabic tweets?" in *2016 7th International Conference on Computer Science and Information Technology (CSIT)*. IEEE, 2016, pp. 1–6.
- [34] K. Polat, B. Akdemir, and S. Güneş, "Computer aided diagnosis of eeg data on the least square support vector machine," *Digital Signal Processing*, vol. 18, no. 1, pp. 25–32, 2008.
- [35] A. P. M. M. Pombo, "Aedes aegypti: Morfologia, morfometria do ovo, desenvolvimento embrionário e aspectos relacionados à vigilância entomológica no município de são paulo," Ph.D. dissertation, Universidade de São Paulo.
- [36] J. Forcier, P. Bissex, and W. J. Chun, *Python web development with Django*. Addison-Wesley Professional, 2008.
- [37] B. Eisenman, *Learning react native: building native mobile apps with javascript*. O'Reilly Media, Inc., 2015.
- [38] J. W. Mains, D. R. Mercer, and S. L. Dobson, "Digital image analysis to estimate numbers of aedes eggs oviposited in containers," *Journal of the American Mosquito Control Association*, vol. 24, no. 4, p. 496, 2008.
- [39] C. A. Mello, W. P. Dos Santos, M. A. Rodrigues, A. L. B. Candeias, and C. M. Gusmao, "Image segmentation of ovitraps for automatic counting of aedes aegypti eggs," in *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE, 2008, pp. 3103–3106.
- [40] E. Fix and J. Hodges Jr, "Significance probabilities of the wilcoxon test," *The Annals of Mathematical Statistics*, pp. 301–312, 1955.




Clodomir Joaquim de Santana Junior é bacharel em Engenharia da Computação pela Escola Politécnica da Universidade de Pernambuco (POLI-UPE) e mestre em Engenharia de Sistemas também pela Escola Politécnica da Universidade de Pernambuco. Atualmente, ele é doutorando em Ciências da Computação na Universidade de Exeter no Reino Unido. Dentre as principais áreas de interesse estão: meta-heurísticas bio-inspiradas, enxames de robótica, técnicas de clusterização, otimização multiobjetivo, redes complexas e redes neurais.



André Caetano Alves Firmo é doutor em Biotecnologia pelo Renorbio, arquiteto de TI no Tribunal de Justiça de Pernambuco, Prof. de pós graduação, Cientista Chefe e Co-fundador da Pickcells. Atua também com Bioinformática e Biotecnologia aplicada a saúde pública, atuando principalmente nos seguintes temas: hardware, Inteligência Computacional, Bioinformática e Processamento de Imagens médicas.



Rodrigo Felipe Albuquerque Paiva de Oliveira possui graduação em em Licenciatura em Computação pela Universidade Federal Rural de Pernambuco (UFRPE) e mestrado em Engenharia da Computação pela Universidade de Pernambuco (UPE). Tem experiência na área de Ciência da Computação, com ênfase em Segurança da Informação, Engenharia de Software, Computação Inteligente, Machine Learning e Visão Computacional.



Pedro José Buarque Lins recebeu o título de bacharel em Engenharia de Computação pela Universidade de Pernambuco em 2017. Participou do programa Ciência Sem Fronteiras na Universidade de Washington em St. Louis. Atualmente está matriculado no programa de mestrado em Engenharia da Computação, também da Universidade de Pernambuco. Seus interesses de pesquisa estão relacionados à mineração de dados e aprendizado de máquina.



Gabriel Alves de Lima é Engenheiro de Computação formado pela Universidade de Pernambuco (UPE) com forte conhecimento técnico baseado em experiências práticas. Possui formação profissional como engenheiro de software e desenvolvedor trabalhando com equipes ágeis e autogerenciadas. Além disso, tem conhecimento de aprendizado de máquina aplica a problemas complexos do mundo real



Ricardo Ataíde de Lima nasceu em Recife, no Brasil, em 1983. Ele é Bacharel em Engenharia Eletrônica, mestrado e doutorado em Engenharia Elétrica pela Universidade Federal de Pernambuco (UFPE) em 2008, 2010 e 2015, respectivamente. É membro permanente do corpo docente do Departamento de Engenharia Elétrica da Universidade de Pernambuco (UPE), Recife, Brasil. Suas atividades de pesquisa incluem sensores ópticos para aplicações no setor elétrico e instrumentação embarcada para caracterização de impedância de biossensores. O Sr.

Lima é membro do Grupo de Sistemas e Electromagnetismo Aplicado do Departamento de Engenharia Elétrica da UPE e desenvolve atividades de pesquisa e ensino nas áreas de teoria e aplicações eletromagnéticas.