

CONTAGEM AUTOMÁTICA DE OVOS DO AEDES AEGYPTI EM PALHETAS DE OVITRAMPAS: UM SISTEMA PARA AQUISIÇÃO E PROCESSAMENTO DE IMAGENS

Carlos Diego Franco da Rocha (1); Ayla Márcia Cordeiro Bizerra(2); Demetrios Araújo Magalhães Coutinho(3); Luiz Fernando Virginio da Silva(4); Michel Santana de Deus(5).

Instituto Federal do Rio Grande do Norte - Campus Pau dos Ferros, carlos-dhyego@hotmail.com

INTRODUÇÃO

A dengue é uma doença endêmica, transmitida pelo mosquito *Aedes aegypti* sendo um dos principais problemas de saúde pública no país e mais comum no mundo. Esse mosquito, tem-se mostrado nos últimos anos resistente à diferentes formas de combate químico, o que faz com que seus índices de infestação aumentem. Além disso, também se mostrou eficaz na transmissão de outras doenças como Zika e Chicungunya, que inclusive têm levado à óbito àqueles infectados, especialmente na região do Nordeste do Brasil.

A vigilância entomológica desempenha papel decisivo na avaliação do impacto das medidas de controle sobre a população do inseto vetor e no seu redirecionamento. Em 2002 foi implantado o Plano de Intensificação das Ações de Controle da Dengue (PIACD) que inseriu medidas com relação ao monitoramento constante e medidas de controle evitando o desencadeamento de novas epidemias. Uma das maneiras de monitorar o mosquito é por meio do uso da ovitrampa, uma armadilha segura e barata, que pode ser facilmente instalada em qualquer local (DONALÍSIO e GLASSER, 2002).

Entretanto, essa técnica apresenta desvantagens, e a principal delas está na maneira como são contados os ovos do mosquito: a fêmea coloca os ovos, as palhetas são recolhidas e a contagem é feita em laboratório especializado de maneira manual, através de um microscópio ou lupa. Além disso, a forma de contabilizar os ovos - um a um e por um técnico especializado na área - torna o processo de contagem lento e passível a erros, levando ao acúmulo de palhetas e conseqüentemente, com o tempo, os ovos passam a se desprender da palheta (DA SILVA, 2012). Diante deste problema, se faz necessário uso de tecnologias que possibilitem uma melhoria para o sistema de contagem, com conseqüente diminuição de erros humanos e atribuição de falsos índices.

De acordo com Feigenbaum (1981, apud, FERNANDES, 2003) inteligência artificial é a parte da ciência da computação voltada para o desenvolvimento de sistemas de computadores inteligentes, ou seja, sistemas que exibem características, as quais se relacionam com a inteligência no comportamento do homem. Pode-se citar como exemplo: compreensão da linguagem, aprendizado, raciocínio, resolução do problema.

O principal objetivo do Haar Cascade é otimizar o reconhecimento de objetos, fazendo com que seus estágios iniciais descartem uma grande quantidade de regiões que contém o objeto desejado, e estágios mais avançados sejam cada vez mais precisos para evitar um falso positivo na região analisada. É possível encontrar na literatura trabalhos que desenvolveram classificadores Haar para reconhecimento de rostos. (LIENHART et al, 2003; WILSON e FERNANDEZ, 2006).

Nota-se, portanto, que o uso de ovitrampas é eficaz no combate ao mosquito bem como uma excelente ferramenta para identificação de índices de infestação. Em virtude de sua eficácia, se faz necessário o aperfeiçoamento da técnica de contagem dos ovos, que atualmente é feito todo de forma manual. Para isso, apresenta-se uma proposta de tornar esse processo mais eficaz automatizando essa contagem a partir do processamento das imagens obtidas das palhetas.

METODOLOGIA

Esse trabalho é composto por um equipamento eletrônico responsável por adquirir as imagens da palheta e o algoritmo de processamento de imagem para realizar a contagem. O equipamento eletrônico tem como finalidade automatizar a captura da imagem por meio de uma aparelhagem eletrônica e controlar a luminosidade para obter mais eficiência no processamento da imagem. Todo o controle interno é feito por meio de um microcomputador *Raspberry*, o qual também executa o algoritmo de contagem de ovos.

Equipamento para obtenção de imagens em ambiente controlado

O equipamento proposto para a captura de imagens neste trabalho consiste em uma caixa composta por dispositivos eletrônicos capazes de manter o ambiente propício para a segunda etapa do processo de contagem de ovos. A caixa foi confeccionada em madeira MDF, e sua base estrutural de alumínio 3mm. Suas medidas são: 15cm de altura por 15cm de largura e 19cm de comprimento. No interior da caixa, um micro controlador *Raspberry Pi 2* se encarrega de processar o algoritmo.

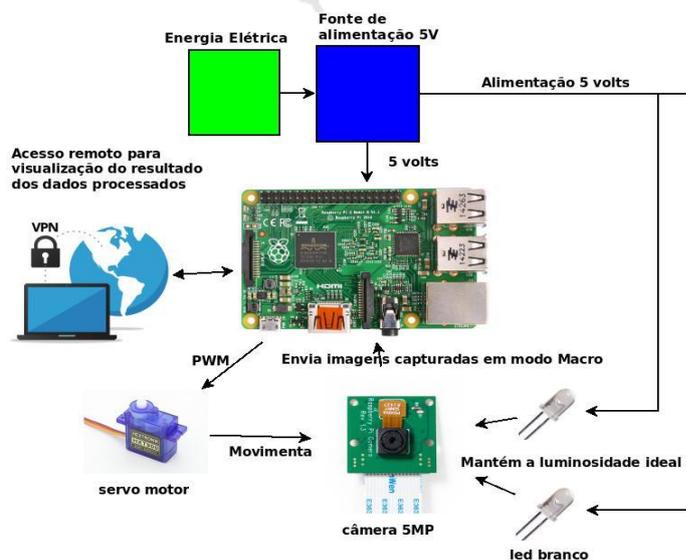


Figura 1 - Diagrama de funcionamento do hardware



Figura 2 - Caixa para captura de imagens

A caixa possui uma luminosidade controlada por LEDs super brancos que estão distribuídos de forma circular ao redor da lente da câmera. A proposta das lâmpadas de LED é combinar a iluminação natural com o fluxo luminoso constante, contribuindo assim, para um ambiente favorável para a captura das imagens.

A câmera utilizada para capturar as imagens é capaz de fornecer uma imagem de resolução de 5MP ou gravação de vídeo HD 1080p a 30fps. Instalada a 4 centímetros da palheta, a câmera foi

ajustada para o modo super macro a fim de capturar uma imagem de qualidade. A área de captura da câmera é de 2,5cm de comprimento por 2,5cm de largura.

Para movimentar a câmera foi instalado um Micro Servo Tower Pro 9g SG90. O servo motor é um dispositivo eletromecânico que pode ter seu eixo posicionado em uma determinada posição angular, permitindo o posicionamento preciso de seu eixo. Nas engrenagens do motor existe um limitador que atua no giro do eixo, fazendo com que ele rotacione entre 0° e 180°. Para utilizar o motor com o eixo girando em 360°, o servo motor foi modificado, retirando seu limitador, isso permite que o mesmo possa atuar com giro contínuo para controlar a velocidade e distância que a câmera percorre a palheta para capturar as imagens.

A movimentação do eixo é determinada pela duração da largura de pulso, sendo gerada pelo módulo PWM (*Pulse Width Modulation*) do *Raspberry Pi*. A vantagem de utilizar o controle por modulação no servo motor é poder controlar a velocidade que a câmera atingirá ao percorrer toda a extensão da palheta, adaptando-a nitidez da qualidade obtida.

O acesso ao dispositivo é realizado através de acesso remoto utilizando uma VPN (*Virtual Personal Network*). Sua principal característica é trafegar os dados criptografados através de “túneis virtuais” que interligam as redes. Este meio de comunicação faz com que a caixa não se limite a cabos conectados a ela, como exemplo, cabo HDMI ou RJ45, tornando-a independente e de fácil manuseio. A caixa é alimentada por duas fontes, uma fonte chaveada AC/DC de 5 volts e 3 amperes, com plug de 3,5 de espessura que servirá para ligar os LEDs e o servo motor. E outra de 5 volts e 1 ampere com plug usb para alimentar somente a raspberry e a câmera.

Contagem automática por meio de processamento de imagens

Para realizar a contagem de ovos, aplicamos técnicas de processamento de imagens e aprendizado de máquina nas imagens obtidas pelo equipamento eletrônico descrito na seção 2.1. No pré-processamento, utilizamos o filtro *high-boost* dada a necessidade de melhorar a detecção de bordas e detalhes finos nas imagens. As técnicas utilizadas para detecção são baseadas no algoritmo proposto por Viola-Jones (2001) que utiliza uma abordagem de reconhecimento de padrões a partir de imagens. Esta técnica foi utilizada por Kasinski (2010), Padilla, Costa Filho e Costa (2012), para o reconhecimento facial, e por Reinius (2013) para o reconhecimento de objetos usando dispositivos móveis. O *Haar Cascade* (VIOLA e JONES, 2001), que pode ser encontrado na biblioteca OpenCV, é um algoritmo de aprendizado baseado em AdaBoost, que seleciona um pequeno número de características visuais críticas de uma determinada imagem, comparando amostras positivas e negativas, e as utiliza para a etapa de detecção e classificação de objetos. A principal característica da cascata de classificadores é fazer com que seus estágios iniciais descartem uma grande quantidade de regiões que não contém o objeto desejado, e deixem o trabalho mais simples para classificadores presentes em estágios mais avançados, aumentando sua eficiência, rapidez e precisão. As etapas do processo de contagem estão representadas no diagrama apresentado na Figura 3.



Figura 3 - Processo de contagem automática

Descrito por Viola e Jones (2001) como uma árvore degenerativa de decisão (*decision stump*), o *Haar Cascade* contém um encadeamento de classificadores do mais genérico ao mais específico, segundo o qual os primeiros níveis da cascata são menos precisos, apesar de conseguir

classificar uma grande quantidade de amostras com uma pequena quantidade de características. No decorrer do processo, assumindo que uma amostra foi classificada como positiva, esta sub-região da imagem é submetida aos classificadores em estágios seguintes, descartando-se regiões classificadas como negativa. O algoritmo AdaBoost é utilizado neste processo para aumentar a eficácia e precisão do classificador utilizado na cascata, utilizamos árvore de decisão como nosso classificador. Este classificador é utilizado tanto para selecionar as características quanto para classificar áreas da imagem como positivas ou negativas.

O trabalho com o classificador envolve duas etapas: treinamento e detecção. Para a etapa de treinamento do *Haar Cascade*, produzimos amostras positivas, que contém o objeto de interesse, e amostras negativas, que não devem conter este objeto. Separamos palhetas que foram colhidas em campo em dois grupos: treinamento e testes. Para o grupo de treinamento, extraímos manualmente pequenas imagens que continham ovos para gerar as amostras positivas, totalizando 20 imagens positivas medindo 92x92 *pixels*. Em seguida criamos, sinteticamente, 35 amostras geradas a partir da rotação, em passos de 10°, das amostras originais, totalizando 720 amostras positivas, algumas destas amostras são apresentadas na Figura 4.



Figura 4 – Pre-processamento de imagens rotacionando em 10 graus.

O conjunto de amostras negativas contém 1440 imagens geradas a partir de regiões das palhetas que não continham ovos. As amostras negativas também passaram pelo processo de pré-processamento para não evidenciar grandes diferenças entre estas e as positivas.

Para a etapa de treinamento utilizamos um computador com a seguinte configuração: processador AMD A10 com 16gb de memória RAM, que dispõe de 6 núcleos para processamento de imagens e 4 para processamento geral.

Os parâmetros adquiridos na fase de treinamento, número de classificadores e características relevantes para a detecção do objeto, foram salvos em um arquivo xml. A fase de treinamento é caracterizada por uma longa demora devido à natureza do próprio treinamento. Uma vez que os classificadores foram treinados, a etapa de detecção se dá de maneira rápida e eficiente com custo computacional mínimo, motivo pelo qual viabilizou o uso do *Raspberry Pi*. Nesta etapa, a caixa captura uma sequência de fotos da palheta, formando uma imagem única. Por fim, o algoritmo faz a busca nessa imagem por regiões que têm as características obtidas no treinamento e retorna à quantidade de objetos detectados por cada palheta escaneada.

RESULTADOS E DISCUSSÕES

Na fase de testes utilizamos uma palheta para a validação dos resultados. Foi feita a contagem dessa palheta usando um microscópio binocular, encontrando 26 ovos. Como observa-se na Figura 5, os quadros verdes são as marcações de ovos encontrados. De 26 ovos contidos na palheta o sistema de reconhecimento e contagem conseguiu contabilizar 14 e identificou alguns falsos positivos.

Outro ponto que pode se destacar é a sobreposição dos ovos, quando há ovos bem próximos ou até por cima do outro, o algoritmo detecta como somente um ovo. Como resultado da contagem, nestes testes iniciais, obtivemos taxa de *recall* de cerca de 60%.

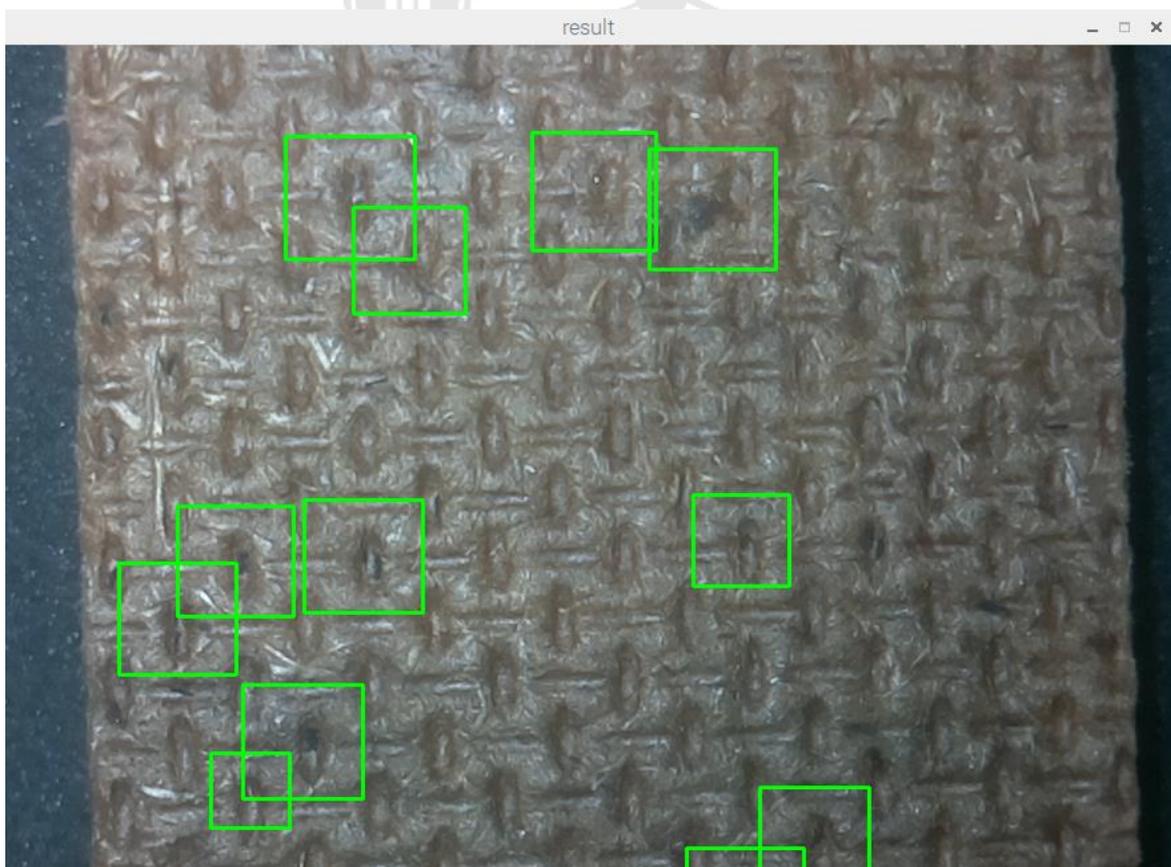


Figura 5 - Imagem do sistema de reconhecimento e contagem de ovos.

CONSIDERAÇÕES FINAIS

Embora o sistema tenha mostrado resultados positivos, algumas melhorias fazem parte das próximas etapas do deste projeto de pesquisa como: a instalação de mais LEDs no interior da caixa, e a aquisição de uma câmera de 8 megapixel, melhorando a qualidade de captura das imagens, a fim de aprimorar os resultados e torná-lo mais robusto a falhas. Na fase de reconhecimento, por exemplo, a utilização de mais critérios de seleção dos objetos poderia aumentar o poder de classificação do algoritmo, e assim garantir que somente ovos fossem reconhecidos.

Outro ponto a ser explorado, é incrementar o número de amostras para melhorar o método de contagem, já na fase de pré-processamento, testar outro filtro de imagem afim de destacar as

regiões da borda. A implementação dessas e outras melhorias a serem incorporadas ao sistema fazem parte dos trabalhos futuros a serem realizados.

REFERÊNCIAS

DA SILVA, M. G. N. M.; RODRIGUES, M. A. B.; DE ARAUJO, R. E. Sistema de aquisição e processamento de imagens de ovitrampas para o combate a dengue. Rev. Bras. Eng. Biom, v. 28, n. 4, p. 364-374, 2012.

DALLAZUANNA H, Bonat WH, Ribeiro Junior PJ. Dengue um ambiente para o monitoramento de ovos do mosquito *Aedes aegypti*. In: RBRAS: Anais da 53ª Reunião Brasileira da Sociedade Internacional de Biometria; 2008 maio 14-16; Lavras. Lavras: SBCS; 2008.

DONALÍSIO, Maria Rita; GLASSER, Carmen Moreno. Vigilância entomológica e controle de vetores do dengue. Revista Brasileira de Epidemiologia, v. 5, n. 3, p. 259-279, 2002.

FERNANDES, Anita Maria da Rocha. Inteligência artificial: noções gerais. Florianópolis: Visual Books, 2003.

KASINSKI, A.; SCHMIDT, A. The architecture and performance of the face and eyes detection system based on the Haar cascade classifiers. Pattern Analysis and Applications, v. 13, n. 2, p. 197-211, 2010.

LIENHART, R.; MAYDT, J., 2002. An Extended Set of Haar-like Features for Rapid Object Detection, IEEE ICIP, vol. 1.

PADILLA, R.; COSTA FILHO, C. F. F.; COSTA, M. G. F. Evaluation of haar cascade classifiers designed for face detection. World Academy of Science, Engineering and Technology, v. 64, 2012.

REINIUS, S. Object recognition using the OpenCV Haar cascade-classifier on the iOS platform. 2013.

VIOLA, P.; JONES, M. Rapid object detection using a boosted cascade of simple features. In: Computer Vision and Pattern Recognition, 2001. CVPR 2001. Proceedings of the 2001 IEEE Computer Society Conference on. IEEE, 2001. p. I-I.

WILSON, Phillip Ian; FERNANDEZ, John. Facial feature detection using Haar classifiers. Journal of Computing Sciences in Colleges, v. 21, n. 4, p. 127-133, 2006.