

PROPOSTA DE MODELO BASEADO EM PROCESSAMENTO DE IMAGENS PARA CLASSIFICAÇÃO AUTOMÁTICA DE MOSQUITOS

Daniel da Silva Motta, dmotta@fieb.org.br¹
Alex Álisson Bandeira Santos, alex.santos@fieb.org.br¹
Daniel André Dias Imperial Pereira, danielimperialadp@gmail.com¹
Alexandre Moraes Cavalcanti, alexandremoraiscavalcanti@gmail.com¹
Eduardo Oyama Lins Fonseca, eduoyama@gmail.com¹
Ingrid Winkler, ingrid.winkler@fieb.org.br¹
Roberto José da Silva Badaró, badaro@fieb.org.br¹

¹CENTRO UNIVERSITÁRIO SENAI CIMATEC, Av. Orlando Gomes, 1845, Piatã, 41.650-010, Salvador, Bahia, Brasil

Resumo: Dengue, Chikungunya e Zika são arboviroses que têm preocupado toda a população e, portanto, têm sido alvo de estudo nos últimos anos. Apesar de serem transmitidos por mosquitos do gênero *Aedes*, este trabalho se dedica ao estudo do *Aedes aegypti*, *Culex quinquefasciatus* e *Aedes albopictus*, por serem espécies que se adaptaram muito bem ao ambiente domiciliar e estão presentes em todo território nacional (Brasil). Classificar corretamente uma espécie é essencial nas ciências biológicas e principalmente na taxonomia de culicídeos. Este trabalho propõe um novo modelo de classificação de mosquitos a partir de imagens, baseado nas características morfológicas, com o objetivo de automatizar esse processo de classificação e assim, contribuir no controle de vetores transmissores de doenças. O modelo proposto neste trabalho é baseado em redes neurais convolucionais e os resultados preliminares indicam que a computação visual com a aplicação de técnicas de aprendizagem de máquina automatizam o processo de classificação de culicídeos, porém os parâmetros do modelo precisam ser ajustados e a base de imagens ampliada para aumentar a taxa de precisão e reduzir a função perda nos resultados.

Palavras-chave: Classificação de mosquitos, *Aedes*; *Culex*; Redes Neurais Convolucionais.

1. INTRODUÇÃO

A dengue é a doença mais comum transmitida por mosquitos do gênero *Aedes* nas Américas sendo a principal suspeita em pacientes com quadro febril. Nos últimos anos novas arboviroses têm preocupado a população e tem sido alvo de estudos, a exemplo da Chikungunya, Zika e mais recentemente Mayaro (PAHO 2017).

O vetor transmissor mais comum dessas doenças é o mosquito *Aedes aegypti*, porém sabe-se atualmente que outras espécies também carregam os vírus e podem infectar as pessoas. O *Aedes albopictus*, além de sua relevante importância médica, está presente em quase todo território brasileiro (Pancetti et al. 2015). O *Culex quinquefasciatus*, assim como o *Aedes aegypti*, tem ampla distribuição no Brasil, está associado ao ambiente domiciliar (Consoli & Oliveira 1998) e é considerado um potencial vetor de transmissão da Febre do Nilo Ocidental no Brasil (Ministério da Saúde 2011). Estudos recentes indicam o *Culex quinquefasciatus* como possível vetor de transmissão do vírus Zika (Guedes et al. 2017; Guo et al. 2016).

As doenças transmitidas por insetos respondem por, aproximadamente, 17% de todas as doenças relatadas globalmente e afetam principalmente as populações de baixa renda (WHO 2017). Ainda de acordo com a Organização Mundial da Saúde, essas doenças geram altos custos nos programas de Saúde e, por consequência, tem grande impacto econômico no desenvolvimento dos Países afetados, uma vez que, além de custos diretos gerados pela perda de produtividade dos trabalhadores infectados, reduzem receitas oriundas do turismo. Na figura 1 verifica-se que América do Sul, África e Ásia são os continentes que apresentam maior índice de doenças relacionadas à transmissão via mosquitos.




Figura 1. Distribuição global dos principais vetores de transmissão de doenças (WHO 2017). A escala de cor indica maior incidência das doenças.

Em 2017, a Organização Mundial da Saúde (OMS) propôs um plano de resposta global no controle de vetores transmissores de doenças de 2017 a 2030 (WHO 2017), com o objetivo de reduzir casos de doença e de mortalidade, além de erradicar epidemias, conforme se verifica na Tabela 1.

Tabela 1. Metas estabelecidas no plano de resposta global no controle de vetores transmissores de doenças de 2017 a 2030. Adaptado de (WHO 2017).

Metas	Metas intermediárias		Meta final
	2020	2025	2030
Reduzir a mortalidade devido a doenças transmitidas globalmente por vetores, comparado com 2016	Em no mínimo 30%	Em no mínimo 50%	Em no mínimo 75%
Reduzir casos de ocorrências de doenças transmitidas globalmente por vetores, comparado com 2016	Em no mínimo 25%	Em no mínimo 40%	Em no mínimo 60%
Prevenir epidemias de doenças transmitidas globalmente por vetores (detecção e redução rápidas de surtos, para evitar propagação no mundo)		Em todos os Países sem transmissão em 2016	Em todos os Países

Entre as ações definidas como prioritárias por este plano da OMS, a ampliação do desenvolvimento de pesquisa básica e aplicada é considerada como fundamental para o alcance das metas estabelecidas na Tabela 1.

Uma das atividades essenciais para nortear as ações de controle em qualquer cenário (epidêmico e não epidêmico) é a caracterização entomológica, que consiste em um conjunto de informações relativas ao vetor transmissor, tais como sua distribuição geográfica, índices de infestação e tipos de depósitos predominantes. As metodologias de pesquisa podem empregar procedimentos de coleta de ovos, larvas, pupas e mosquitos adultos, sendo mais habitual a pesquisa larvária. A utilidade dos índices relativos a adultos ainda é limitada, pois se desconhece a relação entre o número de adultos coletados e o número de adultos existentes no meio ambiente (Ministério da Saúde 2009).

Pesquisas recentes reforçam a importância dos estudos sobre técnicas que busquem acelerar o processo da caracterização entomológica, garantindo a acurácia da classificação. Alguns pesquisadores têm desenvolvido e estudado novas técnicas para classificação dos mosquitos. Parte dos trabalhos estudados busca desenvolver e avaliar modelos e técnicas de detecção e classificação de mosquitos baseados em processamento de imagem (da Silva et al. 2012; Kesavaraju & Dickson 2012; Reyes et al. 2016; Sanchez-Ortiz et al. 2017; Venkateswaran & Arumugam 2014). Outros pesquisadores usam como base as técnicas de análise e conversão de sinais de áudio (Arthur et al. 2014; Kawada et al. 2007; Silva et al. 2013).

Para as técnicas baseadas em processamento de imagens, abordagens recentes apontam os métodos de Redes Neurais Convolucionais (*Convolutional Neural Networks*) como essenciais para reconhecimento de objetos em imagens (Krizhevsky et al. 2012; Sanchez-Ortiz et al. 2017; Vargas 2016).

Este trabalho propõe um modelo computacional usando a técnica de classificação por processamento de imagem, baseado em modelo de Redes Neurais Convolucionais com o objetivo de automatizar o processo de classificação de mosquitos adultos a partir de fotos de mosquitos.

2. METODOLOGIA E DESENVOLVIMENTO

A pesquisa em questão é caracterizada como uma Pesquisa Experimental, que consiste em determinar um objeto de estudo (*Aedes aegypti*, *Aedes albopictus* e *Culex quinquefasciatus*), selecionar as variáveis que seriam capazes de influenciá-lo (forma, cor, textura, etc) e definir formas de controle dessas variáveis (modelagem computacional via aprendizagem de máquina). A Figura 2 abaixo ilustra as etapas executadas ao longo da pesquisa.



Figura 2. Etapas da Pesquisa.

2.1. Fundamentação Teórica e Tecnológica

Nesta etapa do trabalho, foi realizada uma revisão sistemática de literatura com o objetivo de identificar artigos acadêmicos e patentes que tratam de modelos de classificação de insetos por meio de processamento de imagens e técnicas de aprendizagem de máquina baseados na classificação morfológica de insetos adultos, mais precisamente das espécies *Aedes aegypti*, *Aedes albopictus* e do *Culex quinquefasciatus*. A pesquisa realizada considerou as fontes listadas no Quadro 1 para a pesquisa de artigos e a ferramenta *Derwent Innovation*®, considerando as fontes presentes no *Derwent World Patents Index*® (DWPI), para patentes.

Quadro 1. Fontes de pesquisa utilizadas para a revisão sistemática de literatura.

FONTES PESQUISADAS
<i>Web of Science</i>
<i>Current Contents Connect</i>
<i>Conference Proceedings</i>
<i>Inspec</i>
<i>SciELO - Scientific Electronic Library Online</i>
<i>ScienceDirect</i>
<i>Scopus</i>

O método de busca aplicou funcionalidades por tópico, truncamento e booleanos. Essas funcionalidades avançadas fizeram com que a pesquisa fosse refinada, inclusive, podendo fazer diversas combinações com as palavras buscadas. As palavras-chave utilizadas foram:

- Insect or mosquit* or culicid*
- Identificat* or classificat* or recognit*
- *Aedes* or *Culex*
- Imag* or process*

A revisão sistemática foi realizada no dia 30/10/2017 às 10:47:00 e considerou o período de 2000 a 2017 (até o momento da busca). Este período foi selecionado, considerando o crescimento exponencial de casos notificados de dengue no mundo e no Brasil. A análise dos artigos identificados foi realizada conforme fases definidas na Figura 3.




Figura 3. Fases de inclusão e exclusão dos artigos científicos.

O resultado de inclusão/exclusão da revisão sistemática, fases 1 a 3, pode ser verificado na Tabela 2 para os artigos e na tabela 3 para as patentes. Após a aplicação desses critérios, 37 artigos e 5 patentes foram selecionados para a etapa de priorização, que consistirá na leitura dos artigos e a extração de informações através das perguntas de priorização.

Tabela 2. Resultado da revisão sistemática de literatura, após aplicação dos critérios de inclusão/exclusão.

FONTES	FASE 1	FASE 2	FASE 3
<i>Web of Science</i>	118	77	11
<i>Current Contents Connect</i>	398	248	15
<i>Conference Proceedings</i>	0	0	0
<i>Inspec</i>	0	0	0
<i>SciELO</i>	500+	23	0
<i>ScienceDirect</i>	500+	27	1
<i>Scopus</i>	500+	189	10

Tabela 3. Resultado da revisão sistemática de patente.

FONTES	FASE 1	FASE 2	FASE 3
<i>Derwent World Patents Index®</i>	20.838	49	5

2.2. Levantamento de Dados

Para a definição do modelo para automação do processo de classificação dos mosquitos objeto desse estudo (*Aedes aegypti*, *Aedes albopictus* e *Culex quinquefasciatus*), fez-se necessário o levantamento dos seguintes dados:

- Entendimento do método tradicional de caracterização entomológica de mosquitos adultos.
- Definição da chave dicotômica para classificação dos insetos de interesse.

2.2.1. Método Tradicional de Classificação de Mosquitos

O método tradicional de classificação dos mosquitos adultos, de acordo com os procedimentos da Fiocruz, consiste nas etapas descritas na Figura 4.

Os mosquitos, depois de mortos, são montados em um alfinete entomológico junto a uma pequena base de papel. Esta montagem auxilia na manipulação do pesquisador para as regiões de interesse.

O mosquito é levado ao estereoscópio para que a sua classificação seja feita visualmente. O profissional treinado deve fazer uso de uma série de chaves dicotômicas (classificadores binários de mosquitos a partir de características morfológicas do mosquito) para identificar qual a família e espécie do *Culicidae* em questão.

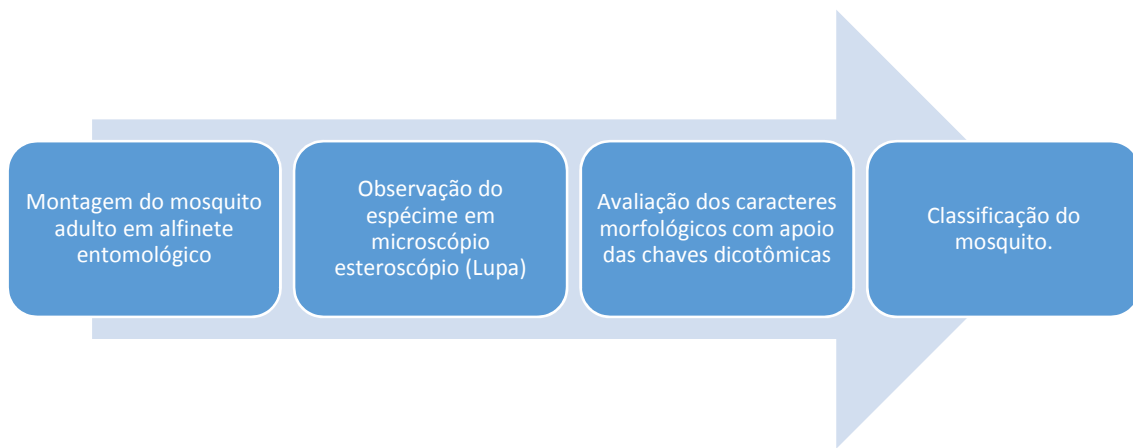


Figura 4. Procedimento de caracterização entomológica de mosquitos adultos.

2.2.2. Chave Dicotômica para Classificação

Considerando as espécies foco do estudo (*Aedes aegypti*, *Aedes albopictus*, *Culex quinquefasciatus*), a classificação destes tomou como base as chaves dicotômicas propostas por (Consoli & Oliveira 1998). A partir destas chaves, as principais características morfológicas dos mosquitos objeto desse estudo foram identificadas, conforme esquema apresentado na Figura 5.




Figura 5. Adaptação das chaves dicotômicas para classificação dos mosquitos objeto deste estudo.

Essas características são importantes para orientar a interpretação dos resultados, bem como a captura das imagens que serão utilizadas para treinamento do modelo.

2.3. Modelagem Computacional

O modelo proposto por este trabalho está baseado nas redes neurais. Uma rede neural em processamento computacional é formada por pequenos processadores (neurônios) de entrada-saída que processam informações valoradas ponderadas e relacionam-se a partir destas (Schmidhuber 2015). A rede é definida como um subconjunto finito de processadores (ou nós ou neurônios) $N=\{u_1, u_2, \dots\}$ e um conjunto finito $H \subseteq N \times N$ de direções ou conexões entre os nós. O nome dos processadores é dado em função da célula biológica de mesmo nome, que recebe sinais de outras e transmite sinais gerados a partir de diversas conexões, onde a informação é distribuída em interconexões e processadas em microssegundos (Jain et al. 1996).

Uma camada (*layer*) é um conjunto de dados, onde a primeira comumente representa os dados de entrada (*input*), processadas por um neurônio. Os dados intermediários (*hidden*) e de saída (*output*) então são submetidos a uma nova camada, que se interconecta e pondera as informações recebidas e enviadas. Uma representação esquemática de uma rede neural de 3 camadas pode ser visualizado na Figura 6.




Figura 6. Representação esquemática de uma rede neural de 3 camadas.

Para reconhecimento de imagens, as redes neurais convolucionais são as que, atualmente, apresentam o melhor desempenho em relação à precisão. A maior competição mundial para reconhecimento de imagens é a *ImageNet Large Scale Visual Recognition Challenge (ILSVRC)*. Desde 2012, as redes convolucionais têm vencido consistentemente essas competições e têm apresentado os melhores resultados na topologia de imagens 2-D (Goodfellow et al. 2016). Por esse motivo este trabalho propõe em seu modelo a adoção das redes neurais Convolucionais.

2.3.1. Estruturação do Banco de Imagens

Para o treinamento das redes neurais convolucionais, a estruturação de um banco de imagens (*dataset*) é fundamental para o aumento da precisão na classificação das imagens. Os principais fatores considerados nesse trabalho são:

- Quantidade total de imagens por espécie (*Aedes aegypti*, *Aedes albopictus* e *Culex quinquefasciatus*), separadas entre macho e fêmea.
- Separação das imagens que estão mais relacionadas com a aplicação do trabalho (imagens capturadas com celular).
- Definição das imagens e do percentual destas a serem utilizadas para:
 - o Treinamento.
 - o Validação.
 - o Teste.

O conteúdo do banco de imagens está em construção e sendo adquirido a partir das seguintes fontes:

- Fotos de mosquitos disponibilizadas e abertas ao público na internet.
- Imagens geradas com o uso de um microscópio estereoscópio.
- Imagens geradas com um sistema profissional de captura e edição disponibilizado pelo CCULI – Coleção de Culicidae da Fiocruz no Rio de Janeiro.
- Imagens geradas com celular.

2.3.2. Treinamento do Modelo

Uma vez estruturado, o banco de imagens é utilizado para treinamento da rede. Durante o treinamento, as imagens podem ser segregadas automaticamente ou manualmente em treinamento, validação e teste. Na figura 7 está representada a sequência de treinamento e o ajuste dos parâmetros do modelo com a finalidade de aumentar sua precisão e reduzir os valores da função perda.

O resultado desse processo de treinamento é influenciado diretamente pelos parâmetros selecionados para o treinamento do modelo. Alguns desses parâmetros estão listados abaixo:

- Número de repetições (épocas) para ajustes dos pesos dos atributos da rede.
- *Solver* a ser utilizado pelo modelo.
- Velocidade da taxa de aprendizagem do modelo e seu comportamento ao longo das épocas.
- Pesos de entrada do modelo (*seed*), que podem ser definidos ou aleatórios.




Figura 7. Representação do treinamento da rede.

2.4. Avaliação dos Resultados

Os resultados obtidos nesse trabalho serão avaliados em relação à taxa de precisão e ao valor da função perda durante o treinamento do modelo e da precisão alcançada pela rede quando se apresentam imagens que não foram utilizadas durante as fases de treinamento e, portanto, são completamente novas para a rede treinada.

A figura 8 apresenta o resultado da taxa de precisão e o valor da função perda durante a evolução do treinamento da rede GoogLeNet com os seguintes parâmetros: (a) 100 épocas; (b) *seed* aleatória; (c) *Solver* SGD; (d) taxa de aprendizagem 0.001 com decaimento sigmoidal; (e) Gamma 0.1. Para o treinamento dessa rede foram utilizadas 2.800 imagens para treinamento, 472 para validação e 131 para teste.

Percebe-se que a cada retroalimentação da rede (ajuste dos pesos dos atributos), de modo geral, a precisão cresce e a função perda diminui, chegando aos valores, após 100 épocas, de taxa de precisão de 58.33% e da função perda de 1.36.




Figura 8. Resultado inicial do treinamento da rede Googlenet.

Após o treinamento da rede, foi apresentada uma imagem não conhecida (não incluída no *dataset* de treinamento) para avaliação da eficácia no processo de classificação. Esta imagem foi avaliada por um entomologista que confirmou,

a partir do método tradicional de classificação de mosquitos e com o uso da chave dicotômica descritos anteriormente neste trabalho, que se trata de um *Aedes aegypti* fêmea.

A figura 9 apresenta o resultado da predição da rede treinada GoogLeNet. A resposta da rede é probabilística, indicando que a partir da análise dos atributos da imagem fornecida, a rede prediz que a probabilidade de se tratar de um *Aedes aegypti* fêmea é de 79,25%. Para efeito de avaliação dos resultados, o maior percentual será convertido em determinação (de probabilística para determinística), ou seja, no caso da figura 9, será considerado que o modelo classificou a imagem como a de um *Aedes aegypti* fêmea. No caso em questão, portanto o modelo acertou.




Figura 9. Resultado da classificação a partir de uma imagem desconhecida.

Os resultados aqui apresentados são iniciais, uma vez que para melhorar o desempenho do modelo há a necessidade de aprofundar os estudos para:

- Ampliar o *dataset* e a distribuição entre imagens de treinamento, de validação e de teste.
- Melhorar os ajustes dos parâmetros para o treinamento da rede.
- Treinar outras redes neurais convolucionais e comparar os resultados.
- Ampliar o número de imagens desconhecidas das redes por espécie e avaliar o desempenho das mesmas.

3. AGRADECIMENTOS

Este trabalho foi apoiado pelo SENAI CIMATEC, pela FAPESB e pela FIOCRUZ.

4. REFERÊNCIAS

- Arthur, B.J. et al., 2014. "Mosquito (*Aedes aegypti*) flight tones: Frequency, harmonicity, spherical spreading, and phase relationships". The Journal of the Acoustical Society of America, 135(2), pp.933–941. Available at: <http://www.ncbi.nlm.nih.gov/pmc/articles/PMC3985972/>.
- Consoli, R.A.G.B. & Oliveira, R.L. de, 1998. "Principais mosquitos de importância sanitária no Brasil", Available at: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0102-311X1995000100027&lng=pt&tlng=pt.
- Goodfellow, I., Bengio, Y. & Courville, A., 2016. "Deep Learning", MIT Press. Available at: <http://www.deeplearningbook.org>.
- Guedes, D.R. et al., 2017. "Zika virus replication in the mosquito *Culex quinquefasciatus* in Brazil". Emerging Microbes & Infections, 6(8), p.e69. Available at: <http://www.nature.com/doifinder/10.1038/emi.2017.59>.
- Guo, X. et al., 2016. "*Culex pipiens quinquefasciatus*: a potential vector to transmit Zika virus". Emerging Microbes & Infections, 5(9), p.e102. Available at: <http://www.nature.com/doifinder/10.1038/emi.2016.102>.
- Jain, A.K., Mao, J. & Mohiuddin, K.M., 1996. "Artificial neural networks: A tutorial". Computer, 29(3), pp.31–44.
- Kawada, H., Honda, S. & Takagi, M., 2007. "Comparative Laboratory Study on the Reaction of *Aedes aegypti* and *Aedes albopictus* to Different Attractive Cues in a Mosquito Trap". Journal of Medical Entomology, 44(3), pp.427–432. Available at: <http://www.bioone.org/doi/full/10.1603/0022-2585%282007%2944%5B427%3ACL%20SOTR%5D2.0.CO%3B2>.
- Kesavaraju, B. & Dickson, S., 2012. "New Technique to Count Mosquito Adults: Using ImageJ Software to Estimate Number of Mosquito Adults in a Trap". Journal of the American Mosquito Control Association, 28(4), pp.330–333. Available at: <http://www.bioone.org/doi/abs/10.2987/12-6254R.1>.
- Krizhevsky, A., Sutskever, I. & Hinton, G.E., 2012. "ImageNet Classification with Deep Convolutional Neural Networks". Advances In Neural Information Processing Systems, pp.1–9.
- Ministério da Saúde, 2009. "Diretrizes Nacionais para a Prevenção e Controle de Epidemias de Dengue". Secretaria de Vigilância em Saúde, p.162.

- Ministério da Saúde, 2011. Guia de vigilância do *Culex quinquefasciatus*. , p.80.
- PAHO, 2017. "Tool for the diagnosis and care of patients with suspected arboviral diseases", Available at: <http://iris.paho.org/xmlui/handle/123456789/33895>.
- Pancetti, F.G.M. et al., 2015. "Twenty-eight years of *Aedes albopictus* in Brazil: A rationale to maintain active entomological and epidemiological surveillance". *Revista da Sociedade Brasileira de Medicina Tropical*, 48(1), pp.87–89.
- Reyes, A.M.M.D.L. et al., 2016. "Detection of *Aedes Aegypti* mosquito by digital image processing techniques and support vector machine". 2016 IEEE Region 10 Conference (TENCON), pp.2342–2345.
- Sanchez-Ortiz, A. et al., 2017. "Mosquito Larva Classification Method Based on Convolutional Neural Networks". Instituto Politécnico Nacional.
- Schmidhuber, J., 2015. "Deep Learning in neural networks: An overview". *Neural Networks*, 61, pp.85–117. Available at: <http://dx.doi.org/10.1016/j.neunet.2014.09.003>.
- Silva, D.F. et al., 2013. "Applying machine learning and audio analysis techniques to insect recognition in intelligent traps". In *Proceedings - 2013 12th International Conference on Machine Learning and Applications, ICMLA 2013*. pp. 99–104.
- da Silva, M.G.N.M., Rodrigues, M.A.B. & de Araujo, R.E., 2012. "Sistema de aquisição e processamento de imagens de ovitrampas para o combate a dengue". *Revista Brasileira de Engenharia Biomedica*, 28(4), pp.364–374.
- Vargas, A., 2016. "Um estudo sobre Redes Neurais Convolucionais e sua aplicação em detecção de pedestres". Sibgrapi. Available at: <http://urlib.net/8JMKD3MGPAW/3ME3L2P>.
- Venkateswaran, T.D. & Arumugam, G., 2014. "Identification of Images Using Digital Image Processing". *Indian Journal of Computer Science and Engineering (IJCSSE)*, 4(6), pp.447–452.
- WHO, 2017. "Global Vector Control Response - Background document to inform deliberations during the 70th session of the World Health Assembly". WHO, 2030, p.47. Available at: http://www.who.int/malaria/areas/vector_control/Draft-WHO-GVCR-2017-2030.pdf?ua=1&ua=1.

5. RESPONSABILIDADE AUTURAL

Os autores são os únicos responsáveis pelo conteúdo deste trabalho.

MODEL PROPOSAL BASED ON IMAGE PROCESSING TO AUTOMATIZE MOSQUITOES CLASSIFICATION

Daniel da Silva Motta, dmotta@fieb.org.br¹
Alex Álisson Bandeira Santos, alex.santos@fieb.org.br¹
Daniel André Dias Imperial Pereira, danielimperialadp@gmail.com¹
Alexandre Moraes Cavalcanti, alexandremoraiscavalcanti@gmail.com¹
Eduardo Oyama Lins Fonseca, eduoyama@gmail.com¹
Ingrid Winkler, ingrid.winkler@fieb.org.br¹
Roberto José da Silva Badaró, badaro@fieb.org.br¹

¹CENTRO UNIVERSITÁRIO SENAI CIMATEC, Av. Orlando Gomes, 1845, Piatã, 41.650-010, Salvador, Bahia, Brasil

Abstract. *Dengue, Chikungunya and Zika are arboviruses that have been calling attention of many countries in the world and therefore have been subject of several study in recent years. Despite these diseases are well known to be transmitted by mosquitoes of the genus Aedes, this work is dedicated to study Aedes aegypti, Aedes albopictus and Culex quinquefasciatus, not only of health importance, but also because they are species that adapted very well to the domestic environment. Also, they are present throughout the entire Brazil territory. Classifying mosquito species precisely is essential for the biological sciences and especially in the taxonomy of culicidae to guide disease control actions. This work aims to develop a computational model to perform morphological classification of adult mosquitoes, based on Convolutional Neural Networks by image processing. Preliminary results indicates that visual computing with the application of Machine learning techniques automatize the classification process, but some adjustments must be done in the parameters of the model and also it is important to increase the dataset in order to increase accuracy and reduce the lost function of the results.*

Keywords: Mosquito Classification; Aedes; Culex; Convolutional Neural Networks (CNN).