



# INTELIGENCIA ARTIFICIAL AL SERVICIO DE LA SALUD PÚBLICA: CASO DE ESTUDIO “DETECCIÓN TEMPRANA DE FOCOS LARVARIOS DE MOSQUITOS”

Regina León-Ovelar<sup>1</sup>, Kevin Cikel<sup>2</sup>, Derlis Gregor<sup>3</sup>

<sup>1,2,3</sup> Artificial Intelligence and Complex Systems Laboratory (ArtICS Lab)

<sup>1,2</sup> MSc. <sup>3</sup> PhD. ArtICS Lab, San Lorenzo, Paraguay. dgregor@artics.com.py

## Abstract

*Mosquito-borne diseases are considered emerging and steadily increasing due to population growth and climate change. In order to monitor the occurrence of mosquito larval outbreaks, a larval identification system based on object detection and classification using computer vision and machine learning has been developed and evaluated. For this purpose, 45 sample images of a container with water containing mosquitoes in larval and pupal stage have been collected. The detector based on adaptive thresholding and contour detection was able to find all the relevant objects in the sample images. To identify each object found by the detector as a larva or not, a classifier based on HOG and SVM, and another based on CNN have been trained and evaluated, obtaining F1 values of 0.951 and 0.991 respectively.*

*Keywords: Machine Vision, CNN, Diptera, Larvae*

## Introducción

Los mosquitos son vectores de múltiples enfermedades y el riesgo de transmisión de estas así como, las posibles medidas de intervención se ven vinculados a la dinámica poblacional y geográfica (Sedda et al., 2020). La expansión hacia nuevas zonas geográficas del *Aedes aegypti* (L.) y *Aedes albopictus* (Skuse) llevaría a un aumento en el riesgo sobre la salud pública debido a su capacidad de transmitir enfermedades arbovirales, como el virus del dengue emergente y reemergente, el virus de la chikungunya, la fiebre amarilla o del virus del Zika. La falta de control contra la proliferación de mosquitos genera una alta incidencia en la transmisión de enfermedades, por lo que es necesario contar con datos completos y actualizados sobre poblaciones de mosquitos brindados por métodos de vigilancia capaces (Fernandes et al., 2020). Sedda et al., (2020) han demostrado una relación

positiva entre la incidencia de casos de dengue en un área y la tasa de crecimiento del mosquito vector, esto facilitaría la evaluación de riesgos de transmisión y la actuación focalizada en dicha área. El comportamiento y dinámica poblacional de los mosquitos depende de factores ambientales. La variación meteorológica afectaría rápidamente a una población de mosquitos, pudiendo en horas o días variar abruptamente su población. El control del ciclo de vida se constituye como medida de control fundamental, principalmente en etapa acuática (Sedda et al., 2020). Estudios sugieren que técnicas basadas en Machine Learning podrían utilizarse para la clasificación automática de especies, una vía podría ser mediante la identificación del sonido del aleteo del mosquito o por el estudio de imágenes de mosquitos empleando redes neuronales convolucionales (Fernandes et al., 2020). En cuanto a la utilización de inteligencia artificial para diferenciación de culícidos se puede mencionar que Sánchez et al. (2017), desarrollaron un clasificador binario para la diferenciación de larvas de mosquitos en dos clases, del género Aedes y de otros géneros, utilizando una CNN basado en el modelo AlexNet (Krizhevsky et al., 2012), observando la diferencia entre los peines ubicados en el octavo segmento de las larvas de los distintos géneros de mosquitos, obteniendo un nivel de acierto del 96.8%. Sin embargo, las imágenes de las larvas fueron capturadas de forma individual, siendo necesaria la colocación de cada larva bajo una lente microscopio acoplada a la cámara. Kim et al. (2019) presentan un sistema automático de detección y control de mosquitos basado en procesamiento de imágenes, atrayendo mosquitos a una plataforma de observación mediante generación de CO<sub>2</sub>. Mediante un preprocesamiento realizado a las imágenes capturadas en esa plataforma se logró obtener las ubicaciones de los objetos presentes en la misma, utilizando una CNN basado en el modelo AlexNet para la clasificación de estos en las clases mosquito y no-mosquito. El mapa de probabilidad obtenido en la capa anterior a la etapa de desconvolución es extraído y utilizado para estimar el número de mosquitos presentes en la imagen. El trabajo desarrollado por Motta et al. (2019) describe la clasificación morfológica de tres especies de mosquitos mediante la utilización de modelos de CNN entrenados con imágenes de mosquitos adultos. Huang et al. (2018) presentaron un sistema de clasificación de mosquitos capaz de catalogarlos en los géneros Aedes y Culex de forma automática.

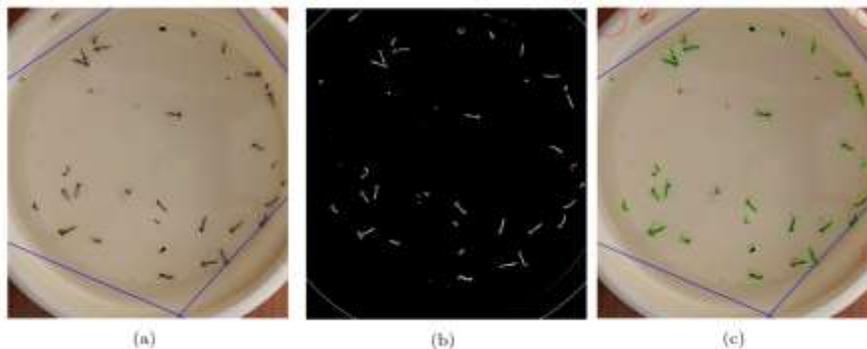
## **Objetivos**

Identificación y conteo de dípteros nematóceros de la familia culícidos en etapa larvaria a través del reconocimiento de imágenes y el análisis predictivo, utilizando técnicas de visión e inteligencia artificial.

## Metodología

### *Detección de objetos*

Se ha realizado el procesamiento de imágenes registradas a partir de un reservorio natural de larvas. Primeramente se reduce el tamaño de las imágenes, previo a la aplicación de algoritmos de procesamiento, además de definir la región de interés para descartar los objetos que se encuentren fuera del área deseada. La imagen se convierte a escala de grises y se aplica un filtro gaussiano, y se aplica una umbralización (thresholding) adaptativa gaussiana invertida, donde el valor umbral para cada píxel se determina mediante la suma gaussiana de los valores de píxeles vecinos, obteniendo una imagen binaria con el fondo en negro y los píxeles de los objetos en blanco. Finalmente se aplica la función findContours de OpenCV, basado en el algoritmo propuesto por Suzuki (1985), descartando objetos muy pequeños con menos de 250 píxeles. Resultando en la ubicación y delimitación de objetos en la imagen. En la figura 1 es posible observar el proceso de detección mencionado.



**Figura 1: Etapas del proceso de detección de objetos.**

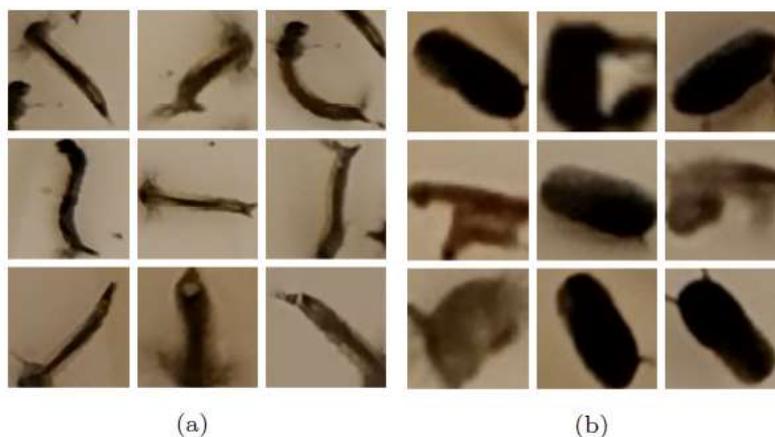
### *Clasificación de objetos*

Para descartar los objetos que no corresponden a larvas, primeramente se definen las clases “no larvas”, que contienen a los culícidos en estado de pupa y otros cuerpos extraños, y “larvas” que contienen a los culícidos en estado de pupa y otros cuerpos extraños, y “larvas” que contiene a los culícidos en estado larvario. El primer paso para la clasificación es el etiquetado manual en una de estas dos clases de todos los cuerpos encontrados por el detector. Con estos datos se realizaron las pruebas mediante clasificadores binarios utilizando dos enfoques distintos. Para el primer clasificador se emplean histogramas de gradientes orientados (HOG) para la extracción de características de cada objeto y una máquina de vector de soporte (SVM) para la clasificación de las mismas, mientras que para el segundo clasificador se emplea una red neuronal convolucional (CNN). Para el entrenamiento de ambos clasificadores se utilizan 30 imágenes, quedando las 15

restantes para la evaluación del rendimiento.

- **Clasificador basado en HOG y SVM**

Para este clasificador se utiliza las imágenes binarias generadas por el detector. Se aplica entonces el descriptor de características HOG para obtener los histogramas de las direcciones de los gradientes de cada objeto, los cuales se guardan en un vector de características. Mediante un clasificador SVM se obtiene el hiperplano que discrimina objetos en una de las clases.



**Figura 2: Muestra de objetos detectados, (a) corresponde a la clase “larvas” y (b) a la clase “no larvas”.**

## Resultados y discusión

Los resultados obtenidos son óptimos, siendo detectados todos los objetos de interés en la imagen. En la Tabla 1 se presenta la matriz de confusión del clasificador.

**Tabla 1: Matriz de confusión del clasificador SVM. Fuente: elaboración propia.**

	“no larvas” detectadas	“larvas” detectadas
“no larvas” reales	56	7
“larvas” reales	38	381

En cuanto al rendimiento, se ha encontrado un valor de precisión de 0.997, lo cual indica que casi la totalidad de los objetos identificados como larvas corresponden a larvas reales. Por otra parte el valor de recuperación (recall) que se obtuvo fue de 0.909, lo que indica que aproximadamente un 9% de larvas reales fueron identificadas como no larvas y un valor F1 igual a 0.951.

La tabla 2 presenta la matriz de confusión y los valores de rendimiento respectivamente. Este estudio de caso demostraría muy altos niveles de acierto con solo tres casos de falsos negativos y cinco de falsos positivos, obteniendo un valor F1 de 0.991 con una precisión de 0.988 y valor de

recuperación igual a 0.993.

**Tabla 2: Matriz de confusión del clasificador CNN. Fuente: elaboración propia.**

	“no larvas” detectadas	“larvas” detectadas
“no larvas” reales	52	5
“larvas” reales	3	416

## **Conclusiones**

La detección temprana de focos larvarios permitiría una intervención de manera preventiva en áreas de alto riesgo, lo cual tendría un potencial efecto económico positivo, contribuyendo con la no saturación de centros asistenciales, la optimización de recursos estatales o la utilización racional de pesticidas.

La identificación de mosquitos en estado larvario mediante la aplicación de inteligencia artificial podría convertirse en una poderosa herramienta de gestión ambiental además, de brindar apoyo en la toma de decisiones en el área de salud pública.

Se destaca el alto nivel de acierto del clasificador CNN a pesar de haber utilizado un modelo no muy complejo con pocas capas, sin embargo esto puede deberse a la limitada variedad de las imágenes, las cuales han sido utilizadas tanto para el entrenamiento como para la evaluación de los clasificadores, ya que todas han sido capturadas de la misma muestra de larvas y en el mismo día, siendo necesarias por lo tanto imágenes adicionales de muestras más diversas para una evaluación más completa de los clasificadores.

## **Reconocimientos**

Los autores quisieran agradecer al Gobierno de Paraguay por el apoyo económico proveído a través del cofinanciamiento del Consejo Nacional de Ciencias y Tecnología – CONACYT con recursos del FEEI (Proyecto *PINV18-001*).

## **Referencias**

Fernandes, M. S., Cordeiro, W., & Recamonde-Mendoza, M. (2020). Detecting *Aedes aegypti* mosquitoes through audio classification with convolutional neural networks. *Computers in Biology and Medicine*, 129, 104152.

Huang, L. P., Hong, M. H., Luo, C. H., Mahajan, S., & Chen, L. J. (2018, November). A vector mosquitoes classification system based on edge computing and deep learning. In *2018 Conference on Technologies and Applications of Artificial Intelligence (TAAI)* (pp. 24-27). IEEE.

- Kim, K., Hyun, J., Kim, H., Lim, H., & Myung, H. (2019). A deep learning-based automatic mosquito sensing and control system for urban mosquito habitats. *Sensors*, *19*(12), 2785.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, *25*, 1097-1105.
- Motta, D., Santos, A. Á. B., Winkler, I., Machado, B. A. S., Pereira, D. A. D. I., Cavalcanti, A. M., ... & Badaró, R. (2019). Application of convolutional neural networks for classification of adult mosquitoes in the field. *PloS one*, *14*(1), e0210829.
- Sanchez-Ortiz, A., Fierro-Radilla, A., Arista-Jalife, A., Cedillo-Hernandez, M., Nakano-Miyatake, M., Robles-Camarillo, D., & Cuatrecasas-Jiménez, V. (2017, February). Mosquito larva classification method based on convolutional neural networks. In *2017 International Conference on Electronics, Communications and Computers (CONIELECOMP)* (pp. 1-6). IEEE.
- Sedda, L., Taylor, B. M., Eiras, A. E., Marques, J. T., & Dillon, R. J. (2020). Using the intrinsic growth rate of the mosquito population improves spatio-temporal dengue risk estimation. *ActaTropica*, 105519.
- Suzuki, S. (1985). Topological structural analysis of digitized binary images by border following. *Computer vision, graphics, and image processing*, *30*(1), 32-4.