



Trampa Inteligente para Detección de Mosquitos basada en IA

Diego César Balbuena Duarte^{a,1}, Mathias Rodolfo Barrios Pereira^{a,1}, Dr. Diego Stalder^{b,2}, Dr. Christian Schaerer^{c,3}

^aTesistas, Facultad de Ingeniería, Universidad Nacional de Asunción, Paraguay

^bTutor, Facultad de Ingeniería, Universidad Nacional de Asunción, Paraguay

^cTutor, Facultad Politécnica, Universidad Nacional de Asunción, Paraguay

PALABRAS CLAVE

Trampa de mosquitos
Visión artificial
Inteligencia artificial
Detección de sonido
Clasificación automática
Aedes aegypti
Monitoreo vectorial
YOLOv8
Mecanismo de captura
Sistema mecatrónico

RESUMEN

La creciente incidencia de enfermedades transmitidas por mosquitos (dengue, zika, chikungunya) exige sistemas de vigilancia entomológica más precisos y eficientes. Actualmente, la clasificación de mosquitos en laboratorios, como el IICS, se realiza predominantemente de forma manual, un proceso ineficiente, lento y susceptible a errores. Este trabajo presenta el diseño e implementación de una trampa inteligente que captura mosquitos vivos, adquiere imágenes en tiempo real y los clasifica automáticamente mediante visión artificial. El sistema emplea el modelo YOLOv8-small, una red neuronal convolucional entrenada para diferenciar entre machos, hembras y especímenes no válidos (incompletos o borrosos). La estructura mecatrónica incluye un sistema de captura asistido por flujo de aire, un mecanismo de iris motorizado para la estabilización visual del espécimen y una cámara de alta velocidad. Los resultados experimentales confirman la operatividad del prototipo en la captura controlada de *Aedes aegypti* y demuestran una alta precisión en la clasificación, validando su potencial para el monitoreo vectorial automatizado.

KEYWORDS

Mosquito trap
Computer vision
Artificial Intelligence
Sound detection
Automated classification
Aedes aegypti
Vector monitoring
YOLOv8
Capture mechanism
Mechatronic system

ABSTRACT

The rising prevalence of mosquito-borne diseases necessitates efficient and automated entomological surveillance systems. Current manual classification methods, often employed in research institutes, are time-consuming and error-prone. This paper introduces the design and implementation of an intelligent trap capable of capturing live mosquitoes, acquiring real-time images, and classifying them using Artificial Intelligence (AI) and computer vision. The system utilizes the YOLOv8-small convolutional neural network, trained to distinguish between male, female, and invalid specimens (incomplete or out of focus). The mechatronic design integrates an airflow-assisted capture mechanism, a motorized iris for visual stabilization, and a high-speed camera. Experimental validation demonstrates reliable operation in controlled environments and achieves high classification accuracy, highlighting the potential for real-world automated vector monitoring applications.

1. Introducción

1.1. Contexto y Justificación

Este capítulo introduce la amenaza creciente de las enfermedades transmitidas por vectores (*dengue*, *zika*, *chikungunya*) y la necesidad crítica de mejorar la vigilancia entomológica en Paraguay. Se contrasta la ineficacia de los métodos tradicionales y se subraya la limitación de sistemas automatizados comerciales (como el BG-Counter 2), cuya precisión es altamente sensible al contexto y la diversidad de insectos no objetivo [1].

El trabajo se fundamenta en investigaciones previas realizadas en la facultad, demostrando la viabilidad de sistemas mecatrónicos de clasificación [2] y el marco teórico para la modelización matemática predictiva basada en factores ambientales [3]. La tesis propone ir más allá al integrar captura, clasificación por visión artificial y un modelo predictivo, buscando una solución tecnológica de bajo costo y robusta.

1.2. Objetivos Generales

- Desarrollar un dispositivo inteligente para atrapar y contar mosquitos para la predicción de su población, y formular un modelo matemático que permita predecir la evolución de las poblaciones de mosquitos en función a temperatura, precipitación y poblaciones de mosquitos anteriores.

1.3. Objetivos Específicos

- Diseñar una trampa para mosquitos con atrayente y recámara para realizar el reconocimiento.

¹Alumnos de Ingeniería Mecatrónica de Facultad de Ingeniería, UNA, Paraguay (email: {dbalbuena, mathiasbarriosp}@fiuna.edu.py)

²Tutor de la Facultad de Ingeniería, LEM-UNA, Paraguay (email: dstalder@ing.edu.py)

³Tutor de la Facultad Politécnica, NIDTec-UNA, Paraguay (email: chris.schaerer@gmail.com)

- Implementar técnicas de visión artificial para diferenciar mosquitos machos y hembras.
- Implementar una base de datos para almacenar datos recopilados.
- Recopilar y analizar datos históricos de poblaciones de mosquitos y factores ambientales.
- Analizar el impacto de las condiciones ambientales en los parámetros usados en el modelo matemático de la población.

1.4. Alcance y Limitaciones

El proyecto se enfoca en el diseño y desarrollo de un prototipo funcional y la implementación inicial de un modelo predictivo.

Alcance:

- Diseño del hardware (trampa, sensores, cámara).
- Clasificación binaria (macho/hembra) mediante técnicas de visión artificial.
- Almacenamiento de datos en una base de datos.
- Construcción de un modelo predictivo a corto plazo.

Limitaciones:

- El sistema es un prototipo, no apto para producción masiva o exposición a condiciones climáticas adversas.
- La clasificación se limita a machos y hembras, sin diferenciación de especies.
- La precisión del modelo predictivo depende de la calidad y completitud de los datos históricos.
- La precisión del reconocimiento en campo puede verse afectada por variables no controladas como la iluminación o el movimiento errático, ya que el modelo fue entrenado en laboratorio.

2. Marco Teórico y Estado del Arte

2.1. Fundamentos del Problema y Justificación Tecnológica

El capítulo establece que el mosquito *Aedes aegypti* es el principal vector de enfermedades como el dengue. Se justifica la necesidad de un monitoreo continuo y eficiente para intervenciones clave, como el uso de *Wolbachia* [4]. Se identifican las limitaciones de los métodos convencionales (manuales) y de los sistemas automatizados comerciales (como el BG-Counter), cuya precisión cae drásticamente en entornos con alta diversidad de insectos no objetivo [1]. Esta brecha justifica el desarrollo de soluciones tecnológicas de bajo costo basadas en visión artificial y modelos predictivos.

2.2. Estrategias de Monitoreo y Tipos de Trampas

Se revisan las principales tecnologías de trapeo:

- Ovitrapas: Sensores de actividad de bajo costo que miden la oviposición, no la población adulta.
- BG-Counter: Referente comercial que utiliza sensores infrarrojos para el conteo [1]. Su limitación principal es la alta variabilidad en precisión y la incapacidad de distinguir especies.

- LAMI: Sistema que integra una cámara para análisis visual, validando el concepto de cámara de inspección [5].

La Tabla 1 resume la comparación de estas tecnologías, resaltando la variabilidad e ineficacia de los sensores ópticos simples.

2.3. Atrayentes, Sensores y Actuadores

Se analizan los tres componentes de las trampas inteligentes:

- **Atrayentes:** Se distinguen entre atrayentes de huésped (CO_2) y de oviposición (gravídicos). La efectividad de cebos orgánicos de bajo costo, como la infusión de pasto validada por la Gravid Aedes Trap (GAT) [6], justifica el enfoque de bajo costo del proyecto.
- **Detección:** Se prioriza el uso de sensores de visión (cámaras) para la identificación morfológica mediante IA, sobre los sensores ópticos simples.
- **Actuadores/Captura:** Se compara el mecanismo de succión de la Trampa Miniatura de Luz (CDC-LT) con mecanismos pasivos (CPT) y químicos, destacando la ventaja del enfoque no letal para estudios posteriores [7]. El principio de captura por cono invertido se estudia como base mecánica.

2.4. Fundamentos de visión por computadora

La visión por computadora es un campo de la inteligencia artificial (IA) que capacita a las computadoras para interpretar y comprender el mundo visual. Mediante el uso de cámaras, datos y algoritmos de IA, las máquinas pueden identificar y clasificar objetos, replicando y superando las capacidades humanas en tareas de análisis visual. Esta tecnología permite a los ordenadores procesar, analizar y extraer información significativa de imágenes y videos, automatizando tareas que tradicionalmente requerían de personal taxonómico experto [8].

El objetivo principal es enseñar a los ordenadores a reconocer patrones en las imágenes para poder diferenciar, separar y clasificar objetos. Esto tiene aplicaciones en diversos sectores como la manufactura, la seguridad y la medicina. En el contexto de la entomología, la visión por computadora se ha convertido en una herramienta poderosa para el estudio de insectos. Permite automatizar tareas como la clasificación de especies, que de forma manual requeriría mucho tiempo y la supervisión de un experto. La integración de la visión por computadora en trampas inteligentes posibilita la identificación y el conteo automatizado y en tiempo real, mejorando significativamente la precisión en el monitoreo de poblaciones de insectos.

2.5. YOLO (You Only Look Once)

YOLO es un algoritmo de detección de objetos en tiempo real que fue presentado en 2015. A diferencia de los sistemas anteriores que realizaban la detección en múltiples pasos, YOLO aborda la detección de objetos como un único problema de regresión. Aplica una sola red neuronal a la imagen completa, dividiéndola en una cuadrícula y prediciendo cuadros delimitadores (*bounding boxes*) y probabilidades de clase para cada celda de la cuadrícula simultáneamente. Esta arquitectura unificada permite que YOLO sea extremadamente rápido, procesando imágenes a altas velocidades (frames per second, FPS), lo que lo hace ideal para aplicaciones en tiempo real.

Trampa	Mecanismo de Detección	Costo (Estimado)	Clasificación Específica	Limitación Principal
Ovitrapa / LIRS	Visual/Manual (Huevos)	Bajo	No (Solo actividad)	Solo mide oviposición, no adultos.
BG-Counter 2 (Comercial)	Sensor Óptico (IR)	Alto	No	Precisión muy variable con insectos no objetivo.
LAMI (Proyecto)	Succión	Medio	No	Solo captura, no clasifica.
CDC-LT (Estándar)	Succión + Luz	Bajo/Medio	Manual posterior	No es en tiempo real, requiere análisis en laboratorio.
Propuesta Actual	Cámara + Deep Learning	Medio	Sí (Automatizada)	Requiere modelo de IA entrenado y alta capacidad de procesamiento.

TABLA 1: Comparación de tecnologías de Trampas para el Monitoreo de Mosquitos.

Fuente: Adaptado de Day et al. (2020), y otros estudios referenciados en el marco teórico.

2.5.1. Arquitectura YOLOv8

YOLOv8, desarrollado por Ultralytics, es una de las versiones más recientes y avanzadas de la familia YOLO, destacando por su velocidad y precisión superiores a las de sus predecesores. Su arquitectura se puede dividir en tres componentes principales:

- **Backbone:** Es la red neuronal convolucional encargada de extraer características de la imagen de entrada. YOLOv8 utiliza un backbone llamado CSPDarknet53, que mejora el flujo de información entre las capas para aumentar la precisión.
- **Neck:** Actúa como un puente, fusionando los mapas de características extraídos por el backbone en diferentes escalas. Esto permite capturar tanto información semántica de alto nivel como detalles espaciales de bajo nivel, mejorando la detección, especialmente de objetos pequeños.
- **Head:** Es la parte final de la red, responsable de generar las predicciones finales. Predice los cuadros delimitadores, las puntuaciones de confianza (que indican la probabilidad de que un objeto esté presente) y las probabilidades de clase para cada objeto detectado.

Una innovación clave en YOLOv8 es su enfoque de detección "sin anclas" (*anchor-free*), lo que simplifica la arquitectura y mejora la capacidad de predecir la ubicación de objetos con formas y tamaños variados.

2.6. Síntesis y Justificación del Enfoque Propuesto

La revisión valida que la tendencia actual se dirige hacia plataformas DIY y sistemas IoT [9, 10]. El trabajo propuesto se justifica al abordar las brechas críticas del estado del arte: **alto costo y baja precisión morfológica**. El diseño adopta el concepto de cámara de inspección y lo adapta a un enfoque de bajo costo, alta precisión por Deep Learning y con capacidad de integración predictiva [3].

3. Metodología del Proyecto

3.1. Enfoque Metodológico

El proyecto adoptó una metodología de **ingeniería concurrente** que integró el desarrollo del modelo matemático predictivo con la construcción de un prototipo mecatrónico. Este enfoque garantiza una **validación bidireccional**: el prototipo proporciona datos de campo limpios al modelo, y el modelo establece los requisitos de calidad para la adquisición de datos.

La metodología se estructuró en tres fases principales que convergieron en la validación:

1. **Modelado Teórico:** Definición del marco analítico y predictivo mediante Ecuaciones Diferenciales Ordinarias (EDOs).
2. **Diseño e Implementación:** Construcción del sistema físico (mecánica, electrónica) y entrenamiento del sistema de clasificación (visión por computadora).
3. **Integración y Validación:** Pruebas de funcionamiento y evaluación del rendimiento del sistema completo.

La interdependencia de los pasos se ilustra en la Figura 1.

3.2. Fases de Desarrollo y Componentes

3.2.1. Modelado Matemático

Se centró en la creación de un sistema de **EDOs** para generar escenarios predictivos. El modelo incluye funciones de tasa de crecimiento y mortalidad dependientes de variables ambientales clave como la temperatura ($T(t)$) y la precipitación ($P(t)$). El principal resultado es un modelo que requiere datos de conteo de adultos para su calibración y validación.

3.2.2. Desarrollo del Modelo de Visión por Computadora

Para la clasificación, se empleó la arquitectura **YOLOv8-small** (una CNN), seleccionada por su eficiencia en dispositivos embebidos. Se recopilaron, anotaron y aumentaron 1,199 imágenes de *Aedes aegypti* para entrenamiento. La clasificación se enfocó en cinco categorías: **Hembra** y **Macho** (principales), y tres clases de error ("Incompleto", "Indefinido", "Fuera de Foco") para garantizar la robustez en condiciones reales.

Metodología Sintetizada - Pasos Clave




Fig. 1: Metodología sintetizada del proyecto, detallando los pasos clave de desarrollo e integración. **Fuente:** Elaboración propia.

3.2.3. Diseño de la Plataforma Mecatrónica

El diseño priorizó la modularidad, el bajo costo y la operación **no letal**, utilizando **CAD** e **Impresión 3D** para componentes críticos (tubo de inspección y mecanismo de iris). La arquitectura electrónica es distribuida: una **Orange Pi** para procesamiento de alto nivel (ejecución del modelo YOLOv8) y un **Arduino UNO** para el control en tiempo real de actuadores (servo-motor y ventilador).

3.3. Integración y Validación Integral

La fase de **Integración** unifica la Plataforma Mecatrónica con el Modelo de Visión. El hardware embebido (Orange Pi) ejecuta YOLOv8 para clasificar el sexo del mosquito; estos datos de vigilancia (conteo) se convierten en la entrada para la calibración del Modelo Matemático.

La **Validación** se realiza en dos niveles:

- **Validación de Componente (Visión):** Se evalúa el modelo YOLOv8-small usando métricas de IA como **mAP50**. La **Matriz de Confusión** (Tabla 5.2) es el instrumento para cuantificar la precisión en la clasificación entre clases de sexo y error.
- **Validación End-to-End (Prototipo):** Se aplica un protocolo de prueba controlada con mosquitos individuales para verificar el ciclo completo: captura, posicionamiento, clasificación y registro de datos. La precisión global del prototipo funcional se resume en la **Matriz de Confusión de la validación experimental** (Tabla 6.1).

4. Modelo Matemático de Dinámica Poblacional

4.1. Planteamiento del Modelo de Ecuaciones Diferenciales Ordinarias (EDOs)

Este capítulo detalla el **Modelo Determinístico de EDOs** utilizado para simular la dinámica poblacional de *Aedes aegypti* bajo la influencia de variables ambientales, fundamentalmente la temperatura y la precipitación [11]. El modelo, previamente validado para el contexto de Paraguay [3], se basa en el sistema adaptado de Chen et al. [12]:

$$\frac{dJ}{dt} = b(t) \left(1 - \frac{J}{K(t)} \right) A - (d(t) + \mu_1(t))J \quad (1)$$

$$\frac{dA}{dt} = 0.5d(t)J - \mu_2(t)A \quad (2)$$

donde $J(t)$ es la población inmadura y $A(t)$ es la población de hembras adultas (vectoras de enfermedad).




Fig. 2: Precipitación diaria registrada en el área de estudio. Este factor ambiental afecta directamente la disponibilidad de sitios de cría para los mosquitos. **Fuente:** Elaboración propia, a partir de los datos de [13].

4.2. Dependencia Biológica y Parámetros Ambientales

Los parámetros entomológicos clave (b, d, μ_1, μ_2) presentan una **dependencia explícita de la temperatura** (T) para reflejar la fisiología del mosquito. En lugar de ajustes polinomiales simples, se utilizaron modelos no lineales con plausibilidad biológica (tipo Brière y cuadrático) ajustados a la base de datos de consenso de [14].

- La **tasa de oviposición** ($b(T)$) y la **tasa de desarrollo** ($d(T)$) se ajustaron con el modelo Brière (Figuras 5 y 6).
- La **tasa de mortalidad adulta** ($\mu_2(T)$) se ajustó con un modelo cuadrático (Figura 4).
- La **tasa de mortalidad acuática** ($\mu_1(T)$) se derivó internamente a partir de la probabilidad de supervivencia y la tasa de desarrollo (Figura 3).

La **capacidad de carga** ($K(t)$) para larvas se relaciona directamente con la **precipitación acumulada** ($P_n(t)$) en los últimos n días, donde $K(t) = K(1 + \alpha P_n(t))$, asumiendo que la lluvia crea sitios de cría.

4.3. Resultados Obtenidos de la Simulación

Se utilizaron datos meteorológicos reales de GDAS [13] (Figuras 2 y 8) para forzar el modelo. La simulación exploró el impacto de distintos índices de **precipitación acumulada normalizada** (P_7, P_{21}, P_{42}) (Figura 7) sobre la dinámica poblacional.




Fig. 3: Tasa de mortalidad de la fase acuática ($\mu_1(T)$) en función de la temperatura. Esta curva no es un ajuste directo, sino el resultado derivado de la relación $\mu_1(T) = -\ln(p_{EA}(T)) \cdot d(T)$. Los bordes verticales representan los umbrales térmicos mínimos y máximos para la viabilidad del ciclo de vida, donde la mortalidad se vuelve del 100%. **Fuente:** Elaboración propia, a partir de los datos de [14].




Fig. 4: Tasa de mortalidad de mosquitos adultos ($\mu_2(T)$) en función de la temperatura. La curva en forma de 'U' es el resultado de ajustar un modelo cuadrático a los datos compilados, mostrando un rango de temperatura óptimo para la supervivencia. Las unidades del eje vertical son días⁻¹. **Fuente:** Elaboración propia, a partir de los datos de [14].




Fig. 5: Tasa de oviposición ($b(T)$) en función de la temperatura. La curva roja representa el ajuste de un modelo tipo Briere a los datos compilados de múltiples estudios de laboratorio. El eje vertical representa el número de huevos por hembra por día. **Fuente:** Elaboración propia, a partir de los datos de [14].

- Las Figuras 9 y 10 ilustran la dinámica simulada de las poblaciones J y A .
- Los resultados demuestran que la **capacidad de carga y el crecimiento poblacional responden sensiblemente a la precipitación** y a la modulación de las tasas biológicas por la temperatura.




Fig. 6: Tasa de desarrollo de la fase acuática ($d(T)$) en función de la temperatura. La curva roja es el ajuste de un modelo tipo Briere a los datos compilados. El eje vertical tiene unidades de días⁻¹ y representa la fracción de la cohorte que completa la transición a adulto por día. **Fuente:** Elaboración propia, a partir de los datos de [14].




Fig. 7: Índices de precipitación acumulada normalizada (P_7 , P_{21} y P_{42}) obtenidos a partir de las lluvias acumuladas en 7, 21 y 42 días, respectivamente. Estos índices se utilizan para modelar el impacto de la lluvia sobre la capacidad de carga $K(t)$. **Fuente:** Elaboración propia, a partir de los datos de [13].




Fig. 8: Temperatura diaria promedio registrada. La temperatura influye fuertemente en las tasas biológicas de desarrollo, mortalidad y oviposición del mosquito. **Fuente:** Elaboración propia, a partir de los datos de [13].

El análisis proporciona una **representación cuantitativa** de los efectos ambientales sobre la población, que sirve como base teórica para la calibración del modelo con los datos de campo generados por la trampa inteligente.




Fig. 9: Dinámica simulada de la población de mosquitos inmaduros (J) bajo distintos escenarios de precipitación acumulada (P_7 , P_{21} y P_{42}). Se observa que mayores acumulaciones de lluvia incrementan la capacidad de carga y, por tanto, el número de inmaduros. **Fuente:** Elaboración propia.




Fig. 10: Dinámica simulada de mosquitos adultos hembra (A) correspondiente a los mismos escenarios de precipitación acumulada. El crecimiento poblacional de los adultos refleja la respuesta retardada respecto a la fase inmadura. **Fuente:** Elaboración propia.

5. Identificación de mosquitos mediante visión por computadora

5.1. Fundamentos y Algoritmo YOLOv8

Este capítulo aborda la aplicación de la **visión por computadora** en la entomología, justificando la automatización de la clasificación de mosquitos para superar la lentitud del análisis manual [8]. El algoritmo central seleccionado es **YOLO (You Only Look Once)**, que utiliza una única red neuronal para la detección y clasificación en tiempo real, superando en velocidad a otros sistemas.

La arquitectura **YOLOv8** se utiliza por su superior velocidad y precisión. Se describe su estructura en tres componentes:

- **Backbone (CSPDarknet53):** Extrae características de la imagen.
- **Neck:** Fusiona mapas de características en diferentes escalas.
- **Head:** Genera las predicciones finales de cuadros delimitadores y clases.

Una innovación clave es el enfoque de detección **sin anclas** (*anchor-free*). El modelo se entrena utilizando una función de pérdida compuesta que incluye **CIOU (Box Loss)** y **Distribution Focal Loss (DFL)** para la localización precisa.

5.2. Desarrollo del Conjunto de Datos y Entrenamiento

Se creó un conjunto de datos personalizado de *Aedes aegypti* (cepa Rockefeller) en el IICS, Paraguay, compuesto por 1,199 imágenes capturadas en un entorno controlado .

- **Anotación:** Las imágenes se etiquetaron manualmente en cinco categorías, siendo las principales **Hembra** y **Macho**, e incluyendo clases de error ("Fuera de foco", "Incompleto" e "Indefinido") para aumentar la robustez del sistema
- **Aumento de Datos:** Se aplicaron transformaciones geométricas y fotométricas para triplicar el conjunto de entrenamiento (a 2,157 imágenes), mitigando el sobreajuste y mejorando la generalización a condiciones de campo variables.

5.3. Resultados Experimentales y Despliegue

El modelo **YOLOv8-small (YOLOv8s)** fue seleccionado por ofrecer el mejor compromiso entre precisión y velocidad de inferencia. Se determinó que un entrenamiento de **40 épocas** (Figura 11) con una resolución de 640×640 era el punto de convergencia adecuado.




Fig. 11: Curvas de pérdida de entrenamiento para YOLOv8-small durante 40 épocas. El eje x representa el número de épocas, y el eje y muestra los valores de pérdida correspondientes. **Fuente:** Elaboración propia, generado por el framework Ultralytics (YOLOv8).

5.3.1. Rendimiento del Modelo

El análisis cualitativo y la **Matriz de Confusión (Tabla 2)** confirmaron el alto rendimiento del modelo para clasificar las clases primarias (**Hembra** y **Macho**). La matriz también reveló un menor rendimiento para clases minoritarias y una dificultad para la distinción de la clase "Fondo", lo cual es común en la detección de objetos.

5.3.2. Despliegue en Hardware Embebido

Las pruebas en plataformas de bajos recursos arrojaron resultados críticos para el diseño mecatrónico:

- **Orange Pi Zero:** Tiempo de inferencia promedio de **9.83 segundos** (inadecuado para tiempo real).
- **Raspberry Pi 5:** Tiempo de inferencia promedio de **1.18 segundos** (prometedor para despliegue en campo).

Estos resultados guían la selección final del hardware para el prototipo.

6. Diseño y Construcción de la Trampa Mecatrónica

6.1. Arquitectura y Flujo de Operación

Este capítulo describe el diseño, fabricación y ensamblaje de la **trampa automatizada**, cuyo objetivo es recolectar datos de forma no letal y selectiva. La arquitectura del sistema es distribuida, coordinada por una **Orange Pi** (procesamiento de alto nivel) y un **Arduino UNO** (control de actuadores en tiempo real)

6.2. Diseño Mecánico y Fabricación

El diseño, modelado en **Onshape** (Figura 12), prioriza la modularidad.

- **Estructura Externa:** Fabricada con **madera terciada marina** y sellada para resistir la intemperie.
- **Módulo de Captura:** Compuesto por un **tubo de inspección** impreso en 3D (Figura 13) y un **mecanismo de iris** accionado por un servomotor (Figura 16). Este mecanismo fue elegido por su **cierre rápido y no letal**.
- **Atrayente:** Se descartaron los cebos comerciales en favor de una **infusión de pasto fermentado**, adoptada tras consulta con expertos del IICS, por su alta eficacia para atraer hembras grávidas (*Aedes aegypti*).
- **Prototipado:** Se documenta la evolución del diseño (Prototipos 1 y 2, Figuras 14 y 15), que condujo a un enfoque modular más robusto y funcional.

6.3. Diseño Electrónico e Integración

El subsistema electrónico utiliza componentes de bajo costo:

- **Orange Pi Zero 3:** Ejecuta el cliente de video, comunicación TCP (Figura 18) y comandos de alto nivel.
- **Arduino UNO:** Controlador de bajo nivel que gestiona el servomotor (iris) y el ventilador a través de un módulo de relé, utilizando una lógica de control reactiva (Figura 17).

6.4. Resultados de Funcionamiento y Validación

La validación se realizó mediante pruebas controladas en laboratorio con 50 mosquitos (*Aedes aegypti*).

- **Precisión General:** La precisión global del prototipo fue del **86%** ((31 hembras + 12 machos)/50).
- **Matriz de Confusión (Tabla 2):** Demostró una **Precisión para Hembras del 100%** (cero falsos positivos), lo cual es crucial para la vigilancia epidemiológica.




Fig. 12: Ensamblaje completo de la trampa en Onshape, mostrando la disposición interna de los componentes mecánicos y electrónicos. **Fuente:** Elaboración propia (Diseño CAD en Onshape).






Fig. 13: Modelo CAD del tubo de inspección. Se aprecian la base cuadrada para el montaje del ventilador y las perforaciones para la sujeción de la cámara y el iris. **Fuente:** Elaboración propia (Diseño CAD en Onshape)

TABLA 2: Matriz de confusión de la validación experimental del prototipo completo. **Fuente:** Elaboración propia.

	Clase Predicha por el Sistema		
	Hembra	Macho	Fuera de Foco
Clase Real: Hembra (35)	31	0	4
Clase Real: Macho (15)	0	12	3

**Fig. 14:** Diseño CAD del Prototipo 1, basado en un cono invertido. **Fuente:** Elaboración propia (Diseño CAD en Onshape).**Fig. 16:** Diseño del mecanismo de iris con el servomotor acoplado. Las palas se deslizan para cerrar la apertura central de forma rápida y controlada. **Fuente:** Elaboración propia (Diseño CAD en Onshape).

- **Análisis de Errores:** Los únicos errores (14%) fueron clasificados correctamente como "Fuera de Foco", sin incurrir en errores de clasificación cruzada de sexo, lo que valida la robustez del modelo de diferenciación.

Los resultados confirman que el diseño mecatrónico finalizado es una plataforma viable y precisa para la vigilancia entomológica automatizada.


7. Conclusión

El capítulo concluye el proyecto, confirmando la **viabilidad técnica** de integrar en un único sistema: captura, clasificación automatizada de mosquitos por visión artificial, y un marco analítico predictivo. El uso de la red neuronal **YOLOv8** demostró ser adecuado para la diferenciación morfológica de insectos para tareas de monitoreo vectorial.

7.1. Síntesis de Aportes y Limitaciones

El trabajo generó contribuciones significativas en tres pilares interconectados:

- **Modelo Matemático de Dinámica Poblacional (Cap. 4):**
Aporte: Se estableció un marco analítico basado en **EDOs** que utiliza la temperatura y la precipitación para generar escenarios predictivos de abundancia vectorial, calibrados para el contexto climático de Paraguay.
Limitación: La validación actual del modelo aún depende de datos históricos externos.
- **Sistema de Visión por Computadora (Cap. 5):**
Aporte: Se validó el uso de **Deep Learning (YOLOv8)** para la vigilancia entomológica, logrando una clasificación automática del sexo del *Aedes aegypti* en tiempo real. La validación mostró un **100% de precisión para hembras** (cero falsos positivos) y una sensibilidad del 88.6%.

**Fig. 15:** Estructura piramidal con espacio interior para el prototipo 2. **Fuente:** Elaboración propia (Diseño CAD en Onshape).




Fig. 17: Diagrama de flujo para el control de los actuadores en el Arduino. **Fuente:** Elaboración propia.




Fig. 18: Diagrama de flujo del cliente de la cámara de video en la Orange Pi. **Fuente:** Elaboración propia.

Limitación: La principal limitación reside en la calidad de la **captura de imagen**, lo que resulta en un porcentaje de muestras descartadas por estar "fuera de foco".

• **Diseño Mecatrónico y Prototipo (Cap. 6):**

Aporte: Se construyó un prototipo funcional, modular, **no letal** y de **bajo costo**, utilizando componentes de electrónica abierta (Orange Pi/Arduino). La innovación clave es el **mecanismo de iris** para la captura y liberación controlada. Se validó la eficiencia del cebo gravídico de pasto fermentado.

Limitación: El sistema aún **depende de un Servidor PC externo** para ejecutar el modelo de Visión por Computadora en tiempo real.

7.2. Recomendaciones para Trabajos Futuros

Se establecen las siguientes líneas de investigación para consolidar y escalar la solución:

- **Portabilidad y Autonomía:** Migrar el modelo de IA a la Orange Pi para eliminar la dependencia de un PC externo y optimizar la autonomía energética y la robustez estructural para el despliegue en campo.
- **Clasificación Específica:** Ampliar la base de datos para habilitar la **clasificación por especies**, aumentando el valor epidemiológico del sistema.
- **Integración IoT:** Implementar conectividad continua para el envío automático de registros a una plataforma centralizada (servidor web/base de datos), permitiendo la vigilancia remota.
- **Validación del Modelo:** Realizar una validación exhaustiva del modelo predictivo utilizando **series temporales ambientales extensas** y contrastando los resultados con los datos de captura reales generados por la trampa en condiciones de campo.

Este trabajo representa un avance significativo hacia el desarrollo de herramientas tecnológicas accesibles y escalables para el monitoreo inteligente de vectores en Paraguay.

8. Referencias

- [1] C. A. Day, S. L. Richards, M. H. Reiskind, M. S. Doyle, and B. D. Byrd, "Context-dependent accuracy of the bg-counter remote mosquito surveillance device in north carolina," *Journal of the American Mosquito Control Association*, vol. 36, no. 2, pp. 74–80, 2020.
- [2] H. T. Hongre Kudo, "Diseño e Implementación de un Sistema Mecatrónico de Clasificación de Mosquitos," 2024.
- [3] D. Balbuena, M. Barrios, D. H. Stalder, C. E. Schaerer, N. González, and M. Ferreira, "Understanding effects of temperature and precipitation in the dynamics of the mosquito population," in *Proceeding Series of the Brazilian Society of Computational and Applied Mathematics*, vol. 11, no. 1, 2025, trabalho apresentado no XLIII CNMAC, 2024.
- [4] W. A. Nazni and A. A. Hoffmann, "Introduction of aedes aegypti mosquitoes carrying walbb wolbachia sharply decreases dengue incidence in disease hotspots," *iScience*, vol. 27, no. 2, 2024.
- [5] (2024) Borne électrique anti-moustiques lami v3, l'anti-moustiques intelligent. Fabrique en Occitanie. [Online]. Available: <https://www.fabrique-en-occitanie.fr/produits/borne-electrique-anti-moustiques-lami-v3-lanti-moustiques-intelligent/>
- [6] S. A. Ritchie, T. S. Buhagiar, M. Townsend, A. Hoffmann, A. F. Van Den Hurk, J. L. McMahon, and A. E. Eiras, "Field validation of the gravid aedes trap (gat) for collection of aedes aegypti (diptera: Culicidae)," *Journal of Medical Entomology*, vol. 51, no. 1, pp. 210–219, Jan 2014.
- [7] D. B. Meyer, B. J. Johnson, K. Fall, T. S. Buhagiar, M. Townsend, and S. A. Ritchie, "Development, optimization, and field evaluation of the novel collapsible passive trap for collection of mosquitoes," *Journal of Medical Entomology*, vol. 55, no. 3, pp. 706–710, May 2018.
- [8] K. Okayasu, K. Yoshida, M. Fuchida, and A. Nakamura, "Vision-based classification of mosquito species: Comparison of conventional and deep learning methods," *Applied Sciences*, vol. 9, no. 18, p. 3935, 2019.
- [9] C. S. Bibbs, N. Reissen, M. A. Dewsnup, R. B. Sorensen, A. Faraji, and G. S. White, "Do it yourself: 3d-printed miniature cdc trap for adult mosquito (diptera: Culicidae) surveillance," *PLOS Neglected Tropical Diseases*, vol. 18, no. 1, p. e0011899, 2024.
- [10] W. Liu, Y. Wang, Y. Chen, B. Chen, A. Lin, S. Dai, C. Chen, and L. Liao, "An iot-based smart mosquito trap system embedded with real-time mosquito image processing by neural networks for mosquito surveillance," *Frontiers in Bioengineering and Biotechnology*, vol. 11, p. 1100968, 2023.
- [11] H. M. Yang and M. L. G. Macoris, "Assessing the effects of temperature on the population of aedes aegypti, the vector of dengue," *Epidemiology and Infection*, vol. 137, no. 8, pp. 1213–1221, 2009.
- [12] J. Chen, X. Huo, A. B. B. Wilke, J. C. Beier, C. Vasquez, W. Petrie, R. S. Cantrell, C. Cosner, and S. Ruan, "Linking mathematical models and trap data to infer the proliferation, abundance, and control of aedes aegypti," *Acta Tropica*, vol. 239, p. 106837, 2023.
- [13] National Oceanic and Atmospheric Administration (NOAA) / National Centers for Environmental Prediction (NCEP), "Global Data Assimilation System (GDAS)," [Online], 2024. [Online]. Available: <https://www.ncep.noaa.gov/>
- [14] E. A. Mordecai, J. M. Cohen, M. V. Evans, P. Gudapati, L. R. Johnson, C. A. Lippi, K. Miazgowiec, C. C. Murdock, J. R. Rohr, S. J. Ryan *et al.*, "Detecting the impact of temperature on transmission of zika, dengue, and chikungunya using mechanistic models," *PLoS neglected tropical diseases*, vol. 11, no. 4, p. e0005568, 2017.