

UNIVERSIDAD DEL VALLE DE GUATEMALA

Facultad de Ingeniería



**Aplicación para el conteo y clasificación de huevos de
mosquito con inteligencia artificial**

Trabajo de graduación en modalidad de Tesis presentado por José Pablo Ponce Pivaral para optar al grado académico de Licenciado en Ingeniería en Ciencia de la Computación y Tecnologías de la Información

Guatemala,

2023

UNIVERSIDAD DEL VALLE DE GUATEMALA

Facultad de Ingeniería



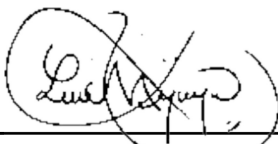
**Aplicación para el conteo y clasificación de huevos de
mosquito con inteligencia artificial**

Trabajo de graduación en modalidad de Tesis presentado por José Pablo Ponce Pivaral para optar al grado académico de Licenciado en Ingeniería en Ciencia de la Computación y Tecnologías de la Información

Guatemala,

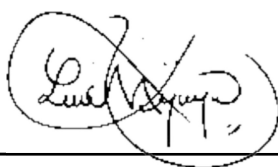
2023

Vo.Bo.:


(f) 

Ing. Luis Guillermo Mijangos

Tribunal Examinador:

(f) 

Ing. Luis Guillermo Mijangos

(f) 

Ing. Leonel Guillén

(f) 

Ing. Douglas Barrios

Fecha de aprobación: Guatemala, 05 de diciembre de 2023.

La realización de este proyecto de graduación ha sido una experiencia de aprendizaje, marcada por la interacción y colaboración de numerosos individuos que desempeñaron un papel clave en su desarrollo. Cada paso del proceso, desde la conceptualización hasta la implementación, ha sido una combinación de esfuerzo, dedicación y aprendizaje.

Primero, quisiera expresar mi sincero agradecimiento a Ana Cristina Benedict Villagran y a la Dra. Norma Renee Padilla Caballeros, quienes son parte del Centro de Estudios en Salud, de la Unidad de Entomología Médica y Malaria, del Instituto de Investigaciones de la Universidad del Valle de Guatemala. Su generosidad al brindarme los sustratos de huevos de mosquitos fue esencial para la viabilidad y precisión de este proyecto. Su colaboración y confianza en mi capacidad para llevar a cabo este trabajo son invaluable.

Un reconocimiento especial es debido a Erlin Renaldo Ayala Ramos, quien no sólo me proveyó de una cámara profesional esencial para la documentación visual del proyecto, sino que también me brindó su conocimiento y recomendaciones para capturar imágenes de la mejor calidad posible. Su apoyo y consejos sobre técnicas de fotografía han sido determinantes para el éxito de esta investigación.

No puedo dejar de mencionar al Ingeniero Luis Guillermo Mijangos Fuentes, mi asesor durante este viaje académico. Su guía, experiencia y constante apoyo han sido pilares fundamentales en cada fase del desarrollo del proyecto. Estoy profundamente agradecido por su paciencia, consejos y la confianza depositada en mí y en mi trabajo.

Además, agradezco a mis compañeros y a mi familia, quienes con su apoyo incondicional y aliento, me impulsaron a seguir adelante.

Prefacio	III
Lista de figuras	VIII
Lista de tablas	IX
Resumen	X
Abstract	XI
1 Introducción	1
2 Antecedentes	2
3 Justificación	3
4 Objetivos	4
4.1 Objetivo general	4
4.2 Objetivos específicos	4
5 Marco Teórico	5
5.1 Introducción al Problema	5
5.2 Ciclo de Vida de los Mosquitos y Significado de los Tipos de Huevos	6
5.2.1 Huevos	6
5.2.2 Larva	8
5.2.3 Pupa	8
5.2.4 Adulto	8
5.3 YOLO y la Detección de Objetos	9
5.3.1 Elección de YOLO sobre Alternativas	9
5.3.2 Arquitectura	9
5.3.3 Eficiencia y Escalabilidad	10
5.3.4 Detección de Objetos con Segmentación de Instancias	10
5.3.5 Precisión en la Detección y Clasificación	10
5.3.6 Entrenamiento y Transferencia de Aprendizaje	11

5.4	Relevancia y Potencial Impacto en la Salud Pública	11
5.5	Validación y Confiabilidad del Modelo	12
5.5.1	División de Datos y Configuración del Entrenamiento	12
5.5.2	Métricas de Evaluación	13
5.6	Tecnologías y Técnicas de diseño Web	14
6	Metodología	15
6.1	Enfoque de Gestión Basado en Metodologías Ágiles	15
6.1.1	Justificación de Enfoque Ágil	15
6.1.2	Implementación Adaptada de Scrum	16
6.1.3	Iteración y Retroalimentación con el Cliente	16
6.2	Recolección de Imágenes	17
6.2.1	Medidas de Seguridad	17
6.2.2	Proceso de Fotografía	17
6.2.3	Resultados de la Recolección	21
6.3	Optimización del Conjunto de Datos	21
6.3.1	Partición del Conjunto de Datos	21
6.3.2	Selección de Técnicas de Preprocesamiento y Aumentación	21
6.3.3	Técnicas de Preprocesamiento Elegidas	22
6.3.4	Técnicas de Aumentación Elegidas	22
6.3.5	Resultados del Preprocesamiento y Aumentación	23
6.4	Investigación y Selección de Modelo de Aprendizaje Profundo	23
6.4.1	Revisión de Modelos Existentes	23
6.4.2	Definición de Métricas de Evaluación	24
6.4.3	Análisis Comparativo	24
6.4.4	Comparación entre Versiones de YOLO	25
6.4.5	Criterios de Selección de Modelo	25
6.4.6	Selección de YOLOv8	25
6.4.7	Configuración y Parámetros de Entrenamiento	25
6.4.8	Variantes del Modelo	26
6.5	Desarrollo y Hospedaje de Aplicación Web	26
6.5.1	Interfaz y Diseño	27
6.5.2	Datos Generales y Específicos de Conteo de Huevecillos	27
6.5.3	Detalles Funcionales de la Aplicación	28
7	Resultados	31
7.1	Experimentos Iniciales	31
7.2	Optimización con Adam con $lr_0 = 0.001$	31
7.3	Optimización con Adam con $lr_0 = 0.01$	37
7.4	Optimización con SGD con $lr_0 = 0.01$	39
7.5	Optimización con SGD con $lr_0 = 0.001$	41
7.6	Comparación de Métodos de Conteo	43
8	Discusión de Resultados	44
9	Conclusiones	48
10	Recomendaciones	49

11 Bibliografía	50
12 Anexos	52
12.1 Anexo 1: Manual de Usuario para la Aplicación Web	52
12.1.1 Acceso a la Plataforma	52
12.1.2 Navegación Principal	52
12.1.3 Realizar Conteo	53
12.1.4 Historial	53

Figura 1. Ciclo de vida del mosquito	6
Figura 2. Representación de huevos viables	7
Figura 3. Representación de huevos en canoa	7
Figura 4. Representación de huevos eclosionados	8
Figura 5. Tablero de Azure	17
Figura 6. Proceso de captura desde el iphone 12	18
Figura 7. Resultado de las imágenes capturadas con iphone 12	18
Figura 8. Resultado de las imágenes capturadas con cámara Mevo	19
Figura 9. Proceso de captura desde telescopio adaptable	19
Figura 10. Proceso de captura desde cámara Canon adaptada al estereoscopio	20
Figura 11. Resultado de las imágenes capturadas con cámara Canon	20
Figura 12. Pantalla de Conteo	28
Figura 13. Pop-up mostrando las Imágenes Etiquetadas	29
Figura 14. Pop-up mostrando las Tablas con Información del Conteo	29
Figura 15. Módulo de Historial General	29
Figura 16. Módulo de Historial Detallado	30
Figura 17. Matriz de Confusión obtenida menos favorable usando Adam con $lr0 = 0.001$	31
Figura 18. Resultados del entrenamiento usando Adam con $lr0 = 0.001$	32
Figura 19. Matriz de confusión normalizada en entrenamiento usando Adam con $lr0 = 0.001$	33
Figura 20. Curva MASKF1 en entrenamiento usando Adam con $lr0 = 0.001$	33
Figura 21. Curva Precisión-Confianza en entrenamiento usando Adam con $lr0 = 0.001$	33
Figura 22. Curva BoxF1 en entrenamiento usando Adam con $lr0 = 0.001$	34
Figura 23. Curva Precisión-Sensibilidad para detección de cajas en entrenamiento usando ADAM con $lr0 = 0.001$	34
Figura 24. Matriz de confusión normalizada en validación usando Adam con $lr0 = 0.001$	35
Figura 25. Curva MASKF1 en validación usando Adam con $lr0 = 0.001$	35
Figura 26. Curva Precisión-Confianza en validación usando Adam con $lr0 = 0.001$	36
Figura 27. Curva Precisión-Sensibilidad para detección de cajas en validación usando ADAM con $lr0 = 0.001$	36
Figura 28. Detección de Huevos de Mosquito 1	37
Figura 29. Detección de Huevos de Mosquito 2	37

Figura 30. Curva Precisión-Sensibilidad para detección de cajas en validación usando Adam con $lr0 = 0.01$	39
Figura 31. Matriz de confusión normalizada en validación usando Adam con $lr0 = 0.01$	39
Figura 32. Curva Precisión-Sensibilidad para detección de cajas en validación usando SGD con $lr0 = 0.01$	40
Figura 33. Matriz de confusión normalizada en validación usando SGD con $lr0 = 0.01$	41
Figura 34. Curva Precisión-Sensibilidad para detección de cajas en validación usando SGD con $lr0 = 0.001$	42
Figura 35. Matriz de confusión normalizada en validación usando SGD con $lr0 = 0.001$	42

Lista de tablas

Tabla 1.	Valores y parámetros utilizados en las técnicas de aumentación	23
Tabla 2.	Comparación de métricas de rendimiento entre RetinaNet, SSD, y YOLOv3	24
Tabla 3.	Comparación de métricas de rendimiento entre Faster R-CNN, SSD, y YOLOv3	24
Tabla 4.	Parámetros de entrenamiento del modelo YOLOv8	26
Tabla 5.	Variantes de entrenamiento del modelo YOLOv8	26
Tabla 6.	Resultados de entrenamiento con optimizador ADAM y $lr0 = 0.001$	32
Tabla 7.	Resultados de validación con optimizador ADAM y $lr0 = 0.001$	35
Tabla 8.	Resultados de entrenamiento con optimizador ADAM y $lr0 = 0.01$	38
Tabla 9.	Resultados de validación con optimizador ADAM y $lr0 = 0.01$	38
Tabla 10.	Resultados de entrenamiento con optimizador SGD y $lr0 = 0.01$	40
Tabla 11.	Resultados de validación con optimizador SGD y $lr0 = 0.01$	40
Tabla 12.	Resultados de entrenamiento con optimizador SGD y $lr0 = 0.001$	41
Tabla 13.	Resultados de validación con optimizador SGD y $lr0 = 0.001$	42
Tabla 14.	Comparación de tiempos entre el modelo YOLOv8 y el conteo manual con fotos	43
Tabla 15.	Resultados del conteo entre el modelo YOLOv8 y el conteo manual con fotos	43
Tabla 16.	Resultados del conteo manual sin fotos por un investigador	43

Este proyecto aborda la identificación y clasificación automática de huevos de mosquito *Aedes aegypti* a partir de imágenes, esencial para el control de enfermedades como dengue, malaria y Zika. Utilizando el modelo de aprendizaje profundo YOLOv8, se logró una precisión general de 0.854 y una sensibilidad de 0.892. Específicamente, se alcanzó un mAP50 de 0.963 para huevos eclosionados, 0.897 para huevos en canoa y 0.944 para huevos viables. La solución se implementó en una aplicación web desarrollada en Angular con Bootstrap y NG-Zorro, permitiendo cargar imágenes y obtener detalles de clasificación y conteo a través de una API en Roboflow. El modelo fue entrenado con los optimizadores Adam y SGD, demostrando alta precisión y eficiencia. Aunque hubo desafíos en la clasificación de huevos en canoa, la herramienta proporciona resultados precisos y confiables, facilitando el trabajo de los investigadores del Centro de Estudios en Salud, de la Unidad de Entomología Médica y Malaria, del Instituto de investigaciones de la Universidad del Valle de Guatemala.

Abstract

This project addresses the automatic identification and classification of *Aedes aegypti* mosquito eggs from images, which is essential for controlling diseases such as dengue, malaria, and Zika. Utilizing the deep learning model YOLOv8, an overall accuracy of 0.854 and a sensitivity of 0.892 were achieved. Specifically, an mAP50 of 0.963 was reached for hatched eggs, 0.897 for canoe eggs, and 0.944 for viable eggs. The solution was implemented in a web application developed in Angular with Bootstrap and NG-Zorro, allowing users to upload images and obtain classification and counting details through an API in Roboflow. The model was trained with Adam and SGD optimizers, demonstrating high accuracy and efficiency. Although there were challenges in classifying canoe eggs, the tool provides precise and reliable results, facilitating the work of researchers at the Center for Health Studies, the Medical Entomology and Malaria Unit, and the Research Institute of Universidad del Valle de Guatemala.

CAPÍTULO 1

Introducción

Los mosquitos, son una parte integral para el ecosistema mundial, ya que generan un impacto significativo en la salud humana y animal. Por un lado, son vitales para la biodiversidad al actuar como polinizadores, pero, por otro, algunas especies son portadoras de enfermedades peligrosas como el dengue, la malaria y el Zika. La naturaleza dual de estos insectos hace que su estudio y monitoreo sean esenciales para la salud humana y la preservación del ecosistema.

Para controlar efectivamente la propagación de enfermedades transmitidas por mosquitos, es crucial monitorear sus poblaciones. Una técnica ampliamente utilizada para este propósito es el conteo de huevos. Los huevos de mosquito son notables por su resistencia a la desecación y su capacidad para permanecer viables durante meses. Al analizar estos huevos, es posible identificar picos de actividad reproductiva y como resultado, implementar medidas para prevenir la proliferación masiva de mosquitos.

Sin embargo, el tradicional método de conteo manual presenta desafíos significativos, esto ya que consume mucho tiempo y es susceptible al error humano. Para abordar estos desafíos y modernizar el proceso de monitoreo, se propone una solución innovadora en este proyecto. Utilizando la inteligencia artificial, se ha desarrollado una aplicación web que, a partir de una fotografía de los huevos de mosquito, realiza un conteo y clasificación automatizado, identificando huevos viables, en canoa y eclosionados.

Se destaca el uso del modelo YOLOv8 para la detección y clasificación precisa de huevos de mosquito, así como la implementación de Angular, reforzado con Bootstrap y NG-Zorro, para desarrollar una interfaz web intuitiva y eficiente. Este informe detalla la problemática abordada, las soluciones tecnológicas propuestas y las conclusiones clave obtenidas a lo largo del proceso de investigación y desarrollo.

En el camino hacia la automatización del conteo de huevos de mosquito, se ha explorado previamente el software ICount para contar huevos de *Aedes aegypti*, facilitando la estimación de la fecundidad de estos mosquitos (Gaburro et al., 2016). Por otro lado, MECVision utilizó visión por computadora para estimar el número de huevos de mosquito en trampas de papel, enfocado en combatir enfermedades como el Zika (Krieshok & Torres Gutierrez, 2020). Ambas soluciones representaron avances significativos en la automatización del conteo de huevos, aunque no abordaron la clasificación de la viabilidad de los huevos, crucial para entender mejor las poblaciones de mosquitos y combatir enfermedades transmitidas por mosquitos.

En el ámbito de la clasificación y detección de objetos mediante imágenes, diversos modelos de aprendizaje profundo y técnicas de visión por computadora podrían ser aplicables a la tarea de clasificación y conteo de huevos de mosquitos. Modelos como Faster R-CNN, SSD, RetinaNet, y versiones de YOLO han demostrado ser eficaces en detección y clasificación de objetos en diversas aplicaciones. Sin embargo, cada uno de estos modelos posee características distintas en términos de precisión, velocidad de procesamiento y complejidad, lo que los hace más o menos adecuados para diferentes tareas.

En el contexto específico de clasificar y contar huevos de mosquitos en imágenes, se requiere un modelo que no solo sea preciso, sino también rápido y eficiente, dado el potencial volumen de datos a procesar. Además, la capacidad de segmentar instancias individuales de objetos es crucial para diferenciar y clasificar correctamente los huevos de mosquitos, añadiendo otra capa de complejidad a la selección del modelo adecuado.

El presente proyecto busca no solo contar los huevos de mosquitos, sino también clasificarlos en categorías de viabilidad, lo que enriquece significativamente el análisis y la comprensión de las poblaciones de mosquitos. Esta meta introduce la necesidad de explorar modelos de aprendizaje profundo más avanzados, que puedan abordar efectivamente tanto la detección como la clasificación de huevos de mosquitos, estableciendo una base sólida para la selección del modelo de aprendizaje profundo más adecuado.

Debido a la evolución de la inteligencia artificial, existen gran cantidad de campos y aplicaciones en las que se puede utilizar y aplicar esta disciplina. Por lo que si se le diera un enfoque hacia la biología, se podría utilizar para la recolección y el monitoreo de datos para controlar las poblaciones de mosquitos. Esto ya que gran cantidad de las tareas de análisis y recolección de datos se tienen que realizar de manera manual y conllevan una gran cantidad de tiempo. El problema que puede surgir de esto, es el error humano al tratar de contabilizar tantos datos, lo que conlleva a que se tomen decisiones erróneas que pueden afectar a diversas áreas donde puede ser necesario contar huevos de mosquito.

Los mosquitos son uno de los insectos más relevantes en cuanto a la transmisión de agentes patógenos virales, entre los que se encuentran el dengue, zika, chikungunya, fiebre amarilla, entre otros (Organización Panamericana de la Salud, 2019). Por lo tanto, contar los huevos de manera rápida y eficiente puede beneficiar a los programas de control de enfermedades al detectar y controlar las poblaciones de este insecto antes de que puedan propagarse las enfermedades derivadas de los mismos.

Un aspecto crítico a tener en cuenta de los mosquitos es que los huevos tienen resistencia a la desecación, por lo que pueden permanecer viables en recipientes por meses. Esto les permite desarrollar resistencia como población ante medidas de control y fenómenos ambientales como sequías (Organización Panamericana de la Salud, 2019). Es importante tener un control de los huevos, lo cual le permite a los científicos monitorear cambios en la población de mosquitos de una zona específica, permitiendo que se puedan ajustar las medidas de control.

Por último, cabe destacar que los mosquitos también son polinizadores importantes, por lo que conocer su población puede ser útil para el estudio y conservación de la biodiversidad.

4.1. Objetivo general

Desarrollar un modelo de aprendizaje profundo que permita clasificar de manera adecuada los distintos tipos de huevos de mosquito de la especie *Aedes aegypti*.

4.2. Objetivos específicos

- Investigar y comparar algoritmos para la detección y clasificación de huevos, seleccionando el más adecuado según criterios de rendimiento y aplicabilidad.
- Establecer un procedimiento de fotografía que facilite la interpretación de las imágenes por el algoritmo.
- Desarrollar una interfaz de usuario que permita a los usuarios realizar la clasificación, el conteo y el registro de huevos.

5.1. Introducción al Problema

Hoy en día, los mosquitos son una parte integral del ecosistema mundial, esto debido a que generan un impacto significativo en la salud humana y animal puesto que algunas especies de mosquitos son vectores de enfermedades peligrosas, entre estas enfermedades se encuentran las mas conocidas como el dengue, la malaria y el zika (Abd, 2020). Por otro lado, los mosquitos no solo emplean un papel dañino, ya que son grandes polinizadores para los ecosistemas y de igual manera son un alimento para distintas especies de animales (Lahondère et al., 2019), por ende se puede considerar que los mosquitos son una especie crucial para la conservación de la biodiversidad.

En este contexto, el Centro de Estudios en Salud, de la Unidad de Entomología Médica y Malaria, del Instituto de Investigaciones de la Universidad del Valle de Guatemala, tiene un papel fundamental en la lucha contra enfermedades transmitidas por mosquitos en la región centroamericana. Su objetivo principal es mejorar la salud y bienestar de la población guatemalteca. Las actividades del Centro de Estudios en Salud abarcan desde el almacenamiento de mosquitos hasta el proceso de secado de huevos en sustratos y su posterior observación con estereoscopios en habitaciones de temperatura controlada. Este enfoque detallado resalta los desafíos enfrentados por los investigadores en el conteo y clasificación de huevos de mosquito (Centro de Estudios en Salud, 2022).

Adicionalmente, es esencial resaltar el diverso trabajo del Centro de Estudios en Salud, ya que no sólo realiza investigaciones vitales para entender y combatir enfermedades transmitidas por mosquitos, sino que también se enfoca en enfermedades humanas de relevancia para Guatemala y la región centroamericana, combinando actividades de campo y laboratorio en un enfoque multidisciplinario (Centro de Estudios en Salud, 2022). Esto los posiciona como una referencia clave en la lucha contra las enfermedades y en la aplicación práctica de sus investigaciones para impulsar soluciones innovadoras en salud pública.

En consecuencia, para poder entender y controlar la propagación de enfermedades

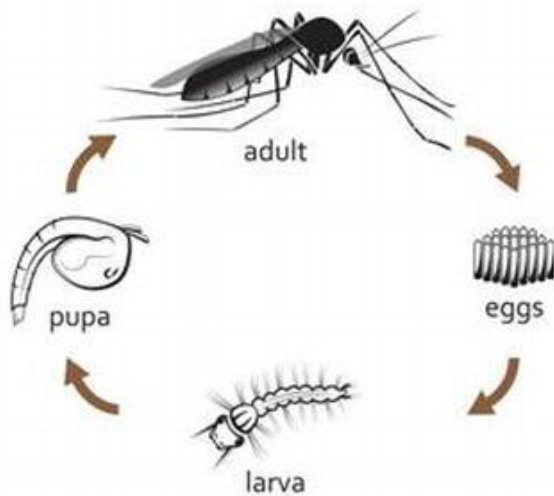
transmitidas por mosquitos, es necesario el monitoreo y control de las poblaciones de este insecto. Para lograr esto, una técnica generalmente utilizada es el conteo de huevos de mosquito, esto debido a que los huevos tienen resistencia a la desecación, por lo que permanece viables por un periodo de hasta 8 meses (Organización Panamericana de la Salud, 2019). Por lo mismo, al contar y clasificar los huevos de mosquito se pueden determinar picos de actividad reproductiva y en consecuencia se logran tomar medidas para controlar las futuras poblaciones de mosquitos. El problema que conlleva este tipo de conteos es que se necesita realizar manualmente, por lo que se toma una gran cantidad de tiempo poder lograr esto. Tal es el caso que un solo mosquito puede poner entre 100 y 200 huevos a la vez y esto lo pueden realizar hasta 5 veces por periodo (Imam et al., 2014).

5.2. Ciclo de Vida de los Mosquitos y Significado de los Tipos de Huevos

Los mosquitos experimentan un proceso de desarrollo que implica múltiples etapas y desempeñan un papel crucial en la comprensión de su ecología, distribución geográfica y capacidad para transmitir enfermedades. Su ciclo vital consta de cuatro fases distintas: huevos, larvas, pupas y adultos (Abd, 2020), como se observa en la Figura 1.

Figura 1

Ciclo de vida del mosquito



Nota: Adaptado de *Ciclo de vida y estudio citogenético de los mosquitos (Diptera: Culicidae)*, por Abd, 2020.

5.2.1 Huevos

En esta fase, las hembras buscan un lugar húmedo para colocar sus huevos, los cuales tienen una forma larga y cilíndrica, y son de color marrón, tardando aproximadamente entre 24 y 30 horas en eclosionar. Dependiendo del entorno en el que se encuentren, su forma y desarrollo pueden variar. Para monitorear y controlar la población de huevos, estos se clasifican como huevos viables, huevos en canoa y huevos eclosionados. Estas categorías son

útiles para los investigadores y especialistas en control de vectores que desean entender y controlar las poblaciones de mosquitos, ya que cada etapa tiene implicaciones específicas para el control y propagación de enfermedades transmitidas por mosquitos (Abd, 2020). A continuación, se describen brevemente los distintos tipos de huevos de mosquito.

Huevos Viables. Son aquellos huevos que se encuentran sanos y tienen el potencial de desarrollarse en larvas bajo las condiciones adecuadas. Estos huevos no han sido dañados y tienen todas las condiciones biológicas para poder continuar con su desarrollo (Mayilsamy, 2019), como se observa en la Figura 2.

Figura 2

Representación de huevos viables



Nota: Elaboración propia.

Huevos en Canoa. Son huevos que no se desarrollaron correctamente o que fueron dañados y no son viables para desarrollar larvas. Se caracterizan por asemejarse a una canoa (Mayilsamy, 2019), como se observa en la Figura 3.

Figura 3

Representación de huevos en canoa



Nota: Elaboración propia.

Huevos Ecllosionados. Son aquellos huevos de los que ya ha emergido una larva. Se caracterizan por tener una apertura desde donde la larva ha salido y, por lo tanto, se encuentran vacíos (Mayilsamy, 2019), como se observa en la Figura 4.

Figura 4

Representación de huevos eclosionados



Nota: Elaboración propia.

5.2.2 Larva

La larva, atraviesa cuatro fases distintas para su eclosión hasta completar tres mudas, cada proceso puede variar entre 1 a 3 días. Durante este periodo, se alimenta de pequeñas cantidades de sustancias orgánicas y de varios microorganismos, como las bacterias, líquenes y hongos (Abd, 2020). Si las larvas se encuentran en un ambiente controlado, la cantidad de alimentación que se les provee dependerá de la cantidad de huevos que se hayan clasificado como viables luego de que se realice un monitoreo y control de los huevos.

5.2.3 Pupa

En su etapa de pupa, las larvas experimentan una mayor transformación que representa la transición entre su fase acuática y la fase terrestre adulta del ciclo de vida del mosquito. Estas presentan características distintivas que las diferencian de las larvas ya que poseen una amplia región de cefalotórax que integra la cabeza, mientras que su extensión caudal simula el abdomen del insecto en su totalidad. A pesar de encontrarse en el agua, las pupas tienen una densidad menor que este medio, lo cual les permite ascender gradualmente a la superficie y en un plazo de entre 24 a 48 horas, la pupa mudara nuevamente para convertirse en adulto (Abd, 2020).

5.2.4 Adulto

Tras emerger, el tamaño del mosquito adulto oscila entre 3.96 y 4.25 mm y está compuesto por una cabeza con dos grandes ojos, un tórax, un par de alas escamosas y seis patas articuladas. El mosquito adulto, tras salir, busca refugio en la vegetación circundante para permitir que sus alas terminen de desarrollarse. A lo largo de su vida, estos insectos requieren fuentes de carbohidratos, por lo tanto, se alimentan del néctar o los exudados de las plantas. Esta alimentación es esencial para mantener la energía necesaria para volar, reproducirse y continuar con su ciclo de vida. Sin embargo, existe una distinción entre la hembra y el macho, ya que la hembra consume sangre para obtener las proteínas requeridas para la formación

de los huevos. Esta particularidad de alimentarse de sangre es la que les permite transmitir diversas enfermedades a humanos y otros animales (Abd, 2020).

5.3. YOLO y la Detección de Objetos

La detección de objetos es esencial en muchas aplicaciones de visión por computadora. En este contexto, YOLO (You Only Look Once) [Sólo Miras Una Vez] ha surgido como un algoritmo destacable, particularmente con su versión más reciente, YOLOv8. Su segmentación de instancias se ha convertido en una característica destacada en la elección del algoritmo para la clasificación y el conteo de huevos de mosquitos de la especie *Aedes aegypti* en grandes conjuntos de imágenes (Solawetz, 2023).

5.3.1 Elección de YOLO sobre Alternativas

En el amplio campo de la detección de objetos, se han desarrollado numerosos algoritmos. Entre las alternativas más importantes que se consideraron para la tarea de clasificar huevos de mosquito de la especie *Aedes aegypti*, destacaron Faster R-CNN, una evolución de las primeras versiones de R-CNN que integra la propuesta de regiones y la detección de objetos en una única red (Ren et al., 2015), SSD (Single Shot Multibox Detector) [Detector de Caja Múltiple de Toma Única], que con el objetivo de equilibrar velocidad y precisión, elimina la propuesta de regiones realizando la detección en una sola pasada (Liu et al., 2016), y RetinaNet, que introduce una función de pérdida focal para tratar el desequilibrio entre fondos y objetos en imágenes (Li & Ren, 2019).

Dentro de la variedad de modelos para la detección de objetos, YOLO fue seleccionado como el modelo más idóneo para la tarea de clasificar y contar huevos de mosquitos en imágenes. La elección de YOLO se basó en su equilibrio entre precisión y velocidad. Aunque existen modelos con precisiones ligeramente superiores, la eficiencia y rapidez de YOLO lo hacen destacar y convertirse en una opción preferente para esta tarea (Solawetz, 2023).

5.3.2 Arquitectura

La arquitectura de YOLOv8 desempeña un papel crucial en la justificación de su elección en esta investigación. Su diseño y el funcionamiento sincronizado de sus componentes son fundamentales para lograr una detección precisa y eficiente de objetos (Solawetz, 2023). A continuación, se realizará un análisis exhaustivo de estos elementos y su contribución dentro del marco arquitectónico de YOLOv8.

Estructura Central. La arquitectura de YOLOv8 se divide en tres componentes principales, tronco, cuello y cabeza. El tronco consiste en una serie de capas convolucionales que procesan la imagen de entrada a diferentes resoluciones y extraen características relevantes. Estas características se fusionan con el cuello para formar una representación unificada de la imagen. Por último la cabeza se encarga de realizar las detecciones de objetos utilizando un enfoque de detección sin anclajes (Solawetz, 2023).

Detección sin Anclajes. Una de las características más destacadas de YOLOv8 es que utiliza una detección sin anclajes. Esto significa que en lugar de predecir en función de anclajes de caja delimitadora, como lo hacen otros modelos, YOLOv8 predice directamente el centro de un objeto. Esta técnica es especialmente útil ya que elimina la necesidad de lidiar con la configuración de anclajes. De igual manera, la ausencia de anclajes permite una detección más eficiente y precisa, lo cual evita problemas relacionados con objetos de formas inusuales o tamaños atípicos (Solawetz, 2023).

Nuevas Capas Convolucionales. La mejora en la estructura de YOLOv8 se extiende a sus capas convolucionales. En primer lugar, se reemplaza la primera capa convolucional de 6x6 de modelos anteriores con una de 3x3. Por otro lado, se ha sustituido C2f por C3 en su arquitectura. Este cambio en las capas convolucionales es significativo ya que mejora la forma en que se procesan las convoluciones en la red neuronal, lo que contribuye a que la detección sea más precisa y rápida de objetos (Solawetz, 2023).

5.3.3 Eficiencia y Escalabilidad

El proceso para poder clasificar y contar huevos de mosquito en grandes conjuntos de datos puede requerir grandes cantidades de recursos. Para este tipo de problemas YOLOv8 destaca por su eficiencia y escalabilidad, lo cual lo convierte en una opción idónea, ya que su capacidad para funcionar de manera eficiente en un hardware limitado permite el procesamiento rápido de grandes cantidades de imágenes (Solawetz, 2023). Esto es esencial cuando se trabaja con conjuntos de datos extensos lo cual permite acelerar el proceso de análisis y obtener resultados de una manera más rápida y eficiente.

5.3.4 Detección de Objetos con Segmentación de Instancias

La segmentación de instancias de YOLOv8 permite que el modelo no solo identifique los huevos, sino que también clasifique con precisión en qué estado se encuentran, proporcionando información valiosa para determinar el tamaño de las futuras poblaciones y si los mosquitos se están desarrollando adecuadamente. Es común que los huevos de mosquitos se superpongan o toquen, lo que dificulta la identificación individual. La segmentación de instancias resuelve este desafío al asignar máscaras únicas a cada huevo, incluso cuando están en contacto (Solawetz, 2023). Esto garantiza que el modelo pueda diferenciar y contar cada huevo de manera precisa, independientemente de su proximidad a otros huevos. Además, la capacidad de separar instancias superpuestas mejora aún más la precisión de la identificación y el conteo. Estas ventajas hacen que YOLOv8 con segmentación de instancias sea una elección sólida para este tipo de tarea.

5.3.5 Precisión en la Detección y Clasificación

La precisión es un aspecto crucial al trabajar en conjuntos de datos de huevos de mosquitos, donde cada huevo cuenta. En este contexto, YOLOv8 ha demostrado tener una alta precisión en tareas de detección y clasificación, especialmente cuando se ha evaluado con conjuntos de datos como COCO (Common Objects in Context) [Objetos Comunes en

Contexto], que es un estándar en la industria para la evaluación de modelos de detección de objetos. El conjunto de datos COCO es altamente respetado en la comunidad de visión por computadora y se utiliza ampliamente para evaluar modelos de detección de objetos. Al comparar diferentes modelos en COCO, dos métricas clave son el mAP y la velocidad de inferencia en FPS. Los resultados de YOLOv8 en el conjunto de datos COCO demuestran una buena precisión, lo cual lo colocan como una herramienta idónea para clasificar y contar huevos de mosquito de la especie *Aedes aegypti* (Solawetz, 2023).

Además de la evaluación en COCO, se han realizado distintas evaluaciones con más conjuntos de datos como el RF100 de Roboflow, que se compone de 100 conjuntos de datos de muestra. Los resultados demuestran que YOLOv8 superó a los otros modelos, justificando su precisión y eficacia en tareas de detección y clasificación precisas (Solawetz, 2023).

5.3.6 Entrenamiento y Transferencia de Aprendizaje

El proceso de entrenamiento de YOLOv8 se beneficia en su capacidad para la transferencia de aprendizaje, esto implica que se pueda iniciar con un modelo preentrenado de un conjunto de datos y ajustarlo específicamente a la tarea de detección y clasificación. Este enfoque es beneficioso ya que permite que el proyecto sea mas escalable y debido a su versatilidad se pueda adaptar a distintas situaciones (Solawetz, 2023), desde el análisis de imágenes de laboratorio hasta la evaluación de huevos en el campo, lo cual es valioso ya que pueden existir imágenes con menor calidad o que la iluminación sea variable.

5.4. Relevancia y Potencial Impacto en la Salud Pública

La detección de huevos de mosquito contribuye directamente a la prevención de enfermedades transmitidas por estos insectos al permitir un monitoreo temprano y preciso de sus poblaciones, ya que diversas especies son portadoras de enfermedades como la malaria, el Zika y el dengue. La capacidad de detectar huevos de mosquito permite a las autoridades de salud pública intervenir de manera temprana y eficiente en áreas donde se detecten picos de actividad de poblaciones de mosquito. Esto puede incluir la implementación de programas para el control de vectores, logrando así controlar la población y evitar su propagación (Gaburro et al., 2016).

El conteo y detección automatizada de los huevos de mosquito puede ser más rentable que los métodos tradicionales de monitoreo de poblaciones de mosquito, que a menudo implican mayor tiempo y personal. Este enfoque ahorra tiempo y recursos, lo cual es esencial, especialmente en regiones con recursos y personal limitados. La intervención temprana y el monitoreo eficiente no solo previenen la propagación de enfermedades, sino que también contribuyen significativamente a la reducción de costos en salud pública y gestión de vectores (Gaburro et al., 2016).

5.5. Validación y Confiabilidad del Modelo

Para garantizar la confiabilidad y efectividad del modelo en aprendizaje profundo, es necesario implementar múltiples estrategias de validación. El objetivo principal es asegurar de que los resultados generados por el modelo no solo sean precisos, sino también consistentes y aplicables a situaciones del mundo real (Lozada, 2022). Aquí se destacan algunas de las prácticas en aprendizaje profundo que se aplicaron para optimizar el rendimiento del modelo.

5.5.1 *División de Datos y Configuración del Entrenamiento*

La configuración del entrenamiento es un aspecto fundamental en la construcción de un modelo de aprendizaje automático, ya que determina en gran medida su rendimiento y capacidad de generalización. Para ello, la división del conjunto de datos en entrenamiento, validación y prueba se realizó asegurando que las categorías de huevos estuvieran lo más equitativamente representadas en cada conjunto, proporcionando de esta manera una base sólida para poder entrenar y evaluar el modelo (Saha, 2023). En este contexto, se detallan los parámetros y técnicas clave utilizadas para optimizar el proceso de entrenamiento del modelo, abarcando aspectos como el tamaño de imagen, la cantidad de épocas, la paciencia, el tamaño de lote, el optimizador y la tasa de aprendizaje, el decaimiento de pesos y el aumento de datos adicional. Cada uno de estos elementos fue seleccionado y ajustado con el objetivo de lograr un equilibrio entre eficiencia computacional y precisión del modelo, asegurando así un aprendizaje robusto y efectivo.

El tamaño de la imagen seleccionado fue el resultado de buscar un equilibrio entre la resolución de la imagen y el tiempo de entrenamiento (Solawetz, 2023). Al elegir un tamaño óptimo, se aspiró a que el modelo pudiera identificar características puntuales y detalladas en la imagen sin que esto resultara en una carga computacional excesiva. Además, el entrenamiento del modelo se llevó a cabo durante un número determinado de épocas, lo que significó que el modelo tuvo múltiples oportunidades de examinar el conjunto de datos en su totalidad y aprender de él. Estas repeticiones son fundamentales para garantizar que el modelo adquiriera una comprensión profunda y óptima de los datos (Lozada, 2022).

A fin de optimizar el proceso de entrenamiento y prevenir problemas como el sobreajuste, se implementó un mecanismo de paciencia. Esto implica que si, durante varias épocas consecutivas, el modelo no demostraba mejora en su rendimiento, el proceso de entrenamiento se interrumpiría. Esta estrategia es eficaz para conservar recursos computacionales y mantener la calidad del modelo. Asimismo, el tamaño de lote seleccionado fue producto de la necesidad de encontrar un equilibrio entre acelerar el entrenamiento y garantizar que las actualizaciones basadas en estos lotes condujeran a un aprendizaje coherente y preciso por parte del modelo (Lozada, 2022).

Finalmente, se incluyó el uso de un optimizador y una tasa de aprendizaje adecuados, así como el decaimiento de pesos y el aumento de datos adicional, para mejorar aún más la capacidad del modelo de aprender de manera eficiente y efectiva. Estos elementos adicionales contribuyeron a afinar el proceso de entrenamiento, asegurando que el modelo no solo aprendiera de manera robusta, sino que también mantuviera su capacidad de generalización frente a nuevas muestras de datos. Esta configuración integral del entrenamiento subraya

la importancia de una selección cuidadosa y equilibrada de parámetros para el éxito en el desarrollo de modelos de aprendizaje automático (Jocher et al., 2023).

Optimizador y Taza de Aprendizaje. El proceso de entrenamiento también involucró la evaluación de diferentes optimizadores. Estos optimizadores se distinguieron por su habilidad para ajustar dinámicamente la tasa de aprendizaje conforme avanza el entrenamiento. Adicionalmente, se exploraron distintas tasas de aprendizaje iniciales. El objetivo principal era hallar un equilibrio que permitiera al modelo converger rápidamente, pero también de manera precisa, evitando así problemas comunes como el estancamiento o el sobreajuste (Lozada, 2022).

Decaimiento de Pesos. El decaimiento de peso se implementó como una estrategia de regularización, con el objetivo principal de penalizar pesos excesivamente grandes dentro del modelo. Esta penalización de pesos grandes actúa como un mecanismo preventivo contra el sobreajuste, permitiendo así que el modelo tenga una mejor capacidad de generalización frente a datos no vistos. Al establecer este decaimiento, se optó por un valor que, sin ser extremadamente bajo, resultara significativo en su impacto. Es decir, se buscó que el valor no fuera tan restrictivo como para limitar la capacidad del modelo, pero al mismo tiempo, que tuviera la relevancia necesaria para influir de manera positiva en la regularización durante el proceso de entrenamiento (Lozada, 2022).

Aumento de Datos Adicional. El aumento de datos es una técnica clave en el aprendizaje automático, ya que permite generar nuevos ejemplos a partir del conjunto de datos original, simulando diversas condiciones y variabilidades. La idea es mejorar la capacidad del modelo para generalizar en situaciones no vistas previamente, sin incurrir en el coste y tiempo que implica la recopilación de datos nuevos. Al introducir variaciones en los ejemplos existentes, se generan versiones modificadas pero relevantes de los datos originales. Estas variaciones pueden incluir pequeñas transformaciones que no alteran el significado o el contenido esencial del dato, proporcionando así una perspectiva diferente al modelo. Esto evita que el modelo memorice el conjunto de datos de entrenamiento y promueve su capacidad para hacer inferencias adecuadas en datos con pequeñas variaciones. De esta manera, se mejora la robustez y adaptabilidad del modelo en escenarios reales, contribuyendo significativamente a la mejora de la generalización, un aspecto crítico en el desarrollo de soluciones de aprendizaje automático efectivas (Lozada, 2022).

5.5.2 Métricas de Evaluación

Para determinar con precisión la eficacia del modelo en términos de clasificación, es fundamental utilizar métricas de evaluación específicas que arrojen luz sobre sus capacidades. En este trabajo, se optó por evaluar el rendimiento del modelo utilizando métricas que proporcionan un análisis detallado de sus capacidades de clasificación. Una herramienta valiosa en este análisis fue la matriz de confusión, la cual proporciona un desglose detallado de las predicciones del modelo, diferenciando entre verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos. Estos valores son esenciales para calcular métricas clave como precisión y sensibilidad, así como para entender mejor las áreas donde el modelo puede estar teniendo dificultades (Jocher et al., 2023).

La precisión (P) y la sensibilidad (R) fueron métricas centrales en este estudio. La

precisión mide la exactitud de las predicciones positivas del modelo, mientras que la sensibilidad evalúa cuántos de los casos positivos reales fueron identificados correctamente. Estas métricas ofrecen una visión clara del rendimiento del modelo, destacando su capacidad para hacer predicciones correctas y su eficacia en la identificación de casos positivos. Además, se utilizó el valor medio de precisión (mAP50), una métrica particularmente útil que combina información de precisión y sensibilidad a lo largo de diferentes umbrales. Esto proporciona un panorama más completo del rendimiento del modelo, especialmente en contextos donde los umbrales de decisión varían, permitiendo una evaluación más robusta y detallada de su eficacia (Jocher et al., 2023).

5.6. Tecnologías y Técnicas de diseño Web

Las aplicaciones web modernas son fundamentales para la interacción humana con tecnologías emergentes, en especial en áreas de investigación y análisis de datos. El proyecto actual, enfocado en el conteo, clasificación y conservación de datos sobre huevos de mosquito de la especie *Aedes aegypti*, se ha beneficiado de herramientas y técnicas adecuadas para desarrollar una aplicación estable, escalable y amigable para el usuario. En este contexto, Angular, desarrollado y liderado por Google, se eligió debido a su arquitectura modular y basada en componentes, que fomenta la reutilización de código y simplifica el mantenimiento y escalabilidad (Deshpande, 2023b). Además, mientras Angular ofrece herramientas para la funcionalidad de la aplicación, Bootstrap proporciona una base sólida para el diseño, garantizando una interfaz visualmente atractiva y adaptable a diferentes dispositivos, desde ordenadores de escritorio hasta dispositivos móviles. La flexibilidad de Bootstrap radica en su sistema de cuadrícula y componentes preconstruidos, que fueron esenciales en el diseño de la interfaz (Deshpande, 2023a).

Complementando a Bootstrap, NG-Zorro ofrece componentes de diseño específicos y atractivos. Su integración permitió una presentación de datos más coherente, especialmente al utilizar sus tablas para visualizar, editar y conservar la información de los conteos de manera ordenada (Sapananavtake, 2023). Para mejorar aún más la experiencia de usuario en la aplicación web, es vital una respuesta rápida y fluida. En este sentido, la implementación de la carga perezosa contribuye significativamente, ya que permite que la página cargue y muestre contenido al usuario de manera incremental, sin esperar a que todos los elementos estén listos (Díaz, 2021). Esto no solo optimiza la eficiencia de los recursos, sino que también ofrece una interacción más inmediata y agradable al usuario. Finalmente, en cuanto al hospedaje web, Vercel se destacó como una opción óptima. Su capacidad para generar sitios directamente desde el repositorio simplifica enormemente el proceso de despliegue. Además, al estar integrado con la plataforma GitHub, se beneficia de las constantes actualizaciones y mejoras de esta, ofreciendo así un servicio de hospedaje confiable y con alta disponibilidad (Vijayvargiya, 2022).

6.1. Enfoque de Gestión Basado en Metodologías Ágiles

Antes de adentrarse en los detalles técnicos del proyecto, es importante destacar el enfoque de gestión que se adoptó para llevar a cabo este proyecto. Se decidió utilizar un enfoque ágil inspirado en algunas prácticas de Scrum, reconociendo su eficacia en proyectos de desarrollo tecnológico y la necesidad de adaptabilidad y retroalimentación continua.

6.1.1 *Justificación de Enfoque Ágil*

En proyectos donde las circunstancias cambian rápidamente y la tecnología avanza constantemente, adoptar un enfoque ágil es fundamental. La metodología ágil permite una mayor flexibilidad y respuesta rápida a los cambios, mejorando la colaboración entre el equipo y el cliente. Esto asegura que el producto final cumpla con las expectativas y necesidades establecidas. A continuación, se presentan las principales razones por las que se eligió un enfoque ágil para el desarrollo del proyecto.

- La adaptabilidad del enfoque ágil, que permite la adaptación a cambios rápidos, es esencial debido a la naturaleza experimental y en evolución del proyecto.
- La colaboración con el cliente, promovida por la inspiración en Scrum, asegura la comunicación constante. En el caso del proyecto, esto garantizó que se alineara con las expectativas y necesidades del cliente, desde el inicio hasta el final.
- Las entregas graduales, que permiten al cliente visualizar el progreso, aseguraron que el producto final fuera el esperado.

6.1.2 Implementación Adaptada de Scrum

Para aprovechar al máximo los beneficios del enfoque ágil, se implementó una versión adaptada de Scrum, una de las metodologías ágiles más populares en el desarrollo de software. Esta implementación se ajustó a las necesidades específicas del equipo y del cliente, permitiendo una gestión de tareas más flexible y eficiente. En las siguientes secciones, se describen los roles, la estructura de los sprints y las ceremonias que formaron parte de esta implementación, destacando las adaptaciones realizadas para asegurar el éxito del proyecto en un entorno dinámico y colaborativo.

Roles. En el desarrollo de este proyecto, se definieron claramente los roles y responsabilidades para asegurar una coordinación eficiente y un cumplimiento efectivo de los objetivos establecidos. Cada miembro del equipo asumió su papel con el propósito de maximizar la productividad y la calidad del trabajo realizado. La colaboración y comunicación constante entre los diferentes roles fueron fundamentales para el éxito del proyecto, permitiendo una adaptación ágil a cualquier cambio o requerimiento que surgiera durante el proceso. Entre los roles definidos se encuentran:

- El Product Owner, quien actuó como el enlace entre el equipo de desarrollo y el cliente, asegurando que el producto final cumpliera con los requisitos de los usuarios.
- El equipo de desarrollo, que se estableció para poder llevar a cabo las tareas definidas durante el sprint. Debido al tamaño reducido del equipo, se asumieron de manera colectiva las responsabilidades para garantizar que se siguieran las prácticas inspiradas en Scrum.

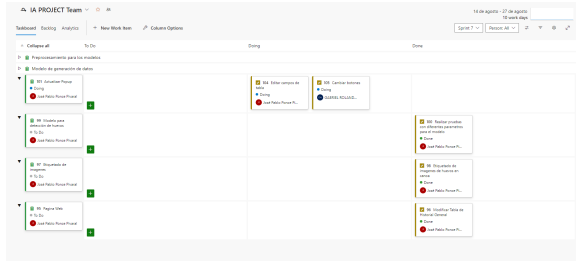
La duración de los sprints fue dinámica y dependió de las necesidades del proyecto. Aunque la mayoría de estos tuvo una duración de dos semanas, hubo algunos que se extendieron hasta un mes. Al final de cada sprint, se presentaba un incremento del producto al cliente para la revisión y retroalimentación. En relación con las ceremonias, se adaptaron las reuniones inspiradas en las ceremonias de Scrum al contexto y dinámica del trabajo. En lugar de tener reuniones separadas para la planificación y la revisión, se combinaron ambas. Cada vez que se presentaban avances al cliente y se recibía feedback, se aprovechaba la oportunidad para planificar las siguientes tareas basadas en los comentarios obtenidos.

6.1.3 Iteración y Retroalimentación con el Cliente

Como se mencionó anteriormente, durante cada sprint, se presentaron avances al cliente, lo que permitió obtener comentarios, ajustar el modelo desarrollado y asegurar que la interfaz fuera desarrollada de acuerdo a sus expectativas. A lo largo del proyecto, se realizaron reuniones regulares con el cliente para presentar estos avances. Estos encuentros evidenciaron la evolución de la interfaz y cómo la retroalimentación del cliente se incorporó en cada etapa. Los comentarios y sugerencias del cliente contribuyeron a la mejora continua y al refinamiento del proyecto en cada fase de desarrollo. Además, se utilizó un tablero de Azure Boards para gestionar y rastrear el progreso del proyecto. A través de este tablero, se pudo visualizar las tareas pendientes, las tareas en progreso y las tareas completadas, como se observa en la Figura 5.

Figura 5

Tablero de Azure



Nota: Elaboración propia.

6.2. Recolección de Imágenes

Para desarrollar un modelo robusto de aprendizaje profundo, es fundamental contar con una base de datos sólida. En este proyecto, la recolección de imágenes de huevos de mosquito de la especie *Aedes aegypti* en distintos estados, incluyendo viables, en canoa y eclosionados, bajo condiciones controladas de laboratorio, fue el primer paso crítico. Cada imagen se capturo de manera no invasiva, garantizando en todo momento la preservación y la integridad de las muestras biológicas, así como también los sustratos se manejaron con extremo cuidado para asegurar la preservación de los huevos de mosquito.

6.2.1 Medidas de Seguridad

La recolección se realizó en el Centro de Estudios en Salud, de la Unidad de Entomología Médica y Malaria, del Instituto de Investigaciones de la Universidad del Valle de Guatemala. Dada la naturaleza sensible del trabajo en un laboratorio, se establecieron estrictas medidas de seguridad y protocolos de higiene para minimizar los riesgos de contaminación y asegurar la integridad de las muestras y del personal. Previo al acceso al laboratorio, era necesario atravesar un pasillo con un sistema de interbloqueo de puertas, asegurando que solo una puerta se abriese a la vez, evitando cualquier potencial fuga de agentes biológicos. Además, se exigía el uso de batas y cubre zapatos antes de entrar, reforzando así la higiene y previniendo la introducción de agentes contaminantes. El laboratorio contaba con sistemas de control de temperatura y humedad, ideales para el desarrollo de los mosquitos y para garantizar la calidad de las imágenes obtenidas.

6.2.2 Proceso de Fotografía


Previo al inicio del proceso de toma de fotografías, se llevó a cabo una revisión exhaustiva de la literatura y estudios previos para entender las mejores técnicas y prácticas en la fotografía de huevos de mosquito. Esta información sirvió como punto de partida para las pruebas.

Las primeras pruebas se realizaron usando smartphones de alta gama, específicamente un iPhone 12 y un Samsung Galaxy Note 10 Plus. A pesar de que estos dispositivos cuentan con

cámaras avanzadas, se presentaron varios desafíos. Por ejemplo, el enfoque automático no siempre ofrecía una imagen clara, y cualquier pequeño movimiento podía desplazar la imagen, reduciendo la calidad de la captura. El uso de trípodes proporcionaba cierta estabilidad, pero no solucionaba completamente el problema de enfoque y estabilidad de la imagen. En la Figura 6 se muestra el proceso de captura con el iPhone 12, y en la Figura 7, los resultados obtenidos con dicho dispositivo.

Figura 6

Proceso de captura desde el iphone 12



Nota: Elaboración propia.

Figura 7

Resultado de las imágenes capturadas con iphone 12




Nota: Elaboración propia.

Posteriormente, se experimentó con una cámara Mevo y un trípode. A pesar de lograr una mayor estabilidad, esta configuración también tuvo desafíos, sobre todo en términos de

enfoque y luz del estereoscopio, lo que afectaba la calidad de las imágenes, como se muestra en la Figura 8.

Figura 8

Resultado de las imágenes capturadas con cámara Mevo



Nota: Elaboración propia.

También se intentó la adaptación de un telescopio con un aumento de x40 a un celular. A pesar de ser un enfoque innovador, no fue adecuado para el propósito, ya que estaba diseñado para observar objetos distantes y no lograba un buen enfoque en objetos cercanos. El intento de captura con este telescopio se muestra en la Figura 9.

Figura 9

Proceso de captura desde telescopio adaptable



Nota: Elaboración propia.

Finalmente, se optó por adaptar una cámara Canon EOS 70D con un adaptador T2 al estereoscopio. Esta configuración superó los problemas encontrados en las pruebas anteriores, ofreciendo imágenes claras, enfoque ajustable y una experiencia de usuario más eficiente. En la Figura 10 se muestra el proceso de captura con esta configuración, mientras que en la Figura 11 se pueden apreciar las imágenes obtenidas.

Figura 10

Proceso de captura desde cámara Canon adaptada al estereoscopio



Nota: Elaboración propia.

Figura 11

Resultado de las imágenes capturadas con cámara Canon



Nota: Elaboración propia.

Esta configuración, al no depender de ajustes manuales constantes ni de trípodes, redujo el margen de error humano y aceleró el proceso de captura, resultando en un conjunto de datos de alta calidad y resolución, adecuado para los requerimientos del proyecto. Además, al comparar las imágenes obtenidas por los diferentes métodos, la cámara Canon adaptada al estereoscopio demostró ser la mejor opción, proporcionando imágenes nítidas y detalladas, esenciales para el desarrollo del modelo.

6.2.3 *Resultados de la Recolección*

Con la técnica seleccionada, se recolectaron 532 imágenes de alta calidad, con un promedio de 16.81 megapíxeles y proporción mediana de 5472x3072. Estas imágenes incluyen 4,316 huevos viables, 2,011 eclosionados y 2,851 en canoa, proporcionando una base sólida para el entrenamiento del modelo. Además, esta selección meticulosa y detallada del método de fotografía aseguró no solo la adquisición de un conjunto de datos de alta calidad, sino también la eficiencia y la viabilidad del proceso de recolección de imágenes. Posteriormente, tras la recolección, se procedió al etiquetado manual de los huevos en las imágenes, clasificándolos como viables, en canoa o eclosionados, utilizando la plataforma de Roboflow.

6.3. Optimización del Conjunto de Datos

Una vez realizada la recolección y etiquetado de las imágenes, era imperativo preparar y optimizar el conjunto de datos para garantizar un entrenamiento de calidad para los modelos de aprendizaje automático. Para esto, se apoyó en la plataforma Roboflow, con la que se realizaron diversas tareas de preprocesamiento y aumentación. A continuación, se describen con detalle los procedimientos llevados a cabo en esta crucial etapa.

6.3.1 *Partición del Conjunto de Datos*

Se inició particionando el conjunto de datos recolectados en tres segmentos: entrenamiento, pruebas y validación. Se optó por asignar el 75% de los datos al entrenamiento, el 15% a la validación y el 10% restante a las pruebas. Esta distribución fue diseñada con el propósito de garantizar que el modelo se desempeñe eficientemente en diversos conjuntos de datos y no se limite a memorizar el set de entrenamiento.

6.3.2 *Selección de Técnicas de Preprocesamiento y Aumentación*

Durante la fase de mejora del conjunto de datos, se experimentó con diversas técnicas de preprocesamiento y aumentación. Entre las técnicas de preprocesamiento probadas, el ajuste automático de contraste no ofreció resultados óptimos, ya que afectaba la diferenciación entre huevos viables y en canoa. Asimismo, varias técnicas de aumentación a nivel del cuadro delimitador, como giros y rotaciones de 90°, no proporcionaron la precisión deseada en el modelo. Para evaluar el desempeño de cada técnica, se utilizó la matriz de confusión como indicador principal. Esta herramienta brindó una mejor percepción sobre la capacidad del modelo para clasificar adecuadamente los huevos de mosquito de la especie *Aedes aegypti* a partir de las imágenes, permitiendo identificar qué técnicas generaban confusiones o clasificaciones erróneas, y así ajustar el enfoque en consecuencia.

6.3.3 Técnicas de Preprocesamiento Elegidas

Después de evaluar diversas técnicas, se optó por aquellas que mostraron un impacto positivo en la coherencia y calidad del conjunto de datos:

- La auto-orientación garantizó que cada imagen estuviera correctamente alineada, simplificando la detección y clasificación por parte del modelo.
- El reajuste de tamaño a 642x642 (reflejando bordes) normalizó el conjunto de datos y redujo la carga computacional, preservando los detalles vitales de las imágenes.

6.3.4 Técnicas de Aumentación Elegidas

Las técnicas de aumentación seleccionadas se centraron en aumentar la diversidad y variabilidad del conjunto de datos, permitiendo que el modelo se entrenara en escenarios más diversos y mejorara su generalización:

- Las rotaciones y giros ayudaron al modelo a reconocer los huevos desde diferentes ángulos, incrementando su capacidad de detección en condiciones variadas.
- Las inclinaciones enseñaron al modelo a identificar huevos con ligeras deformaciones visuales.
- Los ajustes de iluminación, al variar la iluminación y el color, hicieron que el modelo se volviera más robusto ante variaciones de luz en imágenes reales.
- El ruido preparó al modelo para escenarios donde las imágenes podrían no ser perfectamente nítidas.
- La técnica de mosaico aumentó la diversidad de escenarios en una sola imagen, mejorando la capacidad del modelo para detectar huevos en contextos variados.
- La inclusión de imágenes en escala de grises ayudó a reducir la dependencia del modelo en la información de color y aumentó su robustez ante variaciones de color en las imágenes a color.
- Las variaciones de saturación se aplicaron para mejorar la adaptabilidad del modelo a diferentes niveles de saturación en imágenes.
- La variación de la exposición preparó al modelo para cambios en la iluminación de las imágenes.

Para un mejor entendimiento, a continuación se presenta la Tabla 1 detallando los valores específicos o parámetros utilizados para cada una de las técnicas de aumentación:

Tabla 1*Valores y parámetros utilizados en las técnicas de aumentación*

Técnica de Aumentación	Valores/Parámetros Utilizados
Volteo	Horizontal, Vertical
Rotación de 90°	En sentido horario y antihorario
Rotación	Entre -45° y +45°
Inclinación	±5° Horizontal, ±5° Vertical
Iluminación	Entre 0 % y +25 %
Ruido	Hasta 1 % de los píxeles
Escala de Grises	Aplicado al 15 % de las imágenes
Mosaico	2x2 (4 imágenes en 1)
Saturación	Entre -25 % y 25 %
Exposición	Entre -1 % y 1 %

Nota: Elaboración propia.

6.3.5 Resultados del Preprocesamiento y Aumentación

Después de aplicar las técnicas de preprocesamiento y aumentación, se obtuvo un conjunto mejorado de 1209 imágenes para entrenamiento, 80 para validación y 53 para pruebas. Estas técnicas permitieron mejorar significativamente la calidad y diversidad de las imágenes disponibles. En términos porcentuales, el conjunto de entrenamiento comprendía el 90 % del total, mientras que la validación abarcaba el 6 % y las pruebas representaban el 4 %. Este enfoque aseguró que el modelo fuera entrenado, validado y probado con un conjunto de datos robusto y bien distribuido, optimizando así su desempeño final y su capacidad para generalizar.

6.4. Investigación y Selección de Modelo de Aprendizaje Profundo

La elección del modelo de aprendizaje profundo fue una parte fundamental del proyecto, dado que el modelo seleccionado debía abordar de manera efectiva la tarea de clasificar huevos de mosquitos de la especie *Aedes aegypti* en imágenes. Se evaluaron varios modelos de detección y clasificación, tales como Faster R-CNN, SSD, YOLO y RetinaNet, cada uno con sus propias fortalezas y debilidades. Cada uno de estos modelos presenta diferentes enfoques para el equilibrio entre precisión y velocidad, lo cual es crucial para el objetivo. Además, se consideraron aspectos como la facilidad de implementación, la disponibilidad de recursos preentrenados y la capacidad de adaptación a diferentes entornos de trabajo, asegurando que el modelo seleccionado no solo fuera preciso sino también eficiente y práctico en su aplicación.

6.4.1 Revisión de Modelos Existentes

Se realizó una revisión exhaustiva de los modelos de aprendizaje profundo existentes para la detección de objetos. En esta revisión, se examinaron de manera detallada las características, ventajas y desventajas de los modelos Faster R-CNN, SSD, YOLO y

RetinaNet, considerando tanto su precisión como su velocidad de detección. Además, se llevó a cabo un análisis exhaustivo de estudios previos, lo que proporcionó una comprensión más detallada y profunda del rendimiento de cada uno de estos modelos en diversas condiciones y escenarios específicos.

6.4.2 Definición de Métricas de Evaluación

Se identificaron las métricas de rendimiento clave a partir de la literatura existente para entender cómo evaluar los modelos, incluyendo la precisión, la precisión media promedio y los cuadros por segundo. Estas métricas se utilizaron como base para evaluar la manera en que cada modelo podría desempeñarse en términos de identificar correctamente los huevos de mosquito de la especie *Aedes aegypti* en las imágenes y la velocidad a la que podrían procesar imágenes, según los estudios previos realizados en contextos similares de detección de objetos.

6.4.3 Análisis Comparativo

Se revisaron estudios comparativos existentes para obtener una primera comprensión del rendimiento relativo de estos modelos en tareas similares a la clasificación de huevos de mosquitos, como se muestra en la Tabla 2 y Tabla 3. En uno de los estudios, se mostró que, aunque Faster R-CNN alcanzó una MAP de 87.69%, su velocidad de detección (FPS: 3) fue significativamente menor en comparación con YOLOv3, que logró una MAP de 80.17% pero con una velocidad de detección (FPS: 69) más de veinte veces superior (Tan et al., 2021).

Tabla 2

Comparación de métricas de rendimiento entre RetinaNet, SSD, y YOLOv3

Algoritmo	Precisión (%)	Sensibilidad (%)	F1 (%)	MAP (%)	FPS
RetinaNet	64.98	83.86	73.26	82.89	17
SSD	63.69	88.89	74.21	82.71	32
YOLO v3	69.65	80.67	74.77	80.69	51

Nota: Adaptado de *Comparación de YOLO V3, faster R-CNN y SSD para la identificación en tiempo real de píldoras*, por Tan et al., 2021.

Tabla 3

Comparación de métricas de rendimiento entre Faster R-CNN, SSD, y YOLOv3

Algoritmo	Precisión (%)	Sensibilidad (%)	F1 (%)	MAP (%)	FPS
Faster R-CNN	62.19	94.24	78.23	87.69	3
SSD	63.17	88.69	72.13	82.41	41
YOLO v3	69.13	80.19	70.14	80.17	69

Nota: Adaptado de *Comparación de RetinaNet, SSD y YOLO v3 para la identificación en tiempo real de píldoras*, por Tan et al., 2021.

6.4.4 Comparación entre Versiones de YOLO

Se realizó una revisión detallada de las diferencias entre YOLOv3 y YOLOv8, analizando las mejoras en términos de velocidad y precisión que YOLOv8 ofrece sobre YOLOv3, basándose en la literatura disponible. Esta revisión proporcionó una justificación clara para la consideración de YOLOv8 para el proyecto.

6.4.5 Criterios de Selección de Modelo

Basándose en la revisión y comparación detallada, se definieron los criterios para la selección del modelo, enfatizando la importancia del procesamiento de múltiples imágenes simultáneamente para el conteo y clasificación de huevos de mosquito de la especie *Aedes aegypti*. La necesidad de una alta precisión junto con una velocidad de procesamiento rápida fueron factores determinantes.

6.4.6 Selección de YOLOv8

Con base en la investigación realizada, se seleccionó YOLOv8 con segmentación de instancias como el modelo más apto para la tarea de clasificar y contar huevos de mosquitos de la especie *Aedes aegypti* en imágenes. La implementación de la segmentación de instancias se decidió debido a que la identificación y segmentación individual de objetos de la misma clase es crucial para la tarea de clasificar y contar huevos de mosquitos de manera precisa. Además, YOLOv8 mostró un desempeño superior en términos de velocidad y precisión en comparación con las versiones anteriores de YOLO y otros modelos revisados.

6.4.7 Configuración y Parámetros de Entrenamiento

Durante el proceso de entrenamiento del modelo YOLOv8 con segmentación de instancias, se configuraron y ajustaron específicamente diversos parámetros para abordar la tarea de detección y segmentación de huevos de mosquitos de la especie *Aedes aegypti*. A continuación, en la Tabla 4 se describen los parámetros utilizados, así como las aumentaciones adicionales realizadas durante el entrenamiento para evitar que el modelo se sobreajustara a los datos:

Tabla 4*Parámetros de entrenamiento del modelo YOLOv8*

Parámetro	Valor/Descripción
Tarea	Segmentación
Épocas	200
Tamaño de imagen	640
Paciencia	30
Tamaño del lote	16
Decaimiento de peso	0.0005
Rotación	5 grados
Traslación	0.05
Escala	0.5
Mosaico	0.5
Volteo horizontal	0.25
Volteo vertical	0.25

Nota: Elaboración propia

6.4.8 Variantes del Modelo

El modelo se entrenó con cuatro variantes diferentes, ajustando el optimizador y la tasa de aprendizaje inicial, como se muestra en la Tabla 5. Posteriormente, se analizaron los resultados de las diferentes variantes, y se determinó que el modelo entrenado con el optimizador ADAM y una tasa de aprendizaje de 0.001 ofreció los mejores resultados. Por lo tanto, este modelo fue el seleccionado y posteriormente se desplegó en Roboflow.

Tabla 5*Variantes de entrenamiento del modelo YOLOv8*

Optimizador	Tasa de Aprendizaje Inicial
SGD	0.01
SGD	0.001
ADAM	0.01
ADAM	0.001

Nota: Elaboración propia

6.5. Desarrollo y Hospedaje de Aplicación Web

La creación de una aplicación web es un componente esencial de este proyecto. Esta interfaz proporciona a los usuarios una herramienta para utilizar el modelo de aprendizaje profundo con el fin de clasificar y contar los huevos de mosquito, así como almacenar la información resultante en una base de datos. En esta sección, se describe la estructura y funcionamiento de esta aplicación, detallando sus distintos módulos.

6.5.1 Interfaz y Diseño

La aplicación fue desarrollada utilizando el framework Angular, lo que permitió una estructura modular y escalable. Para garantizar un diseño adaptativo y una experiencia de usuario óptima en distintos dispositivos y tamaños de pantalla, se emplearon las bibliotecas de Bootstrap y NG-Zorro, que ofrecen componentes visuales y estilos predefinidos que facilitan la creación de una interfaz coherente y responsiva. En relación con la interfaz, se implementaron dos tablas utilizando NG-Zorro que reflejan de manera clara y organizada la información de los conteos de huevecillos en distintos módulos de la aplicación. Estas tablas no solo mejoran la visualización de los datos, sino que también permiten una interacción más intuitiva y eficiente por parte del usuario, asegurando que la información esté siempre accesible y fácil de entender.

6.5.2 Datos Generales y Específicos de Conteo de Huevecillos

La gestión y análisis de datos de huevecillos de mosquitos es crucial para la comprensión y control de estas especies. La información recopilada abarca tanto datos generales como específicos, permitiendo un seguimiento detallado de cada cepa de mosquitos. Se registran características esenciales como el nombre y la especie de la cepa, su generación filial y el código de crianza, proporcionando un contexto claro sobre el origen y la evolución de los especímenes. Además, se incluye el total de huevos viables obtenidos, lo que es fundamental para evaluar la efectividad de las técnicas de crianza. Junto con estos datos generales, se detalla el proceso de colecta, desde el código del sustrato utilizado hasta las fechas de colocación y retiro, y se cuantifican los distintos tipos de huevos: viables, eclosionados y en canoa. Este enfoque integral asegura un control preciso y eficiente en los programas de investigación y manejo de mosquitos.

La siguiente información contiene datos generales y específicos relacionados con los conteos de huevecillos de mosquitos, actualizándose con cada nuevo análisis. Sus columnas incluyen:

- La cepa, que se refiere al nombre asignado a la cepa de mosquitos.
- La especie, que se refiere a la especie de la cepa de mosquitos.
- La generación, que se refiere a la generación filial de la cepa de mosquitos, de la que se obtienen los huevos.
- El código de crianza, que hace referencia a la crianza original de la que proviene la cepa de mosquitos.
- El total de huevos viables, que se refiere al total de huevos viables que se obtuvieron.
- El código de sustrato, que es un código único para el sustrato utilizado para coleccionar huevos de la cepa de mosquitos. Puede haber más de un papel por alimentación de sangre.
- La fecha de colocación del sustrato, que es la fecha en que se coloca el papel para recoger la ovipostura de la cepa de mosquitos.

- La fecha de retiro del sustrato, que es la fecha en que se retira el papel con la ovipostura de la cepa de mosquitos.
- Los huevos viables, que se refieren al total de huevos viables en el sustrato.
- Los huevos eclosionados, que se refieren al total de huevos eclosionados en el sustrato.
- Los huevos en canoa, que se refieren al total de huevos en canoa (no fértiles) en el papel. Estos huevos son el resultado de un mal secado y almacenamiento.
- El total de huevos, que se refiere al total de huevos en el sustrato, que es la suma de los huevos viables, eclosionados y en forma de canoa.
- La generación filial, que se refiere a la generación filial de los huevos que se obtienen de la cepa de mosquitos.
- El responsable del conteo de huevos, que es la persona responsable de la crianza de la cepa.

6.5.3 *Detalles Funcionales de la Aplicación*

Tras la autenticación, los usuarios son redireccionados a este módulo. Aquí, se pueden cargar múltiples imágenes de huevos de mosquito, como se muestra en la Figura 12. Esto se puede realizar de dos maneras: arrastrando con el cursor las imágenes deseadas desde el escritorio al botón para subirlas o seleccionándolas haciendo clic en el botón y seleccionando la carpeta donde se encuentran. Una vez cargadas, se envían a la API de Roboflow donde el modelo procesa y clasifica las imágenes. Mientras las imágenes se procesan, se muestra una barra de progreso que indica el avance del análisis y, una vez finalizado, se despliega un pop-up con dos tablas con información relacionada al conteo y con las imágenes etiquetadas con las clases de los huevos que se lograron detectar y clasificar, como se muestra en la Figura 13 y Figura 14. Tras esto, existe la opción de guardar la información del conteo, editar las tablas por si hubiera algún dato que no se logró clasificar bien y también se puede regresar y realizar un nuevo análisis.

Figura 12


Pantalla de Conteo



Nota: Elaboración propia.

Figura 13


Pop-up mostrando las Imágenes Etiquetadas



Nota: Elaboración propia.

Figura 14

Pop-up mostrando las Tablas con Información del Conteo




Nota: Elaboración propia.

Además, los usuarios tienen acceso a un historial general que permite revisar la información de las tablas de datos generales de los muestreos anteriores. Cada registro en esta sección tiene un enlace para visualizar detalles adicionales, como se muestra en la Figura 15. Esta sección facilita la comparación de resultados de diferentes períodos de muestreo, crucial para el seguimiento y análisis a lo largo del tiempo. La interfaz está diseñada para facilitar la navegación entre los registros disponibles. Esto no solo proporciona un acceso rápido a los datos históricos, sino que también ayuda a identificar tendencias y patrones importantes en la información recopilada.

Figura 15

Módulo de Historial General




Nota: Elaboración propia.

Al seleccionar un registro específico del historial general, los usuarios son redirigidos a una vista detallada donde se puede ver y editar la información contenida en las tablas de datos generales y conteo de huevecillos, como se muestra en la Figura 16. Esta funcionalidad permite un análisis más profundo y preciso de los datos, proporcionando herramientas para

la edición y actualización de la información almacenada. Se puede revisar minuciosamente cada entrada y hacer las correcciones necesarias, lo cual es crucial para mantener la precisión y relevancia de los datos.

Figura 16

Módulo de Historial Detallado



Nota: Elaboración propia.


Por último, al finalizar el desarrollo y las pruebas de la aplicación, se eligió Vercel como plataforma de hospedaje debido a su integración con repositorios y su simplicidad. Esta elección permite un despliegue ágil y eficiente, asegurando que las actualizaciones y mejoras en la aplicación se realicen de manera continua y sin interrupciones significativas para los usuarios. Vercel ofrece un entorno de hospedaje robusto que soporta el crecimiento y la escalabilidad del proyecto, facilitando la gestión del backend y garantizando una experiencia de usuario óptima. La integración con repositorios también permite una colaboración más fluida entre los desarrolladores, asegurando que el código se mantenga limpio y organizado. Así, la elección de Vercel no solo optimiza el desempeño de la aplicación, sino que también fortalece el proceso de desarrollo y despliegue continuo.

7.1. Experimentos Iniciales

A continuación se presentan los hallazgos de los experimentos iniciales realizados durante el desarrollo del proyecto. Estos experimentos incluyeron pruebas de preprocesamiento y aumentación de datos, utilizando el optimizador Adam con diferentes tasas de aprendizaje. En la Figura 17 se muestra la matriz de confusión obtenida con el uso de Adam y una tasa de aprendizaje de 0.001.

Figura 17

Matriz de Confusión obtenida menos favorable usando Adam con $lr_0 = 0.001$



Nota: Elaboración propia.

7.2. Optimización con Adam con $lr_0 = 0.001$

Este segmento se enfoca en el desempeño final obtenido al optimizar el modelo utilizando el optimizador Adam con una tasa de aprendizaje inicial de 0.001. Se incluyen métricas de

rendimiento como precisión, sensibilidad y puntajes mAP50 y mAP50-95 para diferentes clases de huevos de mosquito de la especie *Aedes aegypti*. Además, se presentan visualmente los datos a través de gráficos, permitiendo una evaluación detallada del desempeño del modelo tanto en el conjunto de entrenamiento como en el conjunto de validación.

Durante el entrenamiento del modelo utilizando el optimizador Adam con una tasa de aprendizaje inicial de 0.001, se evaluaron diversas métricas de rendimiento. En la Tabla 6 se muestran las métricas para cada clase de huevos, proporcionando una visión detallada del desempeño del modelo en términos de precisión, sensibilidad y mAP en diferentes umbrales. La Figura 18 proporciona un resumen visual del rendimiento del entrenamiento, mostrando las principales métricas a lo largo del tiempo de entrenamiento. La Figura 19 presenta la matriz de confusión normalizada, mostrando el desempeño del modelo en la clasificación de las distintas clases de huevos. La Figura 20 incluye la curva MASKF1, que muestra la evolución de esta métrica específica durante el entrenamiento. La Figura 21 presenta la curva de Precisión-Confianza, ilustrando cómo varía la precisión del modelo en función de los niveles de confianza. La Figura 22 muestra la curva BoxF1, que proporciona información sobre la relación entre la precisión y la sensibilidad en la detección de cajas. Finalmente, la Figura 23 presenta la curva de Precisión-Sensibilidad para la detección de cajas, mostrando el rendimiento del modelo en esta tarea específica.

Tabla 6


Resultados de entrenamiento con optimizador ADAM y lr0 = 0.001

Clase	Box(P)	R	mAP50	mAP50-95	Mask(P)	mAP50-95
All	0.853	0.893	0.935	0.834	0.853	0.686
Huevos eclosionados	0.905	0.928	0.964	0.869	0.907	0.72
Huevos en canoa	0.785	0.87	0.896	0.795	0.784	0.648
Huevos viables	0.869	0.882	0.944	0.837	0.868	0.691

Nota: Elaboración propia.

Figura 18

Resultados del entrenamiento usando Adam con lr0 = 0.001



Nota: Elaboración propia.

Figura 19


Matriz de confusión normalizada en entrenamiento usando Adam con $lr0 = 0.001$



Nota: Elaboración propia.

Figura 20


Curva MASKF1 en entrenamiento usando Adam con $lr0 = 0.001$



Nota: Elaboración propia.

Figura 21


Curva Precisión-Confianza en entrenamiento usando Adam con $lr0 = 0.001$



Nota: Elaboración propia.

Figura 22


Curva BoxF1 en entrenamiento usando Adam con $lr_0 = 0.001$



Nota: Elaboración propia.

Figura 23

Curva Precisión-Sensibilidad para detección de cajas en entrenamiento usando ADAM con $lr_0 = 0.001$



Nota: Elaboración propia.

Los datos obtenidos durante la validación del modelo utilizando el optimizador Adam con una tasa de aprendizaje inicial de 0.001 son los siguientes. Similar a la fase de entrenamiento, se muestran tablas y gráficos que evidencian el rendimiento del modelo en la fase de validación. En la Tabla 7 se presentan las métricas de rendimiento, incluyendo precisión, sensibilidad, mAP50 y mAP50-95 para las diferentes clases de huevos de mosquito. La Figura 24 muestra la matriz de confusión normalizada, proporcionando una visión clara del desempeño del modelo en la clasificación de las distintas clases de huevos. La Figura 25 ilustra la curva MASKF1 durante la validación, mientras que la Figura 26 presenta la curva de Precisión-Confianza, mostrando la relación entre la precisión y los niveles de confianza. Además, la Figura 27 muestra la curva de Precisión-Sensibilidad para la detección de cajas, permitiendo una comparación entre el desempeño en el conjunto de entrenamiento y el conjunto de validación.

Tabla 7


Resultados de validación con optimizador ADAM y lr0 = 0.001

Clase	Box(P)	R	mAP50	mAP50-95	Mask(P)	mAP50-95
All	0.854	0.892	0.935	0.838	0.853	0.67
Huevos eclosionados	0.907	0.926	0.963	0.873	0.907	0.703
Huevos en canoa	0.786	0.869	0.897	0.798	0.785	0.632
Huevos viables	0.869	0.881	0.944	0.842	0.868	0.675

Nota: Elaboración propia.

Figura 24


Matriz de confusión normalizada en validación usando Adam con lr0 = 0.001



Nota: Elaboración propia.

Figura 25


Curva MASKF1 en validación usando Adam con lr0 = 0.001



Nota: Elaboración propia.

Figura 26


Curva Precisión-Confianza en validación usando Adam con $lr_0 = 0.001$



Nota: Elaboración propia.

Figura 27

Curva Precisión-Sensibilidad para detección de cajas en validación usando ADAM con $lr_0 = 0.001$




Nota: Elaboración propia.

A continuación se presentan ejemplos visuales de las predicciones realizadas por el modelo, mostrando imágenes con las detecciones y clasificación de huevos de mosquito de la especie *Aedes aegypti*. La Figura 28 y la Figura 29 muestran detecciones en diferentes imágenes de prueba, proporcionando una evaluación visual del rendimiento del modelo en distintos contextos y condiciones.

Figura 28

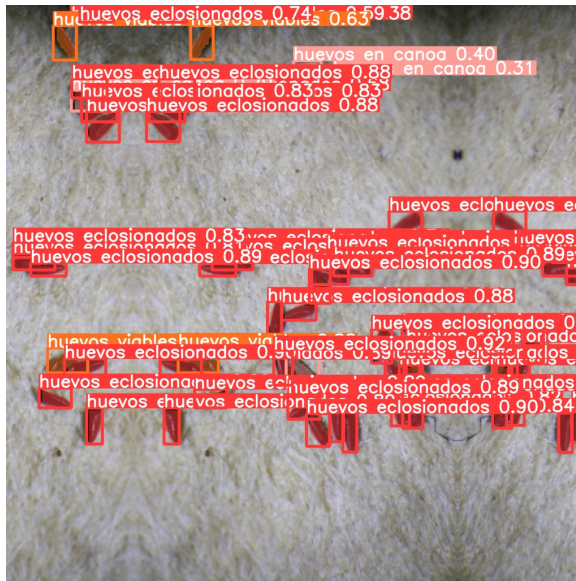
Detección de Huevos de Mosquito 1



Nota: Elaboración propia.

Figura 29

Detección de Huevos de Mosquito 2



Nota: Elaboración propia.

7.3. Optimización con Adam con $lr_0 = 0.01$

Este segmento se enfoca en el desempeño final obtenido al optimizar el modelo utilizando el optimizador Adam con una tasa de aprendizaje inicial de 0.01. Se incluyen métricas de

rendimiento como precisión, sensibilidad y puntajes mAP50 y mAP50-95 para diferentes clases de huevos de mosquito de la especie *Aedes aegypti*. Además, se presentan visualmente los datos a través de gráficos, permitiendo una evaluación detallada del desempeño del modelo tanto en el conjunto de entrenamiento como en el conjunto de validación.

Durante el entrenamiento del modelo utilizando el optimizador Adam con una tasa de aprendizaje inicial de 0.01, se evaluaron diversas métricas de rendimiento. En la Tabla 8 se muestran las métricas para cada clase de huevos, proporcionando una visión detallada del desempeño del modelo en términos de precisión, sensibilidad y mAP en diferentes umbrales.

Tabla 8

Resultados de entrenamiento con optimizador ADAM y lr0 = 0.01

Clase	Box(P)	R	mAP50	mAP50-95	Mask(P)	mAP50-95
All	0.848	0.874	0.93	0.815	0.848	0.653
Huevos eclosionados	0.92	0.921	0.971	0.857	0.922	0.691
Huevos en canoa	0.756	0.856	0.879	0.767	0.756	0.615
Huevos viables	0.867	0.845	0.938	0.821	0.866	0.653

Nota: Elaboración propia.

Los datos obtenidos durante la validación del modelo utilizando el optimizador Adam con una tasa de aprendizaje inicial de 0.01 son los siguientes. Similar a la fase de entrenamiento, se muestran tablas y gráficos que muestran el rendimiento del modelo en la fase de validación, permitiendo una comparación directa con el desempeño observado durante el entrenamiento. En la Tabla 9 se presentan las métricas de rendimiento, incluyendo precisión, sensibilidad, mAP50 y mAP50-95 para las diferentes clases de huevos de mosquito de la especie *Aedes aegypti*. La Figura 30 muestra la curva de Precisión-Sensibilidad para la detección de cajas, proporcionando una visión clara del rendimiento del modelo en esta tarea específica durante la validación. Además, la Figura 31 presenta la matriz de confusión normalizada, ilustrando el desempeño del modelo en la clasificación de las distintas clases de huevos.

Tabla 9


Resultados de validación con optimizador ADAM y lr0 = 0.01

Clase	Box(P)	R	mAP50	mAP50-95	Mask(P)	mAP50-95
All	0.849	0.874	0.93	0.818	0.849	0.639
Huevos eclosionados	0.921	0.921	0.971	0.86	0.922	0.675
Huevos en canoa	0.758	0.856	0.879	0.772	0.758	0.6
Huevos viables	0.868	0.845	0.938	0.823	0.866	0.641

Nota: Elaboración propia.

Figura 30


Curva Precisión-Sensibilidad para detección de cajas en validación usando Adam con $lr_0 = 0.01$



Nota: Elaboración propia.

Figura 31

Matriz de confusión normalizada en validación usando Adam con $lr_0 = 0.01$



Nota: Elaboración propia.

7.4. Optimización con SGD con $lr_0 = 0.01$

Este segmento se enfoca en el desempeño final obtenido al optimizar el modelo utilizando el optimizador SGD con una tasa de aprendizaje inicial de 0.01. Se presentan métricas de rendimiento como precisión, sensibilidad y puntajes mAP50 y mAP50-95 para diferentes clases de huevos de mosquito de la especie *Aedes aegypti*. Además, se incluyen gráficos que visualizan los datos, permitiendo una evaluación detallada del desempeño del modelo tanto en el conjunto de entrenamiento como en el conjunto de validación.

Durante el entrenamiento del modelo utilizando el optimizador SGD con una tasa de aprendizaje inicial de 0.01, se evaluaron diversas métricas de rendimiento. En la Tabla 10 se muestran las métricas para cada clase de huevos, proporcionando una visión detallada del desempeño del modelo en términos de precisión, sensibilidad y mAP en diferentes umbrales.

Tabla 10*Resultados de entrenamiento con optimizador SGD y lr0 = 0.01*

Clase	Box(P)	R	mAP50	mAP50-95	Mask(P)	mAP50-95
All	0.833	0.88	0.918	0.812	0.832	0.672
Huevos eclosionados	0.887	0.944	0.962	0.859	0.886	0.713
Huevos en canoa	0.765	0.829	0.863	0.761	0.764	0.631
Huevos viables	0.847	0.867	0.931	0.817	0.847	0.671

Nota: Elaboración propia.

Durante la fase de validación, el modelo también se evaluó en función de diversas métricas de rendimiento para cada clase de huevos de mosquito de la especie *Aedes aegypti*. En la Tabla 11 se presentan las métricas, incluyendo precisión, sensibilidad, mAP50 y mAP50-95, permitiendo una comparación directa con el desempeño observado durante el entrenamiento. La Figura 32 muestra la curva de Precisión-Sensibilidad para la detección de cajas, proporcionando una visión clara del rendimiento del modelo en esta tarea específica durante la validación. Además, la Figura 33 presenta la matriz de confusión normalizada, ilustrando el desempeño del modelo en la clasificación de las distintas clases de huevos.

Tabla 11*Resultados de validación con optimizador SGD y lr0 = 0.01*

Clase	Box(P)	R	mAP50	mAP50-95	Mask(P)	mAP50-95
All	0.833	0.88	0.919	0.817	0.833	0.656
Huevos eclosionados	0.888	0.943	0.962	0.865	0.888	0.693
Huevos en canoa	0.765	0.829	0.863	0.765	0.764	0.618
Huevos viables	0.847	0.867	0.931	0.821	0.847	0.656


Nota: Elaboración propia.**Figura 32***Curva Precisión-Sensibilidad para detección de cajas en validación usando SGD con lr0 = 0.01**Nota:* Elaboración propia.

Figura 33

Matriz de confusión normalizada en validación usando SGD con lr0 = 0.01



Nota: Elaboración propia.

7.5. Optimización con SGD con lr0 = 0.001

Este segmento se enfoca en el desempeño final obtenido al optimizar el modelo utilizando el optimizador SGD con una tasa de aprendizaje inicial de 0.001. Se presentan métricas de rendimiento como precisión, sensibilidad y puntajes mAP50 y mAP50-95 para diferentes clases de huevos de mosquito de la especie *Aedes aegypti*. Además, se incluyen gráficos que visualizan los datos, permitiendo una evaluación detallada del desempeño del modelo tanto en el conjunto de entrenamiento como en el conjunto de validación.

Durante el entrenamiento del modelo, se evaluaron diversas métricas de rendimiento. En la Tabla 12, se muestran las métricas para cada clase de huevos, proporcionando una visión detallada del desempeño del modelo en términos de precisión, sensibilidad y mAP en diferentes umbrales.

Tabla 12

Resultados de entrenamiento con optimizador SGD y lr0 = 0.001

Clase	Box(P)	R	mAP50	mAP50-95	Mask(P)	mAP50-95
All	0.828	0.872	0.919	0.82	0.828	0.82
Huevos eclosionados	0.893	0.941	0.97	0.878	0.893	0.878
Huevos en canoa	0.764	0.806	0.862	0.763	0.764	0.763
Huevos viables	0.827	0.869	0.926	0.82	0.827	0.82

Nota: Elaboración propia.

En cuanto a la fase de validación, las métricas obtenidas para cada clase de huevo de la especie *Aedes aegypti* se presentan en la Tabla 13. La Figura 34 muestra la curva de Precisión-Sensibilidad para la detección de cajas, proporcionando una visión clara del rendimiento del modelo en esta tarea específica durante la validación. Además, la Figura 35 presenta la matriz de confusión normalizada, ilustrando el desempeño del modelo en la clasificación de las distintas clases de huevos.

Tabla 13


Resultados de validación con optimizador SGD y lr0 = 0.001

Clase	Box(P)	R	mAP50	mAP50-95	Mask(P)	mAP50-95
All	0.828	0.873	0.919	0.823	0.828	0.823
Huevos eclosionados	0.893	0.941	0.97	0.881	0.893	0.881
Huevos en canoa	0.765	0.807	0.862	0.766	0.765	0.766
Huevos viables	0.826	0.87	0.926	0.823	0.826	0.823

Nota: Elaboración propia.

Figura 34


Curva Precisión-Sensibilidad para detección de cajas en validación usando SGD con lr0 = 0.001



Nota: Elaboración propia.

Figura 35

Matriz de confusión normalizada en validación usando SGD con lr0 = 0.001



Nota: Elaboración propia.

7.6. Comparación de Métodos de Conteo

A continuación se presentan los resultados del conteo de huevos de mosquito de la especie *Aedes aegypti* en un sustrato con dimensiones de 36.1 cm de largo y 8.2 cm de ancho, donde se obtuvieron 255 imágenes para abarcar el sustrato completo. Se utilizaron diferentes métodos para realizar el conteo y se compararon con los resultados obtenidos por un investigador que realizó el conteo de manera manual.

Este conteo manual fue llevado a cabo por un técnico especializado del Centro de Estudios en Salud, de la Unidad de Entomología Médica y Malaria, del Instituto de Investigaciones de la Universidad del Valle de Guatemala con amplia experiencia en la identificación y conteo de huevos de mosquito. Es relevante destacar que no cualquier individuo está capacitado para efectuar este tipo de conteo, ya que requiere un conocimiento detallado y una habilidad desarrollada a lo largo de años de experiencia en el campo.

Para la detección de huevos con el modelo, se estableció un umbral de confianza de 0.45, un valor seleccionado para asegurar una identificación adecuada sin omitir huevos potenciales, y al mismo tiempo, no tan bajo como para incluir falsas detecciones. Además, se definió un umbral de superposición de 0.30 para evitar la doble contabilización en caso de superposiciones leves entre detecciones.

En las Tablas 14, 15 y 16 se presentan, respectivamente, la comparación de tiempos entre el modelo YOLOv8 y el conteo manual con fotos, los resultados del conteo entre el modelo YOLOv8 y el conteo manual con fotos, y los resultados del conteo manual sin fotos realizado por un investigador.

Tabla 14

Comparación de tiempos entre el modelo YOLOv8 y el conteo manual con fotos

Método	Tiempo Fotos	Tiempo Análisis	Tiempo Total
Modelo (YOLOv8)	110 min	9 min	119 min
Conteo con Fotos	110 min	90 min	200 min

Nota: Elaboración propia.

Tabla 15

Resultados del conteo entre el modelo YOLOv8 y el conteo manual con fotos

Método	Viables	En canoa	Eclosionados	Total	Precisión (Total)
Modelo (YOLOv8)	1063	520	17	1600	94.73 %
Conteo manual de con Fotos	1455	232	2	1689	Referencia

Nota: Elaboración propia.

Tabla 16

Resultados del conteo manual sin fotos por un investigador

Método	Tiempo Análisis	Viables	En canoa	Eclosionados	Total
Conteo Manual (sin fotos)	30 min	1466	241	1	1709

Nota: Elaboración propia.

Discusión de Resultados

El análisis de los resultados obtenidos con el optimizador Adam y una tasa de aprendizaje inicial de 0.001 sugiere un desempeño general satisfactorio del modelo en la identificación y clasificación de diferentes tipos de huevos de mosquito de la especie *Aedes aegypti*. Para alcanzar estos objetivos, se implementó un exhaustivo procedimiento de experimentación y análisis, utilizando los optimizadores Adam y SGD con diversas tasas de aprendizaje para entrenar modelos de detección y clasificación de imágenes. Las métricas de precisión, sensibilidad, mAP50 y mAP50-95 se emplearon para evaluar el rendimiento de estos modelos. Las herramientas de software utilizadas para entrenar y preprocesar las imágenes fueron YOLO y Roboflow. Además, se desarrolló una interfaz de usuario en forma de página web para facilitar el uso del modelo y llevar el registro de los huevos. Esta interfaz permite a los usuarios realizar la clasificación, el conteo y el registro de huevos de manera eficiente y accesible.

El modelo logró una precisión general superior al 80 %, como se observa en la Tabla 7 para todas las clases de huevos. Específicamente, la clase de huevos eclosionados obtuvo la mayor precisión y sensibilidad, con valores de 0.907 y 0.926, respectivamente, lo que indica que el modelo es particularmente efectivo en la identificación de esta categoría. Sin embargo, la clase de huevos en canoa registró los valores más bajos para ambas métricas, sugiriendo retos específicos al clasificar correctamente esta clase.

Las métricas mAP50 y mAP50-95 proporcionan una perspectiva global del rendimiento del modelo, mostrando resultados consistentes. En particular, la clase de huevos eclosionados destacó con un mAP50 de 0.963. La Figura 18 de métricas de entrenamiento evidencia un aprendizaje efectivo del modelo, con las funciones de pérdida mostrando una tendencia decreciente, señal de un ajuste adecuado de los pesos del modelo a lo largo del entrenamiento. Además, la validación es esencial para asegurar que el modelo generaliza bien en datos no vistos. En este contexto, las métricas de entrenamiento y validación muestran resultados similares como se observa en la Tabla 6 y Tabla 7, proporcionando evidencia robusta de que el modelo generaliza adecuadamente.

Al analizar los resultados obtenidos con el optimizador Adam y una tasa de aprendizaje

inicial de 0.01, se observa un comportamiento coherente entre las métricas de entrenamiento de la Tabla 8 y la Tabla 9 de validación. Comparando las tablas de métricas, se destaca una coincidencia cercana entre las fases de entrenamiento y validación para todas las clases de huevos. Esto sugiere que el modelo es robusto y no está sobreajustando a los datos de entrenamiento. La clase de huevos eclosionados sigue siendo la que muestra un rendimiento más destacado en términos de precisión, sensibilidad y mAP50. Las métricas para huevos en canoa y huevos viables son ligeramente inferiores en comparación con los huevos eclosionados.

En la Figura 30, la tendencia general de la curva Precisión-Sensibilidad es positiva para todas las clases. La curva se mantiene cercana al eje de precisión 1.0, indicando un alto nivel de precisión a diferentes umbrales de sensibilidad. Sin embargo, al acercarse a una sensibilidad completa, hay una disminución en la precisión, un comportamiento esperado ya que suele ser más difícil mantener una alta precisión a altos niveles de sensibilidad. Por otro lado, al observar la Figura 31 de la matriz de confusión, se observa que los huevos en canoa y los huevos viables tienen dificultad al momento de clasificarse, mientras que los huevos eclosionados se mantienen con un margen mínimo de error en la clasificación, clasificando correctamente una proporción arriba de 0.9 de los huevos de la validación.

En resumen, el modelo ha demostrado ser eficaz en la clasificación de las diferentes clases de huevos de mosquito de la especie *Aedes aegypti*. La consistencia entre entrenamiento y validación y la alta precisión en todas las categorías señalan su potencial. Sin embargo, es esencial tener en cuenta los problemas que puede llegar a tener al tratar de clasificar los huevos viables y en canoa.

Tras analizar los resultados del modelo con el optimizador SGD y una tasa de aprendizaje inicial de 0.01, se observan métricas que brindan un panorama más claro del comportamiento del modelo para la detección y clasificación. De igual forma, las métricas de la Tabla 10 de entrenamiento y la Tabla 11 de validación son consistentes. Es importante señalar algunas áreas donde el modelo muestra oportunidades de mejora. Específicamente, la clase de huevos en canoa presenta valores más bajos en comparación con las otras categorías, tanto en precisión como en mAP50. Estos valores inferiores sugieren que el modelo podría estar encontrando dificultades al identificar o distinguir este tipo de huevos de otras categorías o elementos presentes en las imágenes. De igual manera, se puede validar en la Figura 33 con la matriz de confusión que los huevos en canoa tienen dificultad para clasificarse correctamente y tienden a clasificarse como huevos viables, y su proporción de huevos clasificados correctamente está por debajo de 0.80, en comparación con los huevos viables y eclosionados que están por encima de la misma.

Aunque las métricas para huevos eclosionados son relativamente altas, cuando se observan las métricas correspondientes a huevos viables, también se nota un margen de mejora, especialmente al compararlas con la precisión y mAP50 de huevos eclosionados. La Figura 32 muestra una curva de Precisión-Sensibilidad que, aunque en su mayoría es alta, revela una caída en precisión al acercarse a una sensibilidad más completa, especialmente con los huevos en canoa, donde es mucho menor que los huevos viables y eclosionados.

Los resultados del modelo con el optimizador SGD y una tasa de aprendizaje inicial de 0.001 evidencian que el modelo es robusto. Al observar la Tabla 12 de entrenamiento y compararla con la Tabla 13 de validación, es claro que las métricas de entrenamiento y validación son consistentes, lo cual indica que el modelo no está sobreajustado. La clase

huevos eclosionados presenta las métricas más altas, con un mAP50 de 0.97 en la validación. Esto indica una alta precisión y capacidad de sensibilidad en la detección de este tipo de huevos. Por otro lado, la clase huevos en canoa muestra resultados inferiores con un mAP50 de 0.862. Aunque esta métrica es más baja en comparación con las otras clases, aún es relativamente alta y sugiere un rendimiento adecuado en la detección de esta categoría.

De igual forma, se observa en la Figura 35 de la matriz de confusión el bajo desempeño de los huevos en canoa al tratarlos de clasificar, comparándolos con los huevos eclosionados y viables. En la Figura 34 de Precisión-Sensibilidad, se observa que la curva para huevos en canoa es más baja en comparación con las otras clases, lo que concuerda con las métricas observadas en las tablas. En resumen, el modelo logró ser robusto y evitar estar sobreajustado, pero el desempeño al tratar de clasificar correctamente los huevos en canoa es bajo en comparación con las otras categorías de huevos que tuvieron un mayor rendimiento, como se observa en las métricas y gráficas.

Después de evaluar varias configuraciones, es importante destacar el buen desempeño del modelo que utiliza el optimizador Adam con una tasa de aprendizaje inicial de 0.001. Al comparar sus métricas con las de otros modelos evaluados, este en particular muestra un rendimiento sólido en términos de precisión, sensibilidad y consistencia entre los conjuntos de entrenamiento y validación. Un aspecto crucial que merece atención es que este modelo obtuvo los mejores resultados en la matriz de confusión, especialmente en lo que respecta a la clasificación de huevos viables y canoa. Estas categorías específicas resultaron ser un desafío para los demás modelos, sin embargo, el modelo seleccionado demuestra una capacidad significativamente mayor para clasificarlas con precisión.

Dado el destacado desempeño del optimizador Adam con una tasa de aprendizaje inicial de 0.001, se procedió a evaluar la eficacia del modelo YOLOv8 en el análisis de huevos de mosquito de la especie *Aedes aegypti*. El proceso de fotografía se estableció con un umbral de confianza de 0.45 y un umbral de superposición de 0.30 para asegurar una identificación adecuada de los huevos sin incluir falsas detecciones. Este procedimiento fue esencial para la correcta interpretación de las imágenes por parte del algoritmo. El modelo YOLOv8 destaca por su rapidez en el análisis con un tiempo de 9 minutos, considerando el tiempo de toma de fotos de 110 minutos, el proceso total se eleva a 119 minutos, superando al conteo manual sin fotos. A pesar de su impresionante eficiencia en el análisis puro, la sobrecarga introducida por la captura fotográfica pone en evidencia la necesidad de optimizar todo el proceso para maximizar la eficiencia. El modelo YOLOv8 presenta una precisión global del 94.73 %. Sin embargo, al examinar sus resultados de clasificación, se identifican ciertas discrepancias en la categoría de huevos viables, el modelo identificó 392 huevos menos en comparación con el conteo manual con fotos. En la categoría de huevos en canoa, el modelo identificó 288 huevos más que el conteo manual, y en la categoría de huevos eclosionados, el modelo identificó 15 huevos más que el conteo manual. Estas variaciones apuntan a la necesidad de afinar el modelo en ciertas categorías específicas para mejorar su precisión.

El conteo manual utilizando fotografías se implementó como una estrategia de validación adicional. Al contrastar este enfoque con el conteo manual directo realizado por el experto, se identifican algunas discrepancias que pueden surgir debido a errores humanos. Estos errores pueden incluir omisiones durante la captura de fotografías o inexactitudes en el conteo. Por su parte, el experto, a pesar de su experiencia, no está exento de cometer errores ocasionales en su conteo, ya sea por sobreconteo o subconteo de huevos en ciertas áreas. Frente a estos

métodos manuales, el modelo basado en YOLOv8 resalta por su objetividad y consistencia, reduciendo las variables introducidas por el factor humano.

El desarrollo del modelo basado en YOLOv8 fue exitoso, permitiendo clasificar adecuadamente los distintos tipos de huevos de mosquito de la especie *Aedes aegypti*, alcanzando una precisión global del 94.73%. Este logro muestra la capacidad del modelo para realizar una clasificación precisa, crucial para el control de esta especie de mosquito.

La investigación y comparación de algoritmos, incluyendo Faster R-CNN, SSD, YOLO y RetinaNet, reveló que YOLO ofrecía la mejor combinación de precisión y rendimiento en términos de fotogramas por segundo (FPS). Esta elección se fundamenta en criterios de rendimiento y aplicabilidad, evidenciando que YOLO es el algoritmo más adecuado para esta tarea.

El método de captura de imágenes establecido demostró ser efectivo para la interpretación por parte del algoritmo YOLOv8, contribuyendo significativamente a la alta precisión del modelo. No obstante, se identificaron desafíos relacionados con la rapidez del procedimiento. Aunque el conteo manual sin fotografías lleva 30 minutos, la implementación completa del modelo con la captura de imágenes requiere 119 minutos. Esta discrepancia resalta la necesidad de seguir mejorando la rapidez del proceso fotográfico para maximizar las ventajas del algoritmo.

Finalmente, se desarrolló una interfaz de usuario que permite realizar la clasificación, el conteo y el registro de huevos de manera eficiente. Esta herramienta facilita a los usuarios interactuar con el sistema de forma intuitiva y efectiva, mejorando significativamente el proceso de manejo y análisis de datos de huevos de mosquito de la especie *Aedes aegypti*.

Recomendaciones

Primero, se recomienda optimizar el tiempo de captura de fotos, ya que su duración podría afectar la detección de mosquitos y la efectividad de la intervención. Sería conveniente investigar y desarrollar métodos para acelerar la captura o ajustar el protocolo para maximizar la detección.

Además, es importante mejorar el algoritmo de detección. Aunque el algoritmo utilizado mostró una precisión considerable, hay margen para el mejoramiento. Una revisión y eventual recalibración o adopción de nuevos métodos de análisis de imagen puede resultar en una identificación más precisa.

En cuanto a la expansión del proyecto, se sugiere implementar el monitoreo en tiempo real de poblaciones de mosquitos mediante cámaras de vídeo. Esto permitiría detectar y seguir continuamente a los mosquitos en áreas de alta actividad, facilitando una respuesta rápida a brotes y cambios poblacionales.

Se debe considerar también la variabilidad biológica entre los huevos de diferentes especies de mosquitos. Aunque el modelo ha sido entrenado específicamente con huevos de la especie *Aedes aegypti*, incluir variaciones morfológicas de otras especies en el conjunto de datos de entrenamiento podría mejorar su precisión y robustez. Esto requiere la expansión del conjunto de datos para abarcar una mayor diversidad de especies.

Adicionalmente, se recomienda desarrollar herramientas avanzadas de informes y visualización, incluyendo gráficos interactivos que representen el historial de conteos de mosquitos, facilitando la toma de decisiones para controlar estas poblaciones.

Finalmente, es esencial monitorear todas las fases de desarrollo de los mosquitos para controlar efectivamente sus poblaciones. El proyecto podría expandirse para abarcar todas las etapas de desarrollo del mosquito, desde larvas hasta adultos, ofreciendo una comprensión más profunda de su ciclo de vida.

- Abd, S. (2020). Life Cycle and Cytogenetic Study of Mosquitoes (Diptera: Culicidae) [Ciclo de vida y estudio citogenético de los mosquitos (Diptera: Culicidae)]. En M. Sarwar (Ed.), *Life Cycle and Development of Diptera*. IntechOpen. <https://doi.org/10.5772/intechopen.93219>
- Centro de Estudios en Salud. (2022). *Malaria*. <https://www.ces.uvg.edu.gt/page/malaria/>
- Deshpande, C. (2023a, febrero). *What is Bootstrap and How to Embed Bootstrap into Angular?* [¿Qué es Bootstrap y cómo integrar Bootstrap en Angular?]. <https://www.simplilearn.com/tutorials/angular-tutorial/angular-bootstrap>
- Deshpande, C. (2023b, julio). *What is Angular?: Architecture, Features, and Advantages* [¿Qué es Angular?: Arquitectura, características y ventajas]. <https://www.simplilearn.com/tutorials/angular-tutorial/what-is-angular>
- Díaz, F. B. (2021). *Entendiendo el LazyLoad y sus beneficios + ANGULAR - Franco Bello Díaz - Medium*. <https://fbellod.medium.com/entendiendo-el-lazyload-y-sus-beneficios-angular-b8ae4bffa199>
- Gaburro, J., Duchemin, J.-B., Paradkar, P. N., Nahavandi, S., & Bhatti, A. (2016). Assessment of ICount software, a precise and fast egg counting tool for the mosquito vector *Aedes aegypti* [Evaluación del software ICount, una herramienta precisa y rápida para el conteo de huevos del mosquito vector *Aedes aegypti*]. *Parasites & Vectors*, 9(1). <https://doi.org/10.1186/s13071-016-1870-1>
- Imam, H., Zarnigar, Sofi, G., & Seikh, A. (2014). The basic rules and methods of mosquito rearing (*Aedes aegypti*) [Las reglas y métodos básicos para la cría de mosquitos (*Aedes aegypti*)]. *Tropical Parasitology*, 4(1), 53. <https://doi.org/10.4103/2229-5070.129167>
- Jocher, G., Munawar, R., & Vina, A. (2023, marzo). *YOLO Performance Metrics* [Métricas de rendimiento de YOLO]. <https://docs.ultralytics.com/es/guides/yolo-performance-metrics/#choosing-the-right-metrics>
- Krieshok, G., & Torres Gutierrez, C. (2020). Using Computer Vision to Count *Aedes aegypti* Eggs with a Smartphone [Uso de visión por computadora para contar huevos de *Aedes aegypti* con un teléfono inteligente]. <https://doi.org/10.13140/RG.2.2.32057.72802>
- Lahondère, C., Vinauger, C., Okubo, R. P., Wolff, G. H., Chan, J. K., Akbari, O. S., & Riffell, J. A. (2019). The olfactory basis of orchid pollination by mosquitoes [La base olfativa de la polinización de orquídeas por mosquitos]. *Proceedings of the National*

- Academy of Sciences of the United States of America*, 117(1), 708-716. <https://doi.org/10.1073/pnas.1910589117>
- Li, Y., & Ren, F. (2019). Light-Weight RetinaNet for Object Detection [RetinaNet de peso ligero para la detección de objetos]. *arXiv (Cornell University)*. <https://doi.org/10.48550/arxiv.1905.10011>
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S. E., Fu, C.-Y., & Berg, A. C. (2016, enero). *SSD: Single Shot MultiBox Detector [SSD: Detector de múltiples cajas en un solo disparo]*. https://doi.org/10.1007/978-3-319-46448-0_2
- Lozada, S. (2022). *Mejores prácticas en Deep Learning - LatinXinAI - Medium*. <https://medium.com/latinxinai/mejores-practicas-en-deep-learning-f61c2af29c24>
- Mayilsamy, M. (2019). Extremely Long Viability of *Aedes aegypti* (Diptera: Culicidae) Eggs Stored Under Normal Room Condition [Extremadamente larga viabilidad de los huevos de *Aedes aegypti* (Diptera: Culicidae) almacenados bajo condiciones normales de habitación]. *Journal of Medical Entomology*, 56. <https://doi.org/10.1093/jme/tjy232>
- Organización Panamericana de la Salud. (2019, octubre). *Documento técnico para la implementación de intervenciones basado en escenarios operativos genéricos para el control del Aedes aegypti*. <https://iris.paho.org/handle/10665.2/51654>
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks [Faster R-CNN: Hacia la detección de objetos en tiempo real con redes de propuestas de regiones]. *arXiv (Cornell University)*. <https://doi.org/10.48550/arxiv.1506.01497>
- Saha, D. (2023). *Machine Learning: Training Set, Validation Set, and Test Set [Aprendizaje automático: conjunto de entrenamiento, conjunto de validación y conjunto de prueba]*. <https://medium.com/@dipan.saha/machine-learning-training-set-validation-set-and-test-set-48d10ca389db>
- Sapananavtake. (2023). *NG-ZORRO : An Angular UI Library - Sapananavtake - Medium*. <https://medium.com/@sapananavtake27/ng-zorro-203d15ac0b3e>
- Solawetz, J. (2023). What is YOLOV8? The ultimate guide [¿Qué es YOLOV8? La guía definitiva]. *Roboflow Blog*. <https://blog.roboflow.com/whats-new-in-yolov8/>
- Tan, L., Huangfu, T., Wu, L., & Chen, W. (2021). Comparison of YOLO V3, faster R-CNN, and SSD for Real-Time Pill Identification [Comparación de YOLO V3, faster R-CNN y SSD para la identificación en tiempo real de píldoras]. *Research Square (Research Square)*. <https://doi.org/10.21203/rs.3.rs-668895/v1>
- Vijayvargiya, S. (2022). *5 reasons why Vercel is the best for application deployment [5 razones por las que Vercel es el mejor para el despliegue de aplicaciones]*. <https://medium.com/nerd-for-tech/5-reasons-why-vercel-is-the-best-for-application-deployment-92009b17e601>

12.1. Anexo 1: Manual de Usuario para la Aplicación Web

Este anexo proporciona una guía detallada sobre cómo utilizar la aplicación web Mosquito Detector. Incluye instrucciones sobre el acceso a la plataforma, navegación principal, realización de conteos, y revisión del historial de conteos.

12.1.1 Acceso a la Plataforma

1. Ingrese a la plataforma a través del siguiente enlace:
<https://mosquitodetector.vercel.app/login>.
2. Inicie sesión utilizando la opción de Google con su correo.

12.1.2 Navegación Principal

Una vez iniciada la sesión, será redirigido automáticamente a la página de inicio. En la parte superior, encontrará una barra de navegación con las siguientes opciones:

- La página de realizar conteo es la página inicial donde se realiza el conteo de huevos de mosquito.
- El historial muestra una tabla con la información general de los conteos realizados.
- La sección acerca de proporciona información general sobre la página y sus desarrolladores.
- La opción de desconectar permite cerrar la sesión en la plataforma.

12.1.3 Realizar Conteo

1. En la página Realizar Conteo, podrá cargar imágenes de huevos de mosquito, ya sea arrastrando y soltando las imágenes o seleccionándolas desde su explorador de archivos.
2. Tras cargar las imágenes, aparecerá un botón de continuar. Al presionarlo, las imágenes serán enviadas para su análisis.
3. Se mostrará un pop-up con los resultados del análisis, incluyendo la cantidad de huevos totales, clasificados como viables, en canoa y eclosionados. También se proporcionará un espacio para llenar información adicional. En este pop-up encontrará tres botones:
 - El botón guardar, al presionarlo, guardará la información ingresada en las tablas y cerrará el pop-up.
 - El botón regresar cierra el pop-up sin guardar la información.
 - El botón predicción abre un nuevo pop-up donde se podrán ingresar variables para un modelo de predicción.
4. Si seleccionó predicción, ingrese las variables solicitadas en el nuevo pop-up y luego presione predecir para obtener y visualizar las predicciones. Si desea guardar esta predicción, presione guardar. En caso contrario, puede presionar regresar para cerrar el pop-up e ingresar nuevas imágenes si lo desea.
 - El botón guardar, al presionarlo, redirigirá al pop-up inicial en donde se podrán ingresar los datos generales del conteo y guardarlos en la base de datos.
 - El botón regresar cierra el pop-up sin guardar la información.
 - El botón predecir llena la nueva tabla con los datos de los huevos viables, huevos eclosionados y huevos en canoa.

12.1.4 Historial

1. En la sección Historial, encontrará una tabla con todos los conteos realizados.
2. Cada entrada de la tabla tiene un enlace para más información, que al ser presionado, lo redirigirá a Historial Detallado. Aquí se mostrará la misma información de la tabla anterior junto con una tabla adicional de Conteo de Huevecillos con información adicional del conteo seleccionado.
3. En esta sección, podrá editar la información en las tablas si lo considera necesario.

Con estos pasos, podrá hacer uso completo de la plataforma Mosquito Detector para cargar, analizar y revisar el conteo de huevos de mosquito.