

UNIVERSIDAD NACIONAL DE SAN ANTONIO ABAD
DEL CUSCO
FACULTAD DE INGENIERÍA ELÉCTRICA, ELECTRÓNICA, INFORMÁTICA Y
MECÁNICA
ESCUELA PROFESIONAL DE INGENIERÍA INFORMÁTICA Y DE SISTEMAS



TESIS

**IDENTIFICACIÓN Y CLASIFICACIÓN DE LA MOSCA DE LA
FRUTA DE LAS ESPECIES *Anastrepha fraterculus* Y *Ceratitis
capitata* EN IMÁGENES UTILIZANDO UN MODELO DE
VISIÓN COMPUTACIONAL BASADO EN TRANSFERENCIA DE
APRENDIZAJE**

PRESENTADO POR:

Br. ERICK ANDREW BUSTAMANTE FLORES

**PARA OPTAR AL TÍTULO PROFESIONAL DE
INGENIERO INFORMÁTICO Y DE SISTEMAS**

ASESOR:

Mgt. IVAN CESAR MEDRANO VALENCIA

**CUSCO - PERÚ
2024**

INFORME DE ORIGINALIDAD

(Aprobado por Resolución Nro.CU-303-2020-UNSAAC)

El que suscribe, Asesor del trabajo de investigación/tesis titulada: **IDENTIFICACIÓN Y CLASIFICACIÓN DE LA MOSCA DE LA FRUTA DE LAS ESPECIES *Anastrepha fraterculus* Y *Ceratitis capitata* EN IMÁGENES UTILIZANDO UN MODELO DE VISIÓN COMPUTACIONAL BASADO EN TRANSFERENCIA DE APRENDIZAJE** presentado por: **ERICK ANDREW BUSTAMANTE FLORES** con DNI Nro.: **75434094** para optar el título profesional/grado académico de **INGENIERO INFORMÁTICO Y DE SISTEMAS**.

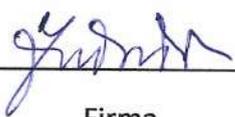
Informo que el trabajo de investigación ha sido sometido a revisión por **02** veces, mediante el **Software Antiplagio, conforme al Art. 6 del Reglamento para Uso de Sistema Antiplagio de la UNSAAC** y de la evaluación de originalidad se tiene un porcentaje de **2%**.

Evaluación y acciones del reporte de coincidencia para trabajos de investigación conducentes a grado académico o título profesional, tesis

Porcentaje	Evaluación y Acciones	Marque con una (X)
Del 1 al 10%	No se considera plagio.	X
Del 11 al 30%	Devolver al usuario para las correcciones.	
Mayor a 31%	El representante de la revisión del documento emite un informe al inmediato jerárquico, quien a su vez eleva el informe a la autoridad académica para que tome las acciones correspondientes, Sin perjuicio de las sanciones administrativas que correspondan de acuerdo a Ley.	

Por lo tanto, en mi condición de asesor, firmo el presente informe en señal de conformidad y adjunto la primera página del reporte del Sistema Antiplagio.

Cusco, 19 de diciembre de 2024.


Firma

Post firma : Mgt. Iván César Medrano Valencia

Nro. de DNI : 23881501

ORCID del Asesor: 0000-0003-0623-090X

Se adjunta:

1. Reporte generado por el Sistema Antiplagio.
2. Enlace del Reporte Generado por el Sistema Antiplagio: oid:27259:417523431

Erick Andrew Bustamante Flores

IDENTIFICACIÓN Y CLASIFICACIÓN DE LA MOSCA DE LA FRUTA DE LAS ESPECIES *Anastrepha fraterculus* Y C

 Universidad Nacional San Antonio Abad del Cusco

Detalles del documento

Identificador de la entrega

trn:oid:::27259:417523431

Fecha de entrega

19 dic 2024, 11:15 a.m. GMT-5

Fecha de descarga

19 dic 2024, 11:18 a.m. GMT-5

Nombre de archivo

Tesis_Erick_Ultimo.pdf

Tamaño de archivo

93.3 MB

99 Páginas

24,703 Palabras

138,102 Caracteres

2% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- ▶ Bibliografía
- ▶ Texto citado
- ▶ Texto mencionado
- ▶ Coincidencias menores (menos de 20 palabras)

Fuentes principales

- 1%  Fuentes de Internet
- 0%  Publicaciones
- 2%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

No se han detectado manipulaciones de texto sospechosas.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

Dedicatoria.

El presente trabajo está dedicado a Dios y a mi familia.

A Dios, quien ha guiado a mis padres en mi crianza, permitiendo que mi camino esté lleno de oportunidades para superarme. En Él deposito mi fe y encuentro la fortaleza para alcanzar mis objetivos.

A mis padres, tíos y abuelos, cuyo ejemplo siempre ha sido mi inspiración. Ellos me inculcaron los valores de la constancia y la disciplina, motivándome a esforzarme para lograr mis metas, tanto personales como profesionales.

A mi hermana y a mis primos, quienes representan mi motivación diaria para ser un ejemplo, compartiendo no solo mis experiencias, sino también mis aprendizajes.

Agradecimientos.

A la Universidad Nacional de San Antonio Abad del Cusco, por brindarme una formación académica integral que ha sido fundamental para mi desarrollo personal y profesional.

A mi asesor, el Mgtr. Iván César Medrano Valencia, y a mi coasesor, el Ph.D. Carlos Fernando Montoya Cubas, por su apoyo, dedicación y guía durante todo el proceso de esta investigación.

Al Servicio Nacional de Sanidad Agraria del Perú, por su colaboración y por proporcionarme los conocimientos necesarios que contribuyeron al logro de los objetivos planteados en esta investigación.

Resumen.

Este estudio presenta un modelo de visión computacional basado en transferencia de aprendizaje para la clasificación automatizada de las especies de moscas de la fruta *Anastrepha fraterculus* y *Ceratitis capitata*, cuya identificación manual, actualmente realizada por expertos del Servicio Nacional de Sanidad Agraria del Perú (SENASA), enfrenta limitaciones de tiempo y consistencia. La plaga de la familia Tephritidae genera graves daños en la producción frutícola de la provincia de La Convención, motivando la necesidad de soluciones que optimicen la gestión y clasificación de estas especies. SENASA ha implementado una red de trampas para capturar muestras, que luego son clasificadas en laboratorios especializados, aunque esta labor resulta compleja debido a la fatiga de los especialistas y a la variabilidad morfológica de las especies.

Para abordar estos desafíos, este proyecto implementó un modelo de aprendizaje profundo, entrenado con imágenes capturadas con un teléfono celular a través del ocular de un estereomicroscopio en un entorno controlado. Las imágenes fueron segmentadas y preprocesadas para resaltar características morfológicas relevantes, empleando los modelos preentrenados VGG16, VGG19 e Inception-v3. Los resultados mostraron que Inception-v3 alcanzó el mayor F1-score (100.00 %), superando a VGG16 (92.00 %) y a VGG19 (87.00 %). Su confiabilidad fue verificada utilizando imágenes de entornos no controlados, incluidas imágenes de internet, además de la técnica Grad-CAM, que confirmó su capacidad para capturar características clave de las especies.

Estos hallazgos sugieren que Inception-v3 es un método efectivo y aplicable en sistemas de monitoreo automatizados, con potencial para mejorar la precisión y eficiencia en la clasificación de *A. fraterculus* y *C. capitata*, apoyando así a los especialistas en el control de esta plaga y contribuyendo a una gestión agrícola más eficaz.

Palabras clave: Moscas de la fruta, *Anastrepha fraterculus*, *Ceratitis capitata*, Visión computacional, Transferencia de aprendizaje, Grad-CAM.

Abstract.

This study presents a computer vision model based on transfer learning for the automated classification of the fruit fly species *Anastrepha fraterculus* and *Ceratitis capitata*, whose manual identification, currently performed by experts from the National Agricultural Health Service of Peru (SENASA), faces limitations in terms of time, and consistency. The Tephritidae family pest causes severe damage to fruit production in the province of La Convención, creating a need for solutions to optimize the management and classification of these species. SENASA has implemented a network of traps to capture samples, which are then classified in specialized laboratories, although this task remains challenging due to the specialists' fatigue and the morphological variability of the species.

To address these challenges, this project implemented a deep learning model, trained with images captured using a mobile phone through the eyepiece of a stereomicroscope in a controlled environment. The images were segmented and preprocessed to highlight relevant morphological features, using the pre-trained models VGG16, VGG19, and Inception-v3. The results showed that Inception-v3 achieved the highest F1-score (100.00%), outperforming VGG16 (92.00%) and VGG19 (87.00%). Its reliability was verified using images from uncontrolled environments, including images from the internet, as well as the Grad-CAM technique, which confirmed its ability to capture key characteristics of the species.

These findings suggest that Inception-v3 is an effective and applicable method in automated monitoring systems, with the potential to improve precision and efficiency in the classification of *A. fraterculus* and *C. capitata*, thus supporting specialists in pest control and contributing to more effective agricultural management.

Keywords: Fruit flies, *Anastrepha fraterculus*, *Ceratitis capitata*, Computer vision, Transfer learning, Grad-CAM.

Índice general

1. Introducción.	1
1.1. Planteamiento del problema de investigación.	1
1.1.1. Descripción del problema.	1
1.1.2. Problema General.	2
1.1.3. Problemas Específicos.	2
1.2. Justificación.	2
1.3. Objetivo.	3
1.3.1. Objetivo General.	3
1.3.2. Objetivos Específicos.	3
1.4. Alcances y Limitaciones.	4
1.4.1. Alcances.	4
1.4.2. Limitaciones.	4
1.5. Metodología.	4
1.6. Resultados esperados.	6
2. Marco Teórico.	7
2.1. Herramientas.	7
2.1.1. Python (3.8.10).	7
2.1.2. Keras (2.13.1).	7
2.1.3. TensorFlow (2.13.0).	7

2.1.4.	OpenCV (4.10.0.84).	8
2.1.5.	Interpolación bilineal.	8
2.1.6.	Escala de grises.	8
2.1.7.	Umbralización.	8
2.1.8.	Filtro de mediana.	8
2.1.9.	Transformaciones morfológicas.	9
2.2.	Procesamiento de imágenes.	9
2.2.1.	Redes Neuronales Convolucionales.	9
2.2.2.	Grad-CAM.	9
2.2.3.	Visión Computacional.	10
2.2.4.	Transferencia de Aprendizaje.	10
2.2.5.	Aumento de datos.	10
2.2.6.	Segmentación de imágenes.	11
2.2.7.	Curvas de rendimiento.	11
2.2.8.	Matriz de confusión.	12
2.3.	Aplicaciones Específicas.	13
2.3.1.	Servicio Nacional de Sanidad Agraria del Perú (SENASA).	13
2.3.2.	Mosca de la fruta.	14
2.3.3.	<i>Anastrepha fraterculus</i> .	14
2.3.4.	<i>Ceratitis capitata</i> .	15
2.4.	Marco Geográfico.	16
2.4.1.	Área geográfica.	16
3.	Trabajos Relacionados.	17
3.1.	Antecedentes.	17
4.	Metodología.	22

4.1. Adquisición de imágenes.	22
4.1.1. Acceso y coordinaciones con el laboratorio.	23
4.1.2. Análisis de las características morfológicas de la mosca de la fruta.	23
4.1.3. Materiales.	30
4.1.4. Manipulación de las muestras.	31
4.1.5. Captura de imágenes.	34
4.2. Preprocesamiento de imágenes.	36
4.2.1. Exploración de los datos.	36
4.2.2. Selección aleatoria de las imágenes	36
4.3. Segmentación de imágenes.	37
4.3.1. Primera segmentación.	37
4.3.2. Segunda segmentación.	40
4.3.3. División del conjunto de datos (entrenamiento, validación y prueba).	44
4.4. Extracción de características.	45
4.4.1. Descripción de los modelos.	45
4.4.2. Aumento de Datos.	47
4.5. Clasificación.	49
4.5.1. Descripción de las capas de salida y clasificación.	49
4.5.2. Representación de la clasificación.	50
5. Experimentos y resultados.	51
5.1. Segmentación.	51
5.1.1. Procesos de segmentación.	51
5.1.2. Construcción del conjunto de datos con el proceso seleccionado.	51
5.2. Entrenamiento.	53
5.2.1. Definición de hiperparámetros.	53

5.2.2. Definición de callbacks.	54
5.3. Resultados.	54
5.3.1. Entrenamiento del modelo VGG16.	54
5.3.2. Entrenamiento del modelo VGG19.	55
5.3.3. Entrenamiento del modelo Inception-V3.	56
5.4. Comparación de tiempos.	59
5.4.1. Toma de tiempos.	59
5.4.2. Comparación de Experto versus modelo.	60
6. Discusión.	62
6.1. Segmentación.	62
6.2. Resultados.	62
6.3. Representación de los patrones que utilizan los modelos.	64
6.3.1. Grad-Cam.	65
6.4. Selección del mejor modelo.	68
6.4.1. Evaluación del Tiempo de Clasificación.	68
6.4.2. Evaluación de Métricas de Rendimiento.	68
6.4.3. Evaluación mediante Grad-CAM.	69
6.4.4. Evaluación en Escenarios No Controlados.	71
7. Conclusiones.	76
7.1. Conclusiones.	76
7.2. Recomendaciones.	78
7.3. Proyectos futuros.	79
Bibliografía	84

Índice de cuadros

4.1. Descripción morfológica del ala de <i>Anastrepha fraterculus</i>	25
4.2. Descripción morfológica del ala de <i>Ceratitis capitata</i>	26
4.3. Descripción morfológica del tórax de <i>Anastrepha fraterculus</i>	28
4.4. Descripción morfológica del tórax de <i>Ceratitis capitata</i>	29
4.5. División del conjunto de datos.	44
5.1. Matriz de confusión resumida de los modelos. Verdaderos Positivos (TP), Falsos Positivos (FP), Falsos Negativos (FN) y Verdaderos Negativos (TN).	59
5.2. Resumen de tiempo de los modelos y el experto en segundos.	61
6.1. Métricas del modelo VGG16.	63
6.2. Métricas del modelo VGG19.	63
6.3. Métricas del modelo Inception-V3.	64
6.4. Niveles de confianza de los modelos en la clasificación de las imágenes de la Figura 6.1	68
6.5. Resultados del modelo VGG16.	72
6.6. Resultados del modelo VGG19.	72
6.7. Resultados del modelo Inception V3.	72
6.8. Resultados del modelo VGG16.	73
6.9. Resultados del modelo VGG19.	73
6.10. Resultados del modelo Inception V3.	73

6.11. <i>Resultados del modelo VGG16.</i>	74
6.12. <i>Resultados del modelo VGG19.</i>	74
6.13. <i>Resultados del modelo Inception V3.</i>	74

Índice de figuras

1.1. Metodología usada.	5
2.1. <i>Trampa McPhail</i>	13
2.2. <i>Anastrepha fraterculus</i>	15
2.3. <i>Ceratitis capitata</i>	15
2.4. <i>La Convención</i>	16
4.1. <i>Secciones del ala de la mosca de la fruta</i>	24
4.2. <i>Ala Anastrepha fraterculus</i>	25
4.3. <i>Ala Ceratitis capitata</i>	26
4.4. <i>Secciones del Tórax. Esd = Escudo, Ses-es = Sutura escudo-escutelar, Esl = Escutelo, Sbe = Subcutelo y Mdt = Medioterguito</i>	27
4.5. <i>Tórax Anastrepha fraterculus</i>	28
4.6. <i>Tórax Ceratitis capitata</i>	29
4.7. <i>Xiaomi Mi 11 Lite 5G NE</i>	30
4.8. <i>Herramientas</i>	30
4.9. <i>Placas de petri</i>	30
4.10. <i>Estereomicroscopio Leica EZ4</i>	31
4.11. <i>Muestras Anastrepha fraterculus (izquierda) y Ceratitis capitata (derecha)</i>	31
4.12. <i>Muestras en placa de Petri (izquierda) y Muestra vista desde el ocular del Estereomicroscopio (derecha)</i>	32
4.13. <i>Posición dorsal sin manipular</i>	32

4.14. <i>Posición ventral sin manipular.</i>	33
4.15. <i>Posición ventral manipulada.</i>	33
4.16. <i>Posición dorsal manipulada.</i>	34
4.17. <i>Ajuste del Estereomicroscopio.</i>	35
4.18. <i>Imagen referencial de la captura de imágenes.</i>	35
4.19. <i>6 carpetas de las imágenes capturadas.</i>	36
4.20. <i>Carpetas de cada especie.</i>	36
4.21. <i>Imagen redimensionada.</i>	37
4.22. <i>Imagen en escala de grises.</i>	38
4.23. <i>Máscara del Threshold.</i>	38
4.24. <i>Imagen con todos los contornos.</i>	39
4.25. <i>Imagen con el mayor contorno.</i>	39
4.26. <i>Imagen recortada.</i>	40
4.27. <i>Primera segmentación de <i>Anastrepha fraterculus</i> (izquierda) y <i>Ceratitis capitata</i> (derecha).</i>	40
4.28. <i>Imagen redimensionada (izquierda) y Filtro de mediana (derecha).</i>	41
4.29. <i>Imagen en espacio de color hsv (izquierda) y máscara de espacio de color hsv (derecha).</i>	41
4.30. <i>Apertura (izquierda), Dilatación (centro) y Cierre (derecha).</i>	42
4.31. <i>Imagen segmentada.</i>	42
4.32. <i>Contorno mas grande (izquierda) e imagen recortada(derecha).</i>	43
4.33. <i>Imagen centrada.</i>	43
4.34. <i>Segunda segmentación de <i>Anastrepha fraterculus</i> (izquierda) y <i>Ceratitis capitata</i> (derecha).</i>	44
4.35. <i>Modelo VGG16.</i>	46
4.36. <i>Modelo VGG19.</i>	46
4.37. <i>Modelo Inception-V3.</i>	47

4.38. <i>Ejemplo del aumento de datos.</i>	48
5.1. <i>Segmentación incorrecta de <i>Anastrepha fraterculus</i> (arriba) y segmentación correcta de <i>Ceratitis capitata</i> (abajo).</i>	52
5.2. <i>Tiempo de clasificación del modelo VGG16.</i>	55
5.3. <i>Tiempo de clasificación del modelo VGG19.</i>	55
5.4. <i>Tiempo de clasificación del modelo Inception-V3.</i>	56
5.5. <i>Curvas de rendimiento del modelo VGG16.</i>	58
5.6. <i>Curvas de rendimiento del modelo VGG19.</i>	58
5.7. <i>Curvas de rendimiento del modelo Inception-V3.</i>	58
6.1. <i>Imágenes del conjunto de prueba con características resaltadas, <i>Anastrepha fraterculus</i> (izquierda) y <i>Ceratitis capitata</i> (derecha).</i>	64
6.2. <i>Predicción y representación con Grad-Cam del modelo VGG16.</i>	65
6.3. <i>Predicción y representación con Grad-Cam del modelo VGG19.</i>	66
6.4. <i>Predicción y representación con Grad-Cam del modelo Inception-V3.</i>	67
6.5. <i>Grad-Cam para la especie <i>Anastrepha fraterculus</i>.</i>	69
6.6. <i>Grad-Cam para la especie <i>Ceratitis capitata</i>.</i>	70
7.1. <i>Registro Oficial de Trampeo (ROT).</i>	85

Capítulo 1

Introducción.

1.1. Planteamiento del problema de investigación.

1.1.1. Descripción del problema.

Según [Gomez Matheus \(2005\)](#) La detección de la mosca de la fruta es uno de los componentes básicos en los programas de control de las moscas de la fruta, a través de la utilización de trampas y atrayentes de acuerdo con la especie a monitorear para realizar un seguimiento en cuanto a magnitud y duración de la infestación, número relativo de adultos, extensión de áreas infestadas y avance de la plaga.

En los distritos de la provincia de la Convención se encuentran repartidas una gran cantidad de trampas oficiales del Servicio Nacional de Sanidad Agraria del Perú (SENASA), el proceso de recolección de las muestras de cada trampa es realizada por los tramperos, los cuales vierten el atrayente de la trampa junto con las moscas atrapadas en pequeños frascos de plástico, estos frascos son etiquetados de acuerdo al sector y a los identificadores de cada trampa.

Los frascos etiquetados son enviados al distrito de Santa Ana, Quillabamba donde se encuentran los especialistas encargados de la identificación y clasificación de las especies de la mosca de la fruta con un tiempo de 10 segundos por muestra, siendo una tarea realizada de forma manual que podría presentar factores humanos que influyan en alcanzar los objetivos.

La identificación y la clasificación de la mosca de la fruta es un proceso previo que permite realizar la toma de decisiones de estrategias integradas para el control de esta plaga.

Por otro lado, el desarrollo de nuevas técnicas de automatización con relación a la inteligencia artificial ha demostrado su amplio aporte a los sistemas de control actuales. Gracias a estas nuevas tecnologías y la amplia capacidad de rendimiento de los equipos

computacionales se puede implementar un modelo de Visión Computacional que apoye a los especialistas en la identificación y clasificación de la mosca de la fruta.

1.1.2. Problema General.

¿Cuál es la precisión de un modelo de visión computacional basado en transferencia de aprendizaje para identificar y clasificar imágenes de la mosca de la fruta de las especies *Anastrepha fraterculus* y *Ceratitis capitata* para apoyar a los especialistas a tomar acciones en el control de esta plaga?

1.1.3. Problemas Específicos.

- No existe un conjunto de datos de la mosca de la fruta de las especies *Anastrepha fraterculus* y *Ceratitis capitata* que permita realizar el entrenamiento de un modelo de visión computacional basado en transferencia de aprendizaje.
- El tiempo de identificación de la mosca de la fruta de las especies *Anastrepha fraterculus* y *Ceratitis capitata* podría afectar en la toma de acciones para el control de esta plaga.
- Existen factores humanos tales como la fatiga, distracciones y subjetividad que podrían afectar a la correcta identificación y clasificación de las especies *Anastrepha fraterculus* y *Ceratitis capitata* de la mosca de la fruta.

1.2. Justificación.

Las moscas de la fruta, son unas de las principales plagas que afectan la fruticultura a nivel mundial. Existen aproximadamente 4000 especies de moscas de la fruta, distribuidas en géneros de importancia económica.

Estas especies son de importancia económica por las pérdidas que causan en la fruticultura, como indica [Municipalidad de Echarati \(2011–2014\)](#), en América latina se estima que las moscas de la fruta provocan pérdidas anuales de alrededor de 35 millones de dólares y según [Servicio Nacional de Sanidad Agropecuaria - SENASA \(2009\)](#), en el Perú se reporta que los daños generados por esta plaga, alcanzan hasta el 60 % de la producción.

Según el [Servicio Nacional de Sanidad Agraria Perú \(2014\)](#), La mosca de la fruta es una de las plagas más peligrosas que afecta los cultivos ocasionando pérdidas económicas por ser un serio obstáculo para la exportación de productos. Los frutos con larvas de mosca de la fruta pierden todo su valor comestible y comercial.

Por lo anterior mencionado podemos entender que la mosca de la fruta es una plaga que causa pérdidas económicas considerables, evitando así que los beneficiarios y productores puedan vender y/o exportar sus productos, es por ello que un proceso esencial en el control integrado de mosca de la fruta es su correcta clasificación.

Las muestras obtenidas en las trampas oficiales de SENASA ubicadas en los distritos de la provincia de la Convención son enviadas a la sede del distrito de Santa Ana donde se encuentran los especialistas que identifican y clasifican la mosca de la fruta. Este proceso permite realizar la toma de acciones para el control de esta plaga, sin embargo se encuentran factores que influyen en este proceso como son los tiempos de identificación y clasificación de las especies y los factores humanos que pueden conllevar a errores.

Actualmente no existe un identificador y clasificador de mosca de la fruta de las especies *Anastrepha fraterculus* y *Ceratitis capitata* a partir de imágenes. Por ello es necesario la búsqueda de un modelo de visión computacional basado en transferencia de aprendizaje que permita identificar y clasificar la mosca de la fruta de las especies *Anastrepha fraterculus* y *Ceratitis capitata*.

1.3. Objetivo.

1.3.1. Objetivo General.

Implementar un modelo de visión computacional basado en transferencia de aprendizaje para la identificación y clasificación de la mosca de la fruta de las especies *Anastrepha fraterculus* y *Ceratitis capitata* en imágenes para apoyar a los especialistas en el control de esta plaga.

1.3.2. Objetivos Específicos.

1. Construir el conjunto de datos de imágenes de la mosca de la fruta de las especies *Anastrepha fraterculus* y *Ceratitis capitata*.
2. Disminuir el tiempo de identificación y clasificación de las especies de la mosca de la fruta aplicando un modelo de visión computacional basado en transferencia de aprendizaje.
3. Encontrar un modelo con una alta precisión en la identificación y clasificación de la mosca de la fruta de las especies *Anastrepha fraterculus* y *Ceratitis capitata*.

1.4. Alcances y Limitaciones.

1.4.1. Alcances.

- El presente trabajo abarca la implementación de un modelo de Visión Computacional basado en Transferencia de Aprendizaje que permita realizar el proceso de identificación y clasificación de la mosca de la fruta solamente de las especies *Anastrepha fraterculus* y *Ceratitis capitata* en imágenes.
- Las muestras recolectadas de las trampas oficiales de SENASA deben ser de la mosca de la fruta que se encuentren en edad adulta.
- Las muestras recolectadas de las trampas oficiales de SENASA deben ser de la mosca de la fruta de las especies *Anastrepha fraterculus* y *Ceratitis capitata*.
- Los resultados del trabajo presentan únicamente la selección de un modelo de Visión Computacional que sirva de apoyo al proceso de identificación y clasificación de la mosca de la fruta de las especies *Anastrepha fraterculus* y *Ceratitis capitata* en imágenes.

1.4.2. Limitaciones.

- La cantidad de muestras recolectadas por cada trampa oficial de SENASA es limitada y varía según el clima en la que se encuentra la zona.
- Los factores externos, como la iluminación y la calidad de las imágenes entre otros, podrían influir en el alcance de una tasa de éxito apropiada en el modelo seleccionado.
- Las moscas poseen un ovipositor, cuya estructura presenta características distintivas que podrían facilitar la clasificación de especies de la mosca de la fruta. Sin embargo las imágenes de las muestras capturadas usadas para esta investigación fueron tomadas en posición dorsal mostrando la mosca completa, pero siendo el ovipositor una parte mas pequeña con respecto a las alas y el tórax, la calibración que hicimos en el estereomicroscopio, no permitió que el ovipositor muestras correctamente las características que resaltan en el, por eso la información de esta parte de la mosca de la fruta fue descartada para las clasificaciones realizadas por los modelos.

1.5. Metodología.

El objetivo de esta tesis es implementar un modelo de Visión Computacional basado en Transferencia de Aprendizaje para realizar la identificación y clasificación

de la mosca de la fruta de las especies *Anastrepha fraterculus* y *Ceratitis capitata* en imágenes.

El proceso propuesto para el desarrollo de esta investigación se basa en cinco pasos que permitirán describir cómo se logró alcanzar los objetivos. Estos pasos se encuentran representados en la Figura 1.1 y descritos brevemente a continuación.

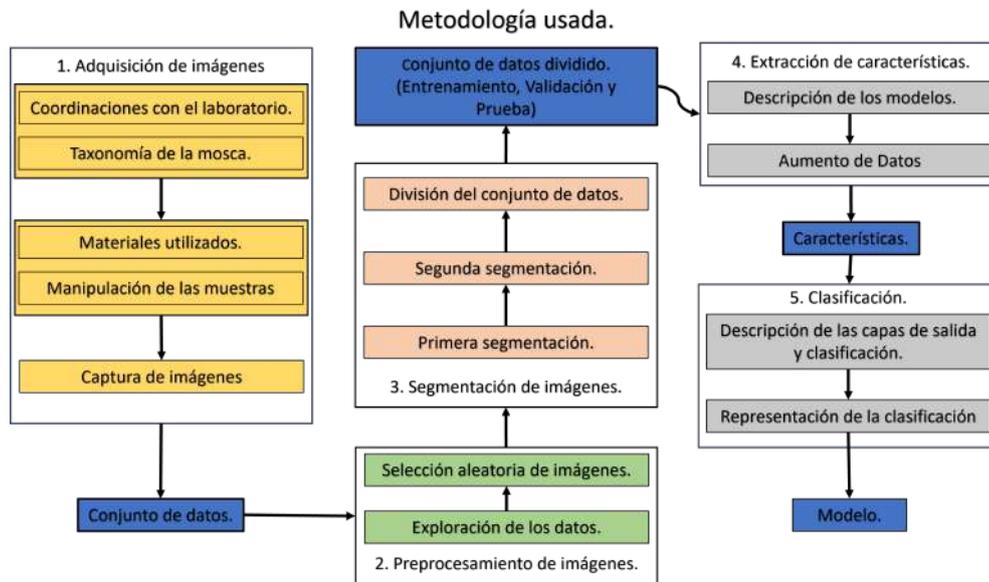


Figura 1.1: Metodología usada.

Fuente: Elaboración propia.

1. **Adquisición de imágenes.** Este paso describe el proceso de adquisición de las imágenes empezando en la coordinación con los encargados de los laboratorios hasta llegar a construir el conjunto de datos.
 - a) Acceso y coordinaciones con el laboratorio.
 - b) Análisis de las características morfológicas de la mosca de la fruta.
 - c) Materiales
 - d) Manipulación de las muestras.
 - e) Captura de imágenes.
2. **Preprocesamiento.** Este paso describe la exploración de los datos y la selección de las imágenes.
 - a) Exploración de los datos.
 - b) Selección aleatoria de las imágenes.
3. **Segmentación.** Este paso describe las pruebas aplicadas al conjunto de datos para los procesos de segmentación de las imágenes y la división de los datos para ser entregados a cada modelo.

- a) Primera segmentación.
 - b) Segunda segmentación.
 - c) División del conjunto de datos (entrenamiento, validación y prueba).
4. **Extracción de características.** Este paso describe los modelos y la facilidad que entregan a la hora de la extracción de características.
- a) Descripción de los modelos.
 - b) Aumento de datos.
5. **Clasificación.** Este paso describe el proceso de clasificación realizado por los modelos.
- a) Descripción de las capas de salida y clasificación.
 - b) Representación de la clasificación.

1.6. Resultados esperados.

1. La construcción de un conjunto de datos a partir de fotografías tomadas de muestras de las especies de mosca de la fruta *Anastrepha fraterculus* y *Ceratitis capitata*.
2. La identificación de características esenciales que permitan la clasificación correcta de las especies *Anastrepha fraterculus* y *Ceratitis capitata* de mosca de la fruta.
3. Implementación de un modelo robusto de Visión Computacional basado en Transferencia de Aprendizaje que permita realizar la identificación y clasificación de las especies *Anastrepha fraterculus* y *Ceratitis capitata* de la mosca de la fruta en imágenes.

Capítulo 2

Marco Teórico.

2.1. Herramientas.

2.1.1. Python (3.8.10).

Según [Matthes \(2023\)](#), python es un lenguaje de programación interpretado y multiplataforma, lo que le permite ejecutarse en distintos sistemas operativos sin necesidad de modificaciones. Su simplicidad y legibilidad lo han convertido en una herramienta popular tanto para desarrolladores novatos como experimentados. Utilizado en una amplia gama de aplicaciones, desde desarrollo web hasta ciencia de datos, Python destaca por su fuerte comunidad de soporte, la cual facilita el aprendizaje y la resolución de problemas. Además, ha evolucionado con el tiempo, siendo Python 3 la versión recomendada debido a sus mejoras en eficiencia y funcionalidad.

2.1.2. Keras (2.13.1).

Como indica [TensorFlow \(2022\)](#), es la API de alto nivel de TensorFlow diseñada para construir y entrenar modelos de aprendizaje profundo. Facilita la creación rápida de prototipos y la investigación avanzada en el campo del aprendizaje automático.

2.1.3. TensorFlow (2.13.0).

Como señala [Larkin A. \(2022\)](#), es una biblioteca de código abierto para Machine Learning (ML) desarrollada por Google para abordar necesidades relacionadas con redes neuronales artificiales. TensorFlow facilita la construcción y entrenamiento de redes neuronales, permitiendo la detección de patrones y el aprendizaje de razonamientos similares a los utilizados por los humanos.

2.1.4. OpenCV (4.10.0.84).

De acuerdo con [Itseez \(2024\)](#), es una librería de código abierto que cuenta con una gran cantidad de algoritmos de visión computacional y procesamiento de imágenes. Permite a los desarrolladores implementar rápidamente aplicaciones que puedan reconocer y analizar objetos en imágenes y videos. Es ampliamente utilizada en proyectos de investigación gracias a su eficiencia y facilidad de uso.

2.1.5. Interpolación bilineal.

Según [Bovik \(2005\)](#), la interpolación bilineal se define como un método que calcula una imagen transformada geoméricamente promediando los niveles de gris de los cuatro vecinos más cercanos utilizando una función bilineal. Este proceso da como resultado una interpolación visualmente más suave en comparación con el enfoque de vecino más cercano.

2.1.6. Escala de grises.

[Itseez \(2024\)](#) menciona que la conversión de una imagen RGB a escala de grises implica transformar la imagen, reduciendo la información de color a un solo canal que representa la intensidad de la luz, sin los componentes de color rojo, verde y azul.

2.1.7. Umbralización.

De acuerdo con [Ochoa-Montiel y cols. \(2018\)](#), la umbralización en segmentación de imágenes es una técnica de procesamiento que se basa en establecer un valor de umbral para separar los objetos del fondo. Utiliza el histograma de la imagen, donde se identifican las modas que representan los objetos y el fondo. El valor mínimo de la distribución del histograma se selecciona como el umbral, permitiendo distinguir los píxeles más claros (objetos) de los más oscuros (fondo).

2.1.8. Filtro de mediana.

Según [González y Woods \(1996\)](#); [Jaramillo, Fernández Muñoz, y de Salazar \(s.f.\)](#), el filtro de mediana es una técnica no lineal utilizada en el Procesamiento Digital de Imágenes (PDI) para mejorar la calidad de las imágenes, eliminando ruidos como el ruido impulsivo, también conocido como ruido de sal y pimienta¹. Este filtro es

¹El ruido de sal y pimienta es un tipo de distorsión caracterizada por la aparición aleatoria de píxeles blancos y negros en una imagen, lo que simula la dispersión de granos de sal y pimienta sobre ella. Este ruido suele ser causado por errores en la transmisión de datos, fallos en los sensores o, en

especialmente efectivo para preservar bordes mientras reduce el ruido, a diferencia de otros métodos como los filtros de paso bajo. Su funcionamiento se basa en analizar un entorno de píxeles, ordenar sus niveles de gris de menor a mayor y seleccionar como valor resultante la mediana estadística, asegurando que la mitad de los valores sean mayores y la otra mitad menores que el valor elegido. Gracias a su simplicidad y eficacia, es una de las herramientas más utilizadas en PDI.

2.1.9. Transformaciones morfológicas.

Según [González y Woods \(2017\)](#), las transformaciones morfológicas, basadas en la morfología matemática, son herramientas utilizadas en el procesamiento de imágenes para extraer componentes relevantes que permiten representar y describir la forma de las regiones, como sus bordes, esqueletos y envolventes convexas. Estas técnicas son fundamentales tanto en el preprocesamiento como en el posprocesamiento de imágenes, incluidas operaciones como el filtrado morfológico, el adelgazamiento y la poda. Además, las transformaciones morfológicas facilitan la transición entre métodos que producen imágenes como salida y aquellos que extraen atributos significativos para tareas como la extracción y descripción de objetos, siendo aplicables tanto a imágenes binarias como en escala de grises.

2.2. Procesamiento de imágenes.

2.2.1. Redes Neuronales Convolucionales.

Según [Lubinus Badillo, Rueda Hernández, Marconi Narváez, y Arias Trillos \(2021\)](#), las redes neuronales convolucionales (CNN) son un modelo fundamental en el aprendizaje profundo, especialmente en tareas de reconocimiento de imágenes. Inspiradas en la estructura del cerebro humano y en estudios de la corteza visual primaria, las CNN consisten en capas jerárquicas que procesan y transforman datos a través de módulos no lineales, facilitando la discriminación de patrones visuales complejos.

2.2.2. Grad-CAM.

Como señala [Selvaraju y cols. \(2017\)](#), Grad-CAM (Gradient-weighted Class Activation Mapping) es una técnica que combina el mapeo de activación de clases (CAM) con los gradientes de activación de clase, lo que permite generar representaciones visuales guiadas de alta resolución y específicas para cada clase.

el caso de imágenes de muestras biológicas, por restos o partículas presentes en la placa de Petri provenientes de clasificaciones manuales anteriores.

Estas representaciones se generan en las capas convolucionales del modelo, donde se conserva la información sobre las características visuales. Sin embargo, dicha información tiende a perderse en las capas completamente conectadas, que son las responsables de la clasificación final. Las capas convolucionales son cruciales, ya que retienen características de alto nivel de las imágenes, mientras que las capas completamente conectadas utilizan esas características para tomar decisiones de clasificación.

Para esta investigación, aprovecharemos la información contenida en la última capa convolucional de nuestro modelo para crear representaciones visuales que nos permitan comprender qué áreas de la imagen el modelo observa al realizar la clasificación.

2.2.3. Visión Computacional.

[González \(2022\)](#) afirma que la visión computacional es una rama de la inteligencia artificial que busca replicar las capacidades de la visión humana. No se limita únicamente a la función de los ojos o a la capacidad de capturar imágenes, como al tomar una foto con un teléfono. El objetivo va más allá de la simple vista; se trata de emular la percepción, es decir, la habilidad humana para interpretar y comprender lo que se observa.

2.2.4. Transferencia de Aprendizaje.

[Yosinski, Clune, Bengio, y Lipson \(2014\)](#) menciona que el aprendizaje por transferencia es un enfoque en el cual se entrenan redes neuronales en una tarea base con un conjunto de datos grande, y luego se reutilizan las características aprendidas para entrenar una red en una tarea objetivo con un conjunto de datos más pequeño. El éxito de este proceso depende de que las características aprendidas en la tarea base sean generales y adecuadas tanto para la tarea base como para la tarea objetivo. En situaciones donde el conjunto de datos de destino es pequeño, el aprendizaje por transferencia puede ser una herramienta poderosa, ya que permite entrenar redes grandes sin sobreajuste. Existen distintas estrategias para transferir estas características, como congelar las capas transferidas o ajustar finamente las primeras capas según el tamaño y la complejidad del conjunto de datos de destino.

2.2.5. Aumento de datos.

Según [Galán-Cuenca, Vázquez-Martín, Mandow, Morales, y García-Cerezo \(2021\)](#), el aumento de datos expande el conjunto de entrenamiento aplicando transformaciones a las imágenes originales, lo cual incrementa la cantidad y variedad de patrones en el conjunto de datos. Esto ayuda a mejorar la generalización de la red durante el aprendizaje.

2.2.6. Segmentación de imágenes.

Como indica [González y Woods \(1996\)](#); [Palomino y Concepción \(2010\)](#), la segmentación de imágenes es el proceso de dividir una imagen en sus partes constituyentes u objetos, con el fin de identificar y separar las regiones de interés del resto de la imagen. Este proceso implica la detección de bordes, regiones, líneas o curvas dentro de la imagen, y su nivel de precisión depende del problema que se desee resolver. Una segmentación precisa facilita la clasificación automática de objetos, mientras que una segmentación débil o errática casi siempre conlleva al fracaso del análisis.

2.2.7. Curvas de rendimiento.

De acuerdo con [Mohr y van Rijn \(2021\)](#), las curvas de validación y entrenamiento son gráficas que muestran cómo evoluciona el rendimiento de un modelo a medida que se ajustan sus parámetros o se incrementa la cantidad de datos de entrenamiento. Estas curvas permiten observar la capacidad del modelo para generalizar y detectar problemas como el sobreajuste (cuando el rendimiento en los datos de entrenamiento mejora, pero en los de validación empeora) o el subajuste (cuando el modelo no mejora ni en los datos de entrenamiento ni en los de validación). Son una herramienta fundamental para entender el proceso de aprendizaje y ajustar los parámetros del modelo.

2.2.7.1. Sobreajuste y Subajuste.

Las curvas de rendimiento son herramientas esenciales para evaluar y comprender el comportamiento de un modelo durante el entrenamiento, ya que permiten identificar problemas como el sobreajuste y el subajuste. Estos problemas afectan la capacidad del modelo para generalizar correctamente en nuevos datos. A continuación, se detallan ambos conceptos y cómo se pueden detectar utilizando las curvas de rendimiento:

1. Sobreajuste (Overfitting):

- **Descripción:** El sobreajuste ocurre cuando el modelo se adapta demasiado a las características particulares del conjunto de entrenamiento, incluyendo ruido o patrones irrelevantes. Como resultado, pierde efectividad al enfrentarse a datos nuevos. [Goodfellow, Bengio, y Courville \(2016\)](#).
- **Señales en las curvas:**
 - El modelo muestra un desempeño excelente en el conjunto de entrenamiento, reflejado en una alta precisión o baja pérdida.
 - Sin embargo, en el conjunto de validación, la precisión se estabiliza o comienza a disminuir mientras que la pérdida aumenta, indicando que el modelo no puede generalizar bien.

- **Causas comunes:** Esto suele suceder cuando el modelo es demasiado complejo, hay una falta de regularización adecuada o el conjunto de datos de entrenamiento es demasiado pequeño.

2. Subajuste (Underfitting):

- **Descripción:** El subajuste ocurre cuando el modelo no es capaz de capturar los patrones importantes en los datos, lo que resulta en un desempeño deficiente tanto en el entrenamiento como en la validación.
- **Señales en las curvas:**
 - Tanto la precisión en el conjunto de entrenamiento como en el de validación permanecen bajas, y no muestran mejoras significativas a medida que avanza el entrenamiento.
 - La pérdida en ambos conjuntos no se reduce considerablemente, indicando que el modelo no está aprendiendo lo suficiente.
- **Causas comunes:** Este problema puede surgir si el modelo es demasiado simple, el tiempo de entrenamiento es insuficiente, los hiperparámetros están mal configurados o los datos no contienen características relevantes.

El análisis de estas curvas proporciona información clave para diagnosticar si el modelo está bien balanceado entre aprendizaje y generalización. Esto es crucial para ajustar parámetros, elegir la arquitectura adecuada o implementar técnicas como regularización para corregir el sobreajuste, o aumentar la capacidad del modelo para solucionar el subajuste.

2.2.8. Matriz de confusión.

Como señala [Ariza-López, Rodríguez-Avi, y Alba-Fernández \(2018\)](#), la matriz de confusión es una herramienta estadística utilizada para evaluar el desempeño de modelos de clasificación. Compara las predicciones del modelo con las observaciones reales, organizando los resultados en una tabla donde las celdas diagonales indican las predicciones correctas y las celdas fuera de la diagonal reflejan los errores (falsos positivos y falsos negativos). Esta matriz permite calcular métricas clave como la precisión, recall y exactitud, que son fundamentales para evaluar la efectividad del modelo en tareas como la clasificación de especies en imágenes. Es especialmente útil en aplicaciones como la clasificación con transferencia de aprendizaje, donde se valida la exactitud del modelo frente a un conjunto de datos de referencia.

2.3. Aplicaciones Específicas.

2.3.1. Servicio Nacional de Sanidad Agraria del Perú (SENASA).

Como indica [Servicio Nacional de Sanidad Agraria del Perú \(s.f.\)](#), el Servicio Nacional de Sanidad Agraria del Perú es responsable de proteger al país contra la entrada de plagas y enfermedades, con el objetivo de preservar la riqueza agrícola y ganadera. Así, asegura que tanto los consumidores peruanos como los internacionales puedan disfrutar de alimentos sanos y seguros.

El protocolo que utiliza SENASA para la captura, identificación, clasificación y reporte de las especies de la mosca de la fruta se detalla a continuación:

- Se distribuyen un conjunto de trampas oficiales proporcionadas por SENASA, específicamente trampas del tipo McPhail (Figura 2.1). Estas trampas están diseñadas para atraer y capturar especies de moscas mediante el uso de un atrayente alimenticio de levadura de torula. Una vez atraídas, las moscas se adhieren a la trampa y quedan capturadas.



Figura 2.1: *Trampa McPhail.*

Fuente: Sáfer (2022).

- Para la recolección de las moscas capturadas, las moscas se vierte en frascos que son codificados meticulosamente de acuerdo al distrito, zona y trampa en la que fueron recolectadas.
- Estos frascos, que contienen las muestras, son entregados al experto encargado de la identificación y clasificación de las especies.
- Toda la información relacionada con las especies identificadas y clasificadas se documenta en un formato de Registro Oficial de Trampeo (ROT), el cual permite

llevar un control exhaustivo de las trampas instaladas a nivel nacional, esta información se encuentra en [Servicio de Sanidad Agraria Perú \(2007\)](#) y el documento se puede observar en la Figura 7.1.

2.3.2. Mosca de la fruta.

Como indica [Ortiz Marin \(2021\)](#), la familia Tephritidae comprende aproximadamente 4,000 especies a nivel global, comúnmente conocidas como "moscas de la fruta", una plaga de gran relevancia. En Perú, se destacan cuatro especies que son las más extendidas entre las reportadas en el país.

- *Ceratitis capitata* "Mosca mediterránea".
- *Anastrepha fraterculus* "Mosca sudamericana".
- *Anastrepha serpentina* "Mosca castaño negruzca".
- *Anastrepha striata* "Mosca de dos franjas".

Para esta investigación se seleccionaron dos especies clave: *Anastrepha fraterculus* y *Ceratitis capitata*. La elección de estas especies se basó en las recomendaciones de los especialistas sobre la dinámica poblacional de las mismas. Se consideró la inclusión de las principales especies de importancia económica en la provincia de La Convención; sin embargo, debido a la carga laboral de los especialistas y a la exhaustiva tarea de separar estas especies en frascos individuales, se optó por limitar el estudio a estas dos especies como etapa inicial. El objetivo es, en el futuro, generalizar el modelo a un conjunto más amplio de especies.

2.3.3. *Anastrepha fraterculus*.

La especie más ampliamente distribuida, cuyos estadios juveniles son muy similares a los de *Ceratitis capitata* pero se diferencian principalmente por su tamaño, presenta una cabeza de color amarillento sin manchas oscuras. El tórax muestra macrosetas negras o castañas con marcas sublaterales de color amarillo claro, mientras que el escutelo y las mesopluras son completamente amarillos. El subescutelo tiene una mancha negra a cada lado que se extiende hasta el medio del tergito. Las alas exhiben una banda S completa en la parte media y ligeramente ancha en la porción apical, con las bandas C y S conectadas y la banda V completa. El abdomen es de un color uniforme (Figura 2.2). [Ortiz Marin \(2021\)](#).



Figura 2.2: *Anastrepha fraterculus*

Fuente: [Ortiz Marin \(2021\)](#).

2.3.4. *Ceratitis capitata*.

Esta mosca, originaria de África – Marruecos, se ha propagado globalmente debido al comercio de frutas y es ligeramente más pequeña que las moscas comunes. Su color predominante es castaño, destacando un tórax negro con manchas blancas. Mide entre 4 y 5 mm de longitud. La cabeza es oscura con una cara de tono blanco grisáceo, y tiene ojos rojos vivos con cuatro pares de cerdas frontales orbitales. El tórax presenta un mesonoto negro brillante con el margen posterior y las suturas paralelas en amarillo. El escutelo también es negro brillante, salvo por una línea ondulada amarilla que cruza su base. El mesonoto tiene una zona pilosa de color gris, y a los lados del mesonoto se encuentran manchas negras. Las alas son cortas y anchas, midiendo 5 mm de largo por 2.5 mm de ancho, con manchas características y numerosos puntos negros en la base; en la parte media, hay una banda vertical oscura. El abdomen es amarillo y está cubierto con cerdas cortas y negras (Figura 2.3). [Ortiz Marin \(2021\)](#).



Figura 2.3: *Ceratitis capitata*.

Fuente: [Ortiz Marin \(2021\)](#).

2.4. Marco Geográfico.

2.4.1. Área geográfica.

El área geográfica en la cual se realizó la investigación es en la provincia de la Convención en el departamento de Cusco, en esta área se encuentran repartidas las trampas de las cuales fueron recolectadas las muestras usadas para esta investigación (Figura 2.4).



Figura 2.4: *La Convención*
Fuente: [Wikipedia](#) (2024).

Capítulo 3

Trabajos Relacionados.

3.1. Antecedentes.

1. Cuarentena interna y proceso de inspección fitosanitaria de moscas de la fruta en el mercado mayorista de frutas, Lima-Perú. (Tesis - 2023)

Un antecedente importante es la investigación de [Loarte Albornoz \(2023\)](#), que examina las actividades de certificación fitosanitaria para los hospedantes de la mosca de la fruta y sus limitaciones. Según un informe de 2019 de Gestión, el Perú pierde anualmente 100 millones de dólares debido a esta plaga, **siendo *Ceratitis capitata* y *Anastrepha spp.* las especies más perjudiciales**. Los puestos de control de SENASA desempeñan un papel clave en la protección de la producción hortofrutícola, confiscando y eliminando productos sin la documentación adecuada.

Pasos de la Inspección Fitosanitaria:

- a) **Verificación de la información:** Se confirma la solicitud de inspección y la disposición de los productos.
- b) **Muestreo de frutos:** Se realiza un muestreo aleatorio para evaluar la presencia de la plaga.
- c) **Inspección visual:** Se observa la presencia de hendiduras o galerías internas causadas por las larvas.
- d) **Certificación:** Si no hay presencia de plaga, el producto recibe el CFTI, en caso contrario, es rechazado.
- e) **Precintado:** Los productos se precintan con un sello de seguridad de SENASA para asegurar su rastreabilidad.

Resumen de rechazos de productos durante el proceso de inspección fitosanitaria por estación y año

Para el año 2021

- a) Otoño: Durazno (29.732 TM), Naranja (26.314 TM), Mango (5.172 TM).
- b) Invierno: Durazno (22.203 TM), Naranja (11.219 TM), Mango (7.031 TM).
- c) Primavera: Naranja (87.011 TM), Durazno (29.277 TM).

Para el año 2022

- a) Verano: Naranja (128.022 TM), Durazno (15.63 TM).
- b) Otoño: Naranja (33.48 TM), Durazno (17.124 TM).
- c) Invierno: Naranja (13.729 TM), Mango (6.224 TM), Durazno (5.772 TM).
- d) Primavera: Naranja (33.486 TM), Durazno (6.75 TM), Mango (0.925 TM).

Para el año 2023

- a) Verano: Naranja (45.047 TM), Durazno (22.513 TM).

Basado en los resultados de la inspección fitosanitaria de la investigación, se concluye que la mosca de la fruta genera importantes pérdidas económicas para los productores agrícolas. Estas pérdidas no solo son en términos de cantidad de producto, sino también en los costos asociados al manejo, transporte y disposición de los productos rechazados, afectando la rentabilidad del sector.

Además, los productos rechazados no pueden ser comercializados, lo que reduce las oportunidades de ingresos para los productores y afecta la competitividad de la cadena de suministro agrícola.

En conclusión, los resultados de la investigación resaltan la necesidad urgente de acelerar los procesos de prospección y monitoreo de la mosca de la fruta. Una detección temprana y un monitoreo constante permitirían identificar rápidamente los focos de infestación y realizar intervenciones oportunas, reduciendo así las pérdidas económicas y mejorando la competitividad del sector agrícola frente a esta plaga.

2. Sistema autónomo de detección de plagas en el olivar (Tesis - 2022).

La investigación de [Sánchez de la Cuadra \(2022\)](#), busca realizar la clasificación de la mosca de la fruta de la especie *Bactocera Oleae* o mosca del olivo en tomas fotográficas de trampas.

Para lograr una correcta clasificación de esta especie, se deben clasificar los insectos de las tomas fotográficas que son parte de la plaga de los que no lo son.

Para esto se hace uso de la umbralización complementada con el método Otsu para obtener de manera eficiente la segmentación de los insectos.

Las imágenes segmentadas son entregadas a una red neuronal previamente entrenada la cual se encarga de clasificar dos clases “moscas” y “no-mosca”, obteniendo una tasa de aciertos superior al 95 %.

Teniendo clasificadas las moscas, se realizó una selección de características esenciales para poder separar las moscas oscuras (moscas de varios tipos) de las moscas de color claro (pulgonos y crisópidos), haciendo uso de una red neuronal previamente entrenada.

Esta segunda clasificación permite encontrar cuáles de las moscas son parte de la plaga con una tasa de acierto del 100 %.

3. Identificación y conteo de insectos (mosca blanca, trips y minador de hoja) capturados en trampa adhesiva mediante visión e inteligencia artificial. Caso Flores El Trigal (Tesis - 2020).

López Grisales (2020) busca automatizar el proceso de conteo y caracterización de insectos atrapados en trampas sólidas.

Para la etapa de investigación se realizó una visita a campo donde se conocieron las condiciones del campo donde se harán las tomas fotográficas para así evaluar cuál será el preprocesamiento de las imágenes para obtener características adecuadas.

Para la etapa de ideación y prototipado se plantean posibles soluciones y se evalúa la implementación de la misma, ya teniendo los factores que podrían influir en la correcta clasificación de un conjunto de datos evaluamos de mejor manera el prototipado.

Para la etapa de selección de modelo se comparó la tasa de éxito de los prototipos creados para así escoger el de mejor desempeño. Escogiendo así uno de los modelos YOLO que obtuvo una precisión del 85 %, Recall de 84 % y mAP del 83.62 %.

Para concluir el trabajo, se comienza con la implementación de un software que permita hacer uso de dicho modelo.

4. Aplicación de aprendizaje profundo para la detección y clasificación automática de insectos agrícolas en trampas pegantes (Tesis - 2021).

Córdova Pérez (2021) busca implementar una herramienta que permita automatizar el reconocimiento de la población de insectos plaga a partir de fotografías de trampas pegantes.

Para poder alcanzar el objetivo de automatizar este proceso se debe construir un conjunto de datos que permite realizar el entrenamiento de un modelo.

Para esto se creó un generador de imágenes sintéticas de trampas pegantes debido a la limitada disponibilidad del mismo, para tener un conjunto de datos realista se pasaron a validar puntos específicos, con el rango de insectos por trampa, el porcentaje de iluminación y el porcentaje de ruido.

Para la etapa de entrenamiento se hizo uso de 2 modelos Faster R-CNN y YOLOv4 haciendo uso de las variables que tiene la red neuronal para así obtener mejores resultados.

El resultado de cada uno de estos modelos fue para Faster R-CNN un mAP de 94.06 % y para YOLOv4 un mAP de 95.82 %.

5. Automatic identification of fruit flies (Diptera: Tephritidae) (Artículo - 2014).

La investigación de Faria y cols. (2014), busca realizar una clasificación de las especies *Anastrepha fraterculus*, *Anastrepha obliqua* y *Anastrepha sororcula* de la mosca de la fruta utilizando un conjunto de datos con imágenes de las alas y el ovipositor de cada especie.

Para la etapa de preprocesamiento se utilizó el método Otsu combinado con una transformación morfológica de dilatación para segmentar las imágenes.

La extracción de características se realizó utilizando descriptores de color y textura, se entrenaron múltiples clasificadores individuales con las características extraídas.

Para mejorar la precisión, se aplicó un enfoque de fusión, combinando los resultados de hasta 33 clasificadores mediante un metaclasificador SVM. Se utilizó la fusión multimodal, donde combina ambos conjuntos de datos, permitiendo alcanzar una precisión del 98.8% en la clasificación final.

6. **Deep Learning applied to the Identification of Fruit Fly in Intelligent Traps (Artículo - 2019).**

La investigación de [Martins, Freitas, de Aguiar, de Brisolara, y Ferreira \(2019\)](#), busca identificar la mosca de la fruta en trampas inteligentes y clasificarlas en dos especies *Ceratitis capitata* y *Grapholita molesta*.

Se utilizaron modelos preentrenados ResNext, ResNet18, Inception y SqueezeNet donde resaltó el modelo ResNet18 con una exactitud de 84.28%.

Utilizando el modelo ResNet18 se aplicó el aumento de datos haciendo uso de “Giro vertical y horizontal”, “Rotación aleatoria” y “Borrado aleatorio” obteniendo una precisión de 93.55% y 91.28% para *Ceratitis capitata* y *Grapholita molesta* respectivamente.

Esta investigación buscaba un modelo preentrenado que tenga una arquitectura embebida que pueda ser usada en un Raspberry Pi v2, entonces implementaron el modelo SqueezeNet, que tiene esta arquitectura, con las técnicas de aumento de datos, obteniendo una precisión de 88.56% y 90.60% para *Ceratitis capitata* y *Grapholita molesta* respectivamente.

7. **CNN-SVM: A classification method for fruit fly image with the complex background (Artículo - 2020).**

En la investigación de [Peng y cols. \(2020\)](#), se busca realizar la clasificación de las especies “*Bactrocera dorsalis*” Hendel, “*Bactrocera cucurbitae*”, “*Bactrocera tau*” y “*Bactrocera scutellata*” de la mosca de la fruta en imágenes que tengan un fondo complejo.

Primero, realizaron una serie de experimentos variando los hiperparámetros de una CNN. Seleccionaron el modelo que alcanzó la mejor precisión, pero observaron que presentaba sobreajuste.

Para solucionar el sobreajuste reemplazaron la última capa Softmax por 4 modelos de “machine learning” como son Máquina de vectores de soporte (SVM), k-vecinos más cercanos (KNN), AdaBoost y Random Forest (RF) buscando así reducir el sobreajuste y mejorar la precisión.

Con los resultados de las pruebas se observó que CNN-SVM es la mejor combinación obteniendo una precisión de 92.4%.

8. **Deep feature-based classifiers for fruit fly identification (Diptera: Tephritidae) (Artículo - 2018).**

En la investigación de [Leonardo, Carvalho, Rezende, Zucchi, y Faria \(2018\)](#), se busca realizar la clasificación de tres especies de *Anastrepha*, “*Anastrepha fraterculus*”, “*Anastrepha obliqua*” y “*Anastrepha sorórcula*”.

Para este propósito se utilizaron los modelos pre entrenados ResNet, VGG16, VGG19, Xception e Inception para el enfoque de extracción de características.

Estas características se utilizaron para la comparación de la precisión de los modelos de Machine learning como son árbol de decisión, k-vecinos mas cercanos, Perceptrón Multicapa, Naive Bayes, Descenso de gradiente estocástico (SGD) y Máquina de vectores de soporte (SVM).

Utilizando la técnica de validación cruzada de 5 veces, se observó que la mejor combinación es del modelo VGG16 con SVM obteniendo la mejor precisión del 95.68 %.

9. **Remote fruit fly detection using computer vision and machine learning-based electronic trap (Artículo - 2023).**

[Molina-Rotger, Morán, Miranda, y Alorda-Ladaria \(2023\)](#) busca implementar un sistema de monitoreo de las trampas pegantes con las moscas adheridas.

Se crearon dos conjuntos de datos, el primero con las clases “Mosca del Olivo” y “Otros”, la clase “Otros” engloba tanto a las moscas que no son mosca del olivo y a los restos que podrían encontrarse en la trampa pegante.

El segundo conjunto de datos tiene las clases “Mosca de la fruta” englobando a todas las moscas y “Otros” solo centrándose en residuos.

Se utilizaron modelos de machine learning como Random Forest (RF), Máquina de vectores de soporte (SVM), Decision Tree y modelos de Deep learning como VGG16, MobileNet y Xception.

Los mejores resultados para el primer conjunto de datos fueron que RF y SVM con una precisión del 62.1 % y 86.4 % respectivamente, estos 2 modelos se entrenaron con el segundo conjunto de datos y se puede observar una mejora de los resultados obteniendo una precisión del 91.9 % para RF y 94.5 % para SVM.

10. **Determination of the Physiological Age in Two Tephritid Fruit Fly Species Using Artificial Intelligence (Artículo - 2022).**

En la investigación de [González-López y cols. \(2022\)](#), se busca determinar la edad de las pupas de la mosca de la fruta con el objetivo de volverlas estériles.

Para la construcción del conjunto de datos, se limpió una zona específica de las pupas, exponiendo los ojos de las moscas para su posterior análisis.

Se empleó la técnica de Multi-Template Matching en combinación con el modelo Inception-v1, esta técnica de preprocesamiento de imágenes por plantillas obtuvo un 72.22 % de precisión para *Anastrepha ludens* y un 83.17 % de precisión para *Ceratitidis capitata*.

Capítulo 4

Metodología.

En esta investigación se han aplicado los siguientes enfoques metodológicos:

1. **Investigación Descriptiva.** Se recopiló y analizó información detallada sobre las especies *Anastrepha fraterculus* y *Ceratitis capitata*, describiendo las características morfológicas distintivas de cada una.
2. **Investigación Cuantitativa.** Se llevó a cabo un análisis exploratorio del conjunto de datos, seguido de la selección aleatoria de imágenes con el objetivo de equilibrar la cantidad de datos por clase para garantizar el proceso de clasificación.
3. **Investigación Experimental.** Se realizaron ajustes en los hiperparámetros de los modelos utilizados, buscando optimizar su rendimiento y mejorar los resultados en la tarea de clasificación. Esta manipulación permitió identificar las configuraciones más efectivas para cada modelo.

4.1. Adquisición de imágenes.

La adquisición de imágenes es una parte fundamental en el desarrollo de modelos de inteligencia artificial (IA), ya que proporciona el conjunto de datos necesario para el entrenamiento de dichos modelos. Esta etapa es crucial, ya que la calidad de los datos capturados impactan directamente en la precisión y eficacia del modelo.

Antes de proceder con la captura de imágenes de insectos, es fundamental evaluar el entorno en el que se realizará esta tarea. Según lo señalado en [Martineau y cols. \(2017\)](#), los entornos pueden clasificarse principalmente en laboratorio y campo, cada uno con sus propios desafíos.

En este contexto, la entidad reguladora de esta plaga lleva a cabo la identificación y clasificación de las especies en sus laboratorios. Gracias a la colaboración con la entidad, se obtuvo acceso a uno de estos laboratorios, donde se sigue un protocolo

riguroso que garantiza la precisión en la captura, identificación, clasificación y reporte de las especies de la mosca de la fruta.

Durante esta etapa de la investigación, se solicitó a la entidad reguladora el acceso a un conjunto de datos fotográficos de estas especies. Sin embargo, dicha entidad indicó que no existe un conjunto de datos que cumpla con las características necesarias para continuar con la investigación. Ante esta situación, se propuso y se llevó a cabo la creación de un conjunto de datos específico para este estudio.

4.1.1. Acceso y coordinaciones con el laboratorio.

El laboratorio al cual se obtuvo acceso es responsable de la identificación de aproximadamente 27 a 30 especies de la mosca de la fruta, proceso crucial para el monitoreo y control de estas plagas. En situaciones donde se encuentra una especie que no puede ser clasificada por los especialistas locales, las sedes están obligadas a enviar la muestra a la central. Esta central, se encarga de la identificación y clasificación precisa de la especie. Una vez identificada, si se trata de una especie nueva en la zona, se emite una notificación formal sobre su presencia, lo que puede desencadenar medidas adicionales de control y estudio.

En colaboración con el especialista de esta sede, se procedió a separar específicamente las moscas de las especies *Anastrepha fraterculus* y *Ceratitis capitata* en frascos individuales. Estas muestras servirán como base para la construcción del conjunto de datos necesario para esta investigación. Este proceso no solo asegura la precisión en la identificación de las especies, sino que también garantiza que el conjunto de datos refleje fielmente la diversidad y características de las especies estudiadas, lo que es fundamental para el desarrollo de modelos de inteligencia artificial robustos y precisos.

4.1.2. Análisis de las características morfológicas de la mosca de la fruta.

Para la identificación y clasificación de las especies de mosca de la fruta, los especialistas se basan en un conjunto de características morfológicas distintivas que permiten diferenciar una especie de otra. Estas características se centran principalmente en las alas, el tórax y el ovipositor.

La revisión de las características morfológicas abordadas en esta investigación se basa en estudios detallados de las especies, como se describe en las fuentes consultadas [Hernández-Ortiz, Hernández-López, y Steck \(2020\)](#); [Norrbon y cols. \(s.f.\)](#); [Sistema Nacional de Vigilancia de Moscas de la Fruta \(S. F.a, S. F.b\)](#). Estos estudios proporcionan un marco de referencia sólido que guía el análisis morfológico de *Anastrepha fraterculus* y *Ceratitis capitata*, permitiendo definir que las características morfológicas que utilizaremos para esta investigación son las alas y el tórax de cada una de estas especies ya que estas serán visibles en las tomas fotográficas de las muestras, también permite

establecer una base científica para validar que nuestros modelos estén utilizando la información de estas características para clasificar las especies.

Las alas son de particular importancia, ya que exhiben patrones de venación y coloración específicos que varían entre especies, permitiendo una diferenciación efectiva. El tórax, por su parte, presenta patrones de coloración en su estructura lo que también es útil para la clasificación.

4.1.2.1. Secciones del Ala de la Mosca de la fruta.

Las características morfológicas de las alas proporcionan información crucial para diferenciar las diversas especies de la mosca de la fruta. El conocimiento detallado de cada sección de las alas permite identificar patrones específicos y diferencias estructurales entre las especies, lo que es esencial para la clasificación precisa en estudios entomológicos (Figura 4.1).

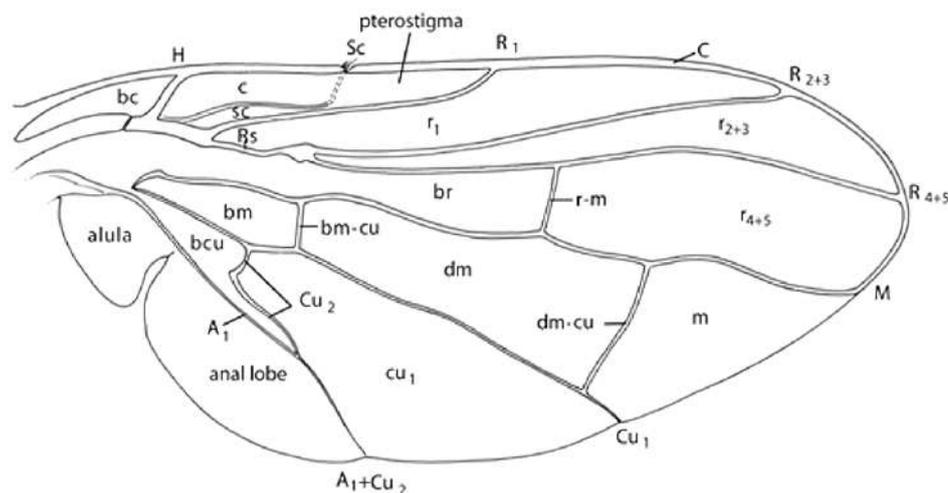


Figura 4.1: Secciones del ala de la mosca de la fruta.

Fuente: Norrbom y cols. (s.f.).

En esta investigación, uno de los enfoques son las características morfológicas de las alas de las especies bajo estudio, con el objetivo de identificar y diferenciar claramente a *Anastrepha fraterculus* y *Ceratitis capitata* a partir de sus patrones alares.

4.1.2.2. Descripción morfológicas del ala de la especie *Anastrepha fraterculus*

Estas características, esenciales para la identificación y clasificación de esta especie, se resumen en la tabla 4.1 y se ilustran en la Figura 4.2

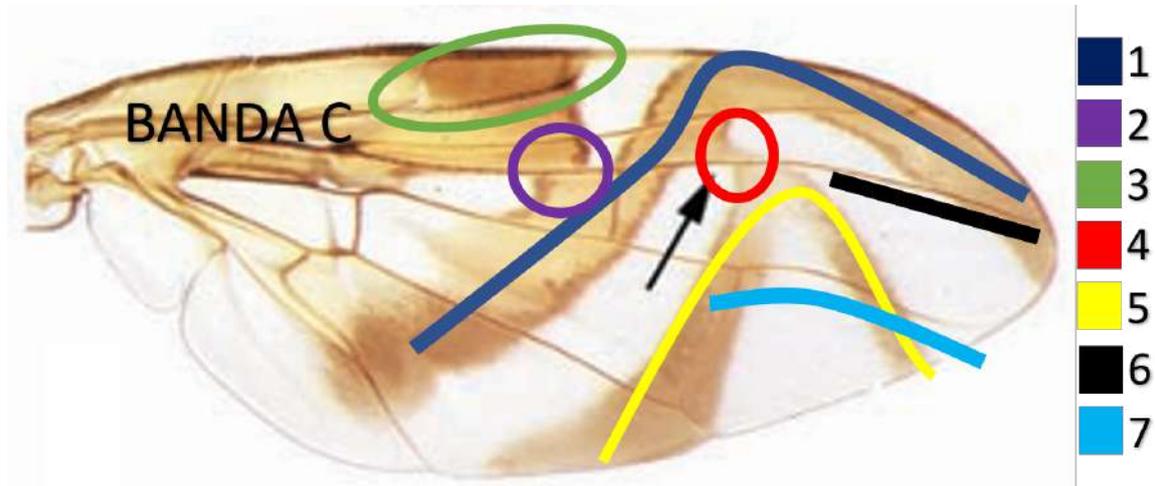


Figura 4.2: Ala *Anastrepha fraterculus*.

Fuente: Hernández-Ortiz y cols. (2020).

Cuadro 4.1: Descripción morfológica del ala de *Anastrepha fraterculus*.

Descripción morfológica del ala	Figura
Banda S completa y ligeramente ancha en su porción apical	Figura 4.2.1
Banda C y S completamente conectadas	Figura 4.2.2
Mancha hialina en el ápice de la vena R1	Figura 4.2.3
Banda S y V generalmente conectadas, en ocasiones con separación ligera	Figura 4.2.4
Banda V completa en su porción superior	Figura 4.2.5
Vena R 4+5 casi recta	Figura 4.2.6
Curvatura apical de la vena M moderada	Figura 4.2.7

Fuente: Elaboración propia.

4.1.2.3. Descripción morfológica del ala de la especie *Ceratitis capitata*.

Estas características, esenciales para la identificación y clasificación de esta especie, se resumen en la tabla 4.2 y se ilustran en la Figura 4.3

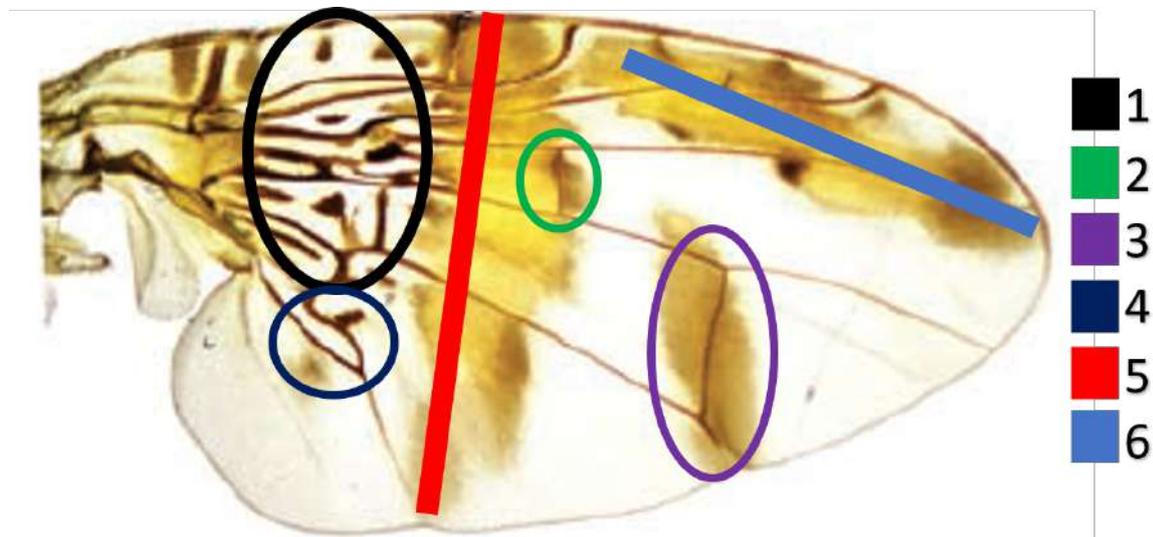


Figura 4.3: Ala *Ceratitis capitata*.

Fuente: Hernández-Ortiz y cols. (2020).

Cuadro 4.2: Descripción morfológica del ala de *Ceratitis capitata*.

Descripción morfológica del ala	Figura
Alas con un patrón a base de franjas amarillas	Figura 4.3
Franja discal	Figura 4.3.5
Franja costal extendida hasta el margen apical del ala	Figura 4.3.6
Ala con manchas oscuras en celdas bc, c, br, bm y bcu	Figura 4.3.1
Vena r-m cerca del medio de la celda dm dentro de la banda discal	Figura 4.3.2
Banda costal que pigmenta la vena dm-cu no cruza la celda r4+5	Figura 4.3.3
Lóbulo posteroapical de celda bcu más delgado en la base que en la mitad	Figura 4.3.4

Fuente: Elaboración propia.

4.1.2.4. Partes del Tórax de la Mosca de la fruta.

Las características morfológicas del tórax ofrecen información para la diferenciación entre las diversas especies de la mosca de la fruta. En particular, los patrones de coloración, la estructura del escudo, el escutelo, el subescutelo, el medioterguito y la sutura scutum-scutellar son fundamentales para la identificación taxonómica de las especies Figura 4.4.

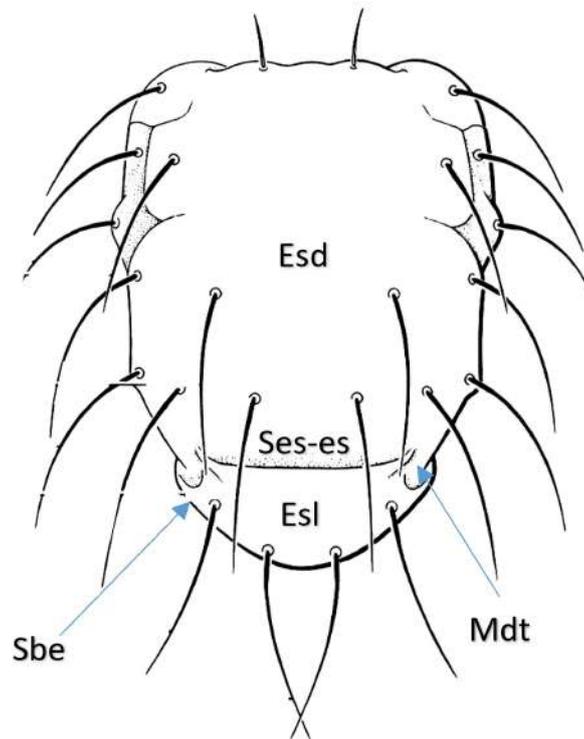


Figura 4.4: Secciones del Tórax. *Esd* = Escudo, *Ses-es* = Sutura escudo-escutelar, *Esl* = Escutelo, *Sbe* = Subscutelo y *Mdt* = Medioterguito.

Fuente: [Hernández-Ortiz y cols. \(2020\)](#); Sistema Nacional de Vigilancia de Moscas de la Fruta (S. F.b).

En esta investigación, uno de los enfoques son las características morfológicas del tórax de las especies bajo estudio, con el objetivo de identificar y diferenciar claramente a *Anastrepha fraterculus* y *Ceratitis capitata*.

4.1.2.5. Descripción morfológica del tórax de la especie *Anastrepha fraterculus*.

Estas características, esenciales para la identificación y clasificación de esta especie, se resumen en la tabla 4.3 y se ilustran en la Figura 4.5

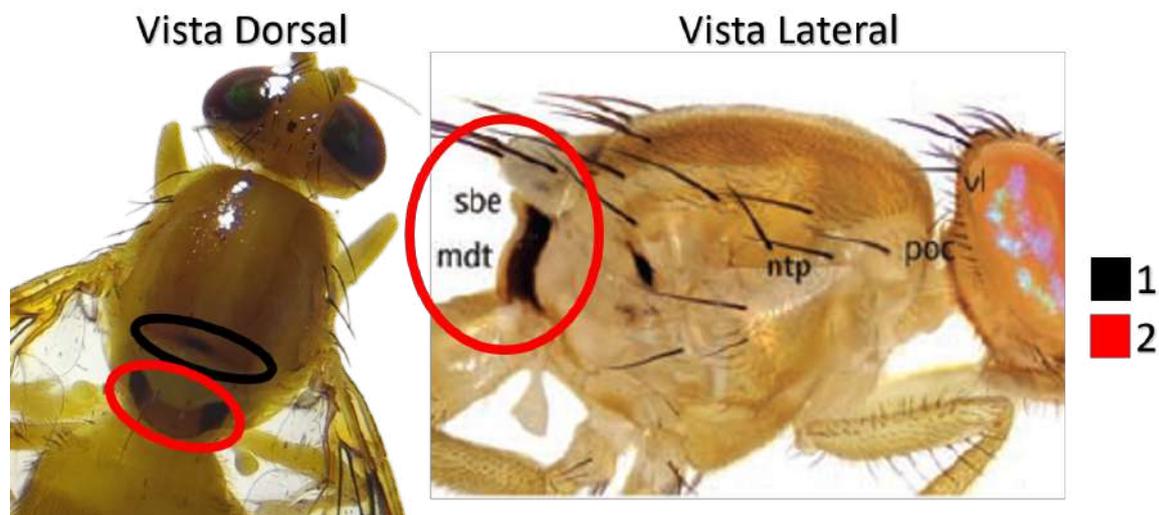


Figura 4.5: Tórax *Anastrepha fraterculus*.

Fuente: Hernández-Ortiz y cols. (2020).

Cuadro 4.3: Descripción morfológica del tórax de *Anastrepha fraterculus*.

Descripción morfológica del tórax	Figura
Mancha de la Sutura escudo-escutelar (Ses-es) generalmente presente y expandida hacia los lados	Figura 4.5.1
Subscutelo (sbe) con una mancha negra a cada lado que se extiende hasta el medioterguito (mdt)	Figura 4.5.2

Fuente: Elaboración propia.

4.1.2.6. Descripción Morfológica del tórax de la especie *ceratitis capitata*

Estas características, esenciales para la identificación y clasificación de esta especie, se resumen en la tabla 4.4 y se ilustran en la Figura 4.6

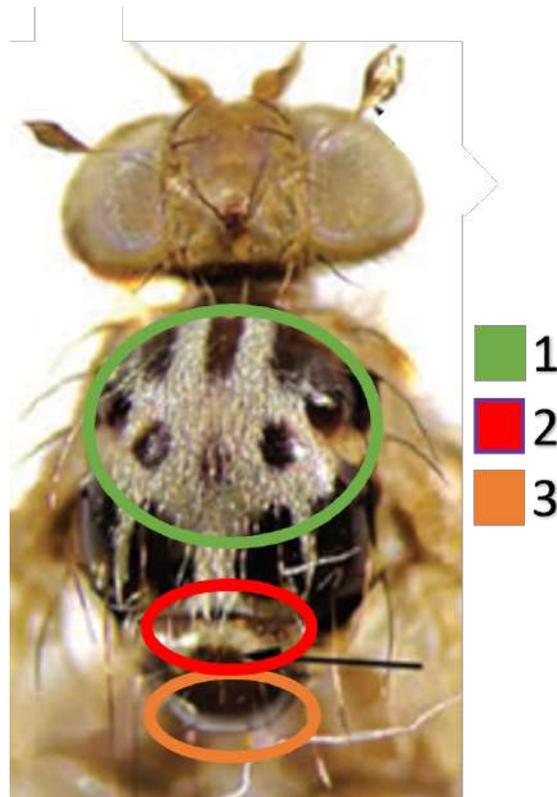


Figura 4.6: Tórax *Ceratitidis capitata*.

Fuente: [Hernández-Ortiz y cols. \(2020\)](#).

Cuadro 4.4: Descripción morfológica del tórax de *Ceratitidis capitata*.

Descripción morfológica del tórax	Figura
Escudo con manchas irregulares amarillas	Figura 4.6.1
Marca amarilla cercana a la Sutura escudo-escutelar	Figura 4.6.2
Escutelo globoso o abultado de color negro brillante	Figura 4.6.3

Fuente: Elaboración propia.

4.1.3. Materiales.

Para llevar a cabo la exploración visual y tomas fotográficas de las muestras de las moscas, previamente separadas por el encargado del laboratorio, se utilizó un conjunto específico de materiales.

- Xiaomi Mi 11 Lite 5G NE (Figura 4.7).



Figura 4.7: *Xiaomi Mi 11 Lite 5G NE.*

Fuente: Elaboración propia.

- Herramientas para la manipulación de las moscas (Figura 4.8).



Figura 4.8: *Herramientas.*

Fuente: Elaboración propia.

- Placas de Petri (Figura 4.9).



Figura 4.9: *Placas de petri.*

Fuente: Elaboración propia.

- Estereomicroscopio (Figura 4.10).



Figura 4.10: *Estereomicroscopio Leica EZ4.*

Fuente: Elaboración propia.

4.1.4. Manipulación de las muestras.

Una vez que las muestras fueron separadas, colocamos las muestras en una placa de Petri (Figura 4.11).



Figura 4.11: *Muestras Anastrepha fraterculus (izquierda) y Ceratitis capitata (derecha).*

Fuente: Elaboración propia.

Para realizar un análisis detallado, se colocó cada muestra en una placa de petri y se realizó una análisis en busca de la mejor posición y poder capturar en imágenes el mayor área de interés (Figura 4.12).

Identificamos que la posición dorsal es la más adecuada para capturar imágenes fotográficas, ya que permite observar de manera óptima las alas y el tórax, que son las principales áreas de interés en esta investigación.

Sin embargo, estas moscas al ser capturadas en las trampas se quedan adheridas en distintas posiciones lo cual podría generar errores en el proceso de entrenamiento de nuestros modelos.



Figura 4.12: *Muestras en placa de Petri (izquierda) y Muestra vista desde el ocular del Estereomicroscopio (derecha).*

Fuente: Elaboración propia.

Para mitigar estos posibles errores, manipulamos cada mosca cuidadosamente, ajustando su posición para mejorar la visibilidad de las características morfológicas clave. Antes de manipular, identificamos las causas de la mala posición de nuestras muestras.

Se colocó nuestra muestra en posición dorsal sobre una placa de Petri con alcohol al 70 %, y se utilizó un estereomicroscopio para analizar detalladamente las alas y el tórax desde los oculares. Durante la observación, notamos que nuestra muestra presentaba inclinaciones laterales y el ala izquierda retraída (Figura 4.13).

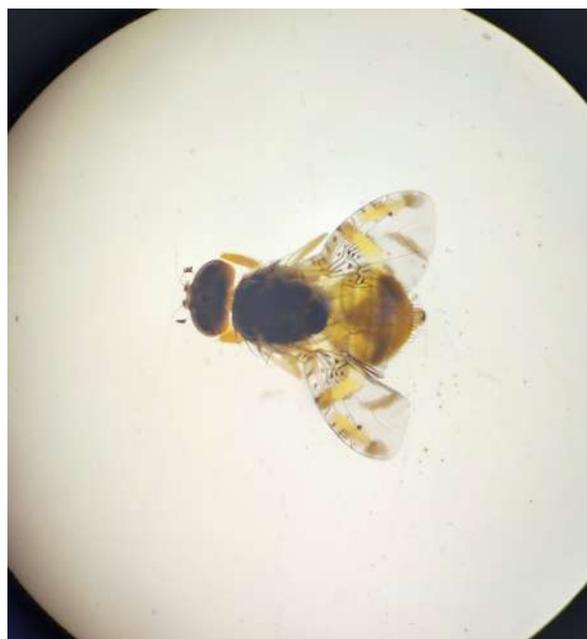


Figura 4.13: *Posición dorsal sin manipular.*

Fuente: Elaboración propia.

Se colocó nuestra muestra en posición ventral, y se observó que el abdomen de la mosca está contraído y las patas están retraídas hacia el tórax. Esto impide una visualización adecuada de la mosca desde la posición dorsal (Figura 4.14).



Figura 4.14: *Posición ventral sin manipular.*

Fuente: Elaboración propia.

Observando las causas de la mala posición de la muestra, procedimos a manipular la mosca para corregir la postura. Expandimos el abdomen y extendimos las patas desde el tórax, lo que permitió una mejor visualización de las áreas de interés, como las alas y el tórax, desde la posición dorsal (Figura 4.15).



Figura 4.15: *Posición ventral manipulada.*

Fuente: Elaboración propia.

Luego de realizar esta manipulación regresamos nuestra mosca a la posición dorsal donde podemos observar que nuestra mosca ya no se encuentra inclinada a la izquierda y que el ala izquierda muestra de forma correcta el área de interés (Figura 4.16).



Figura 4.16: *Posición dorsal manipulada.*

Fuente: Elaboración propia.

Este análisis se llevó a cabo para cada una de las muestras. En algunos casos, estos procesos de manipulación no fueron necesarios, ya que las muestras mostraban de manera correcta el área de interés en la posición dorsal.

4.1.5. Captura de imágenes.

Las tomas fotográficas de las especies *Anastrepha fraterculus* y *Ceratitis capitata* se realizaron con las moscas en posición dorsal, además estas muestras se encuentran muertas facilitando este proceso. Para ello, se utilizó un teléfono Xiaomi Mi 11 Lite 5G NE, que dispone de una función de enfoque automático. Adicionalmente, se empleó un estereomicroscopio Leica EZ4 para asegurar la correcta visualización y captura de detalles morfológicos. Esta combinación de equipos permitió obtener imágenes de alta resolución.

1. Se coloca la muestra en la placa de petri con alcohol de 70°.
2. Ajustamos el estereomicroscopio para visualizar claramente el área de interés en las alas y el tórax de la mosca. Este ajuste incluye el enfoque y la iluminación para obtener una vista nítida y detallada (Figura 4.17).
3. Si es necesario, manipulamos la muestra para corregir su posición y maximizar la visibilidad del área de interés.
4. Una vez que el área de interés está claramente identificado y visible, se colocó la cámara del teléfono Xiaomi Mi 11 Lite 5G NE en uno de los oculares del estereomicroscopio, asegurando que el objetivo de la cámara esté alineado correctamente con el ocular.



Figura 4.17: *Ajuste del Estereomicroscopio.*

Fuente: Elaboración propia.

5. Ajustamos el enfoque automático de la cámara para obtener una imagen clara y detallada del área de interés.
6. Capturamos la imagen y la guardamos en un formato adecuado para su posterior análisis.
7. Repetimos este proceso para cada una de las muestras, para mantener la consistencia en la calidad de las imágenes y la metodología de captura.

Este proceso se encuentra representado de forma referencial en la (Figura 4.18).



Figura 4.18: *Imagen referencial de la captura de imágenes.*

Fuente: Elaboración propia.

Terminada la captura de las imágenes, se observó que la resolución de estas se encuentra entre 2088 x 4640 y 3472 x 4640 píxeles. Se logró obtener un conjunto de imágenes que fueron almacenadas en formato JPG para su posterior análisis.

Las imágenes capturadas se organizaron en carpetas para facilitar su manejo y análisis. Se crearon un total de 6 carpetas, agrupando las imágenes según la especie y el día de captura. Específicamente, se dispuso de 3 carpetas para imágenes de *Anastrepha fraterculus* y 3 carpetas para imágenes de *Ceratitis capitata*. Cada carpeta contiene

imágenes correspondientes a días específicos de captura, lo que permite una mejor organización y acceso a los datos durante el análisis (Figura 4.19).



Figura 4.19: 6 carpetas de las imágenes capturadas.

Fuente: Elaboración propia.

4.2. Preprocesamiento de imágenes.

4.2.1. Exploración de los datos.

Carpetas *Anastrepha fraterculus*: Se obtuvieron 3 carpetas con imágenes de esta especie, cada una con 163, 380 y 146 imágenes respectivamente, sumando un total de 689 imágenes.

Carpetas *Ceratitis capitata*: Se obtuvieron 3 carpetas con imágenes de esta especie, cada una con 133, 101 y 52 imágenes respectivamente, sumando un total de 286 imágenes. Para realizar la selección de las imágenes, se unieron las carpetas de cada especie en una sola (Figura 4.20).



Figura 4.20: Carpetas de cada especie.

Fuente: Elaboración propia.

4.2.2. Selección aleatoria de las imágenes

Se creó una función para realizar la selección aleatoria de imágenes de una carpeta, esta función selecciona una cantidad de imágenes de la carpeta, las mueve a otras

carpetas según su especie y les da un formato en el nombre de especie-1, especie-2 ... especie-n.

Buscando mantener una cantidad homogénea de datos para ambas especies, se seleccionaron 286 imágenes de cada carpeta, siendo esta la máxima cantidad que se podría seleccionar de la especie *Ceratitis capitata*.

Una vez construido el conjunto de datos, es fundamental destacar la importancia de preservar su **privacidad**. Las fotografías utilizadas en este conjunto son de autoría de SENASA y han sido recopiladas exclusivamente por mí para esta investigación. Aunque estas imágenes podrán ser utilizadas en futuras investigaciones o publicaciones realizadas por SENASA o por mí, el acceso a ellas está estrictamente limitado a ambas partes, garantizando su uso controlado y protegido.

4.3. Segmentación de imágenes.

4.3.1. Primera segmentación.

En esta primera segmentación utilizamos una función que sigue los siguientes pasos:

1. Cargar la imagen.
2. La imagen se redimensiona a un tamaño de 800 x 600 píxeles utilizando la función **resize** de OpenCV, que cuenta con una interpolación **bilineal** que permite conservar la mayor cantidad de información al redimensionar la imagen (Figura 4.21).



Figura 4.21: *Imagen redimensionada.*

Fuente: Elaboración propia.

3. Transformamos la imagen a una escala de grises Figura 4.22.



Figura 4.22: *Imagen en escala de grises.*

Fuente: Elaboración propia.

4. Establecemos una combinación de valores para encontrar un umbral que resalte el mayor área de interés en la imagen (estos valores se aplicaron a todas las imágenes) (Figura 4.23).

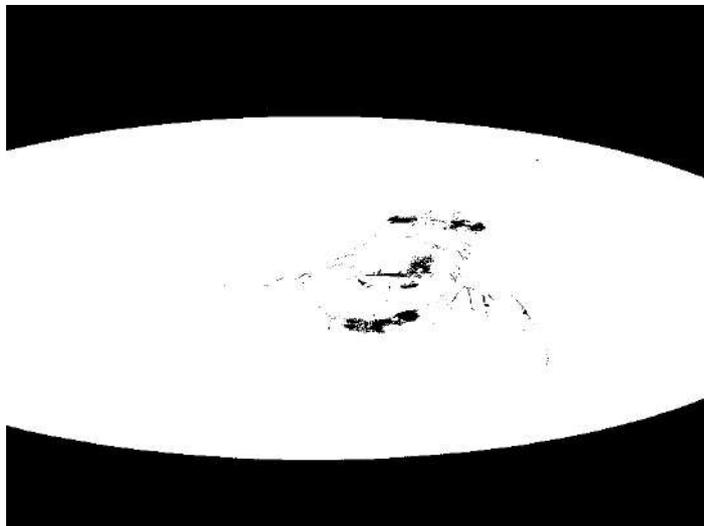


Figura 4.23: *Máscara del Threshold.*

Fuente: Elaboración propia.

5. Detectamos todos los contornos dentro de la imagen (Figura 4.24).



Figura 4.24: *Imagen con todos los contornos.*

Fuente: Elaboración propia.

6. Seleccionamos la información contenida en el contorno con el área más grande (Figura 4.25).



Figura 4.25: *Imagen con el mayor contorno.*

Fuente: Elaboración propia.

7. Recortamos la imagen utilizando las coordenadas del contorno mayor encontrado (Figura 4.26).



Figura 4.26: *Imagen recortada.*

Fuente: Elaboración propia.

8. Guardamos la imagen en otra carpeta.

La imagen final aplicando la primera segmentación a cada especie se puede observar en la Figura 4.27



Figura 4.27: *Primera segmentación de Anastrepha fraterculus (izquierda) y Ceratitis capitata (derecha).*

Fuente: Elaboración propia.

4.3.2. Segunda segmentación.

En esta segunda segmentación, utilizamos funciones diseñadas para identificar el área de mayor interés en las moscas. Estas funciones se encargan de realizar la segmentación, el recorte y el centrado de la imagen de la mosca.

Segmentación de la mosca.

1. Cargamos la imagen.
2. La imagen se redimensiona a un tamaño de 800 x 600 píxeles utilizando la función **resize** de OpenCV, que cuenta con una interpolación **bilineal** que permite conservar la mayor cantidad de información al redimensionar la imagen Figura 4.28.

3. Se aplica un filtro de mediana para suavizar la imagen y reducir el ruido de tipo “sal y pimienta” (Figura 4.28).



Figura 4.28: *Imagen redimensionada (izquierda) y Filtro de mediana (derecha).*

Fuente: Elaboración propia.

4. Convertimos la imagen al espacio de color HSV y generamos una máscara seleccionando los píxeles que se encuentran dentro de un rango específico (Figura 4.29).

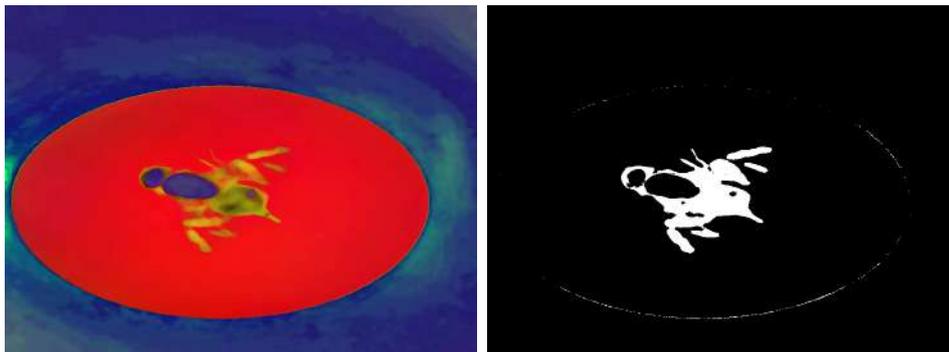


Figura 4.29: *Imagen en espacio de color hsv (izquierda) y máscara de espacio de color hsv (derecha).*

Fuente: Elaboración propia.

5. A la máscara creada anteriormente se le aplicaron varias transformaciones morfológicas (Figura 4.30).
 - **Apertura.** Eliminó las áreas de menor tamaño que no contenían información relevante.
 - **Dilatación.** Expandió el área seleccionada, abarcando toda la información relevante cercana.
 - **Cierre.** Rellenó las pequeñas áreas que quedaron dentro de las regiones identificadas por la apertura y dilatación, pero que no habían sido seleccionadas por estas.

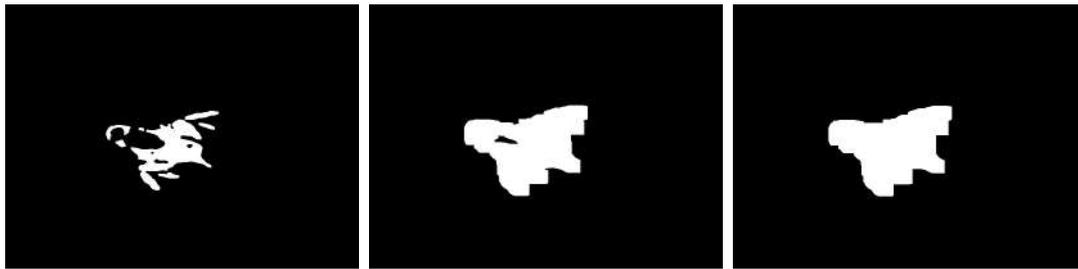


Figura 4.30: *Apertura (izquierda), Dilatación (centro) y Cierre (derecha).*

Fuente: Elaboración propia.

6. Combinamos la máscara con la imagen original para visualizar el área identificada, y se cambiaron los píxeles con valor 0 a 255, de modo que el fondo quedara blanco. Luego, recortamos la imagen para reducir el fondo y conservar únicamente la imagen segmentada (Figura 4.31).



Figura 4.31: *Imagen segmentada.*

Fuente: Elaboración propia.

Recorte.

1. Con la información de la máscara obtenida en el paso anterior, buscamos el contorno más grande y determinamos sus coordenadas para realizar el recorte (Figura 4.32).
2. Recortamos la imagen segmentada utilizando las coordenadas del contorno más grande (Figura 4.32).



Figura 4.32: *Contorno mas grande (izquierda) e imagen recortada(derecha).*

Fuente: Elaboración propia.

Centrado. Dado que al segmentar y recortar las imágenes estas tienen distintos tamaños, es necesario mantener un tamaño uniforme.

1. Optamos por un tamaño de 400 x 400 píxeles para cada imagen, con el fin de evitar un redimensionamiento excesivo de las imágenes más pequeñas. Para lograr este redimensionamiento sin distorsionar la imagen, calculamos un factor de escala dividiendo el tamaño deseado por el valor más alto entre la altura y el ancho de la imagen original.
2. Centramos la imagen dentro del tamaño de 400 x 400 píxeles y rellenamos las áreas faltantes con color blanco para mantener la uniformidad del fondo (Figura 4.33).



Figura 4.33: *Imagen centrada.*

Fuente: Elaboración propia.

La imagen final aplicando la segunda segmentación a cada especie se puede observar en la (Figura 4.34).

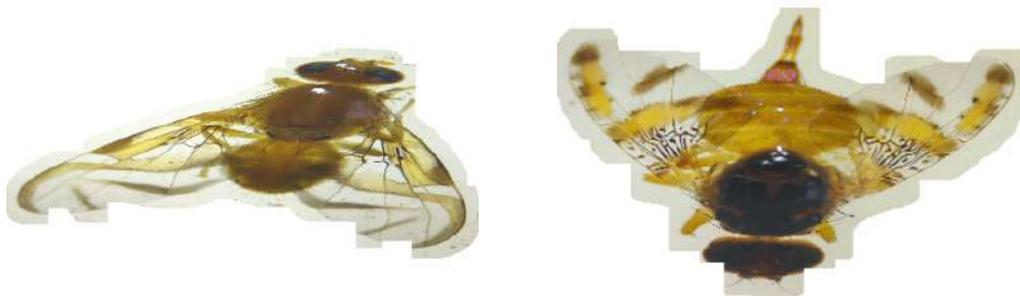


Figura 4.34: Segunda segmentación de *Anastrepha fraterculus* (izquierda) y *Ceratitis capitata* (derecha).

Fuente: Elaboración propia.

4.3.3. División del conjunto de datos (entrenamiento, validación y prueba).

Para poder realizar la división del conjunto de datos utilizamos el conjunto de datos de la segunda segmentación y realizamos los siguientes pasos.

1. Creamos 3 carpetas con los siguientes nombres train, validation y test.
2. Dentro de cada carpeta creamos 2 subcarpetas llamadas fraterculus y capitata
3. Implementamos una función que se encarga de dividir el conjunto de datos en 70 % para entrenamiento, 20 % para validación y 10 % para pruebas, también moverá las imágenes a sus respectivas carpetas según su especie (Tabla 4.5).

Cuadro 4.5: División del conjunto de datos.

Especie	Entrenamiento	Validación	Prueba
<i>Anastrepha fraterculus</i>	165	47	24
<i>Ceratitis capitata</i>	165	47	24
Total	330	94	48

Fuente: Elaboración propia.

4.4. Extracción de características.

La extracción de características es un proceso fundamental en la clasificación de imágenes, ya que permite identificar patrones, colores y descriptores, entre otros valores, que son cruciales para diferenciar entre distintas clases de objetos.

Como señala [Pan y Yang \(2009\)](#) en su estudio, la mayoría de los modelos se deben construir desde cero utilizando datos de entrenamiento recién recopilados. Sin embargo, en muchas aplicaciones del mundo real, resulta costoso o incluso imposible reunir los datos de entrenamiento necesarios para desarrollar modelos desde cero. En estos casos, sería ideal reducir la necesidad y el esfuerzo de recopilar nuevos datos de entrenamiento.

Para abordar este desafío, utilizamos la transferencia de aprendizaje, una técnica que permite transferir y reutilizar los parámetros de un modelo previamente entrenado en un problema diferente con un conjunto de datos más pequeño. [Yosinski y cols. \(2014\)](#) describe cómo esta técnica puede acelerar significativamente el proceso de modelado y mejorar los resultados en contextos donde los datos son limitados.

De acuerdo con la literatura, los modelos VGG16 y VGG19 han demostrado ser efectivos como extractores de características, como se observa en el trabajo de [Leonardo y cols. \(2018\)](#), donde ambos modelos proporcionaron resultados destacados. Por otro lado, el modelo Inception-V1, utilizado por [González-López y cols. \(2022\)](#) también mostró buenos resultados, aunque el autor sugiere que versiones más avanzadas del modelo, como Inception-V3, Inception-V4 e Inception-ResNet, podrían ofrecer mejoras adicionales debido a sus iteraciones y optimizaciones.

En esta investigación, para alcanzar nuestros objetivos y basándonos en la evidencia presentada en la literatura, emplearemos los modelos preentrenados VGG16, VGG19 e Inception-V3 junto con la técnica de transferencia de aprendizaje.

4.4.1. Descripción de los modelos.

4.4.1.1. Modelos VGG.

Como indica [Simonyan y Zisserman \(2015\)](#), los modelos VGG16 y VGG19 fueron entrenados utilizando imágenes de tamaño 224 x 224 píxeles con 3 canales de color (RGB). Ambos modelos forman parte de una arquitectura de redes neuronales profundas que se destacaron en la competencia ImageNet Large Scale Visual Recognition Challenge (ILSVRC) en 2014, logrando resultados de vanguardia en la clasificación de imágenes.

VGG16 (Figura 4.35) y VGG19 (Figura 4.36) se caracterizan por su simplicidad y eficacia, utilizando múltiples capas convolucionales con filtros pequeños de 3x3, lo que les permite capturar características detalladas de las imágenes. La principal diferencia

entre ambos modelos radica en el número de capas: VGG16 tiene 16 capas con pesos ajustables, mientras que VGG19 tiene 19. La profundidad de VGG19 permite capturar patrones más complejos, pero con un mayor tiempo de cómputo y recursos.

Ambos modelos son populares en la transferencia de aprendizaje debido a su capacidad para generalizar bien en una amplia variedad de tareas de visión por computadora, lo que los hace ideales para aplicaciones como la clasificación de especies en imágenes, como en el caso de esta investigación.

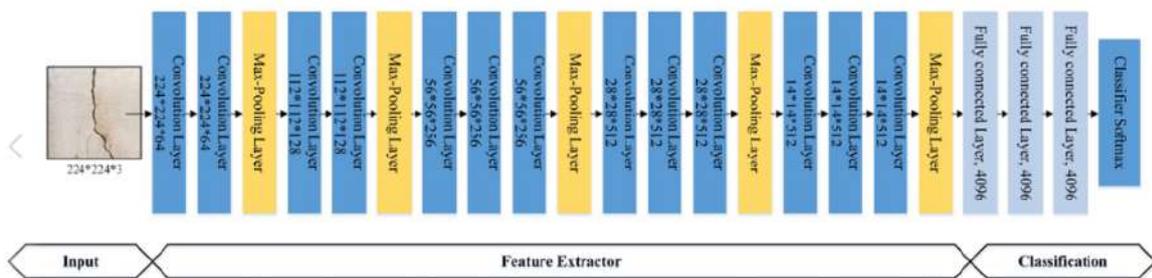


Figura 4.35: *Modelo VGG16*.

Fuente: Ali y cols. (2021).

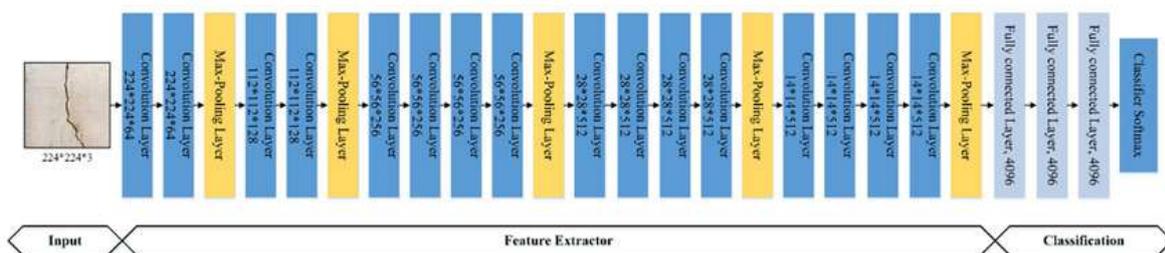


Figura 4.36: *Modelo VGG19*.

Fuente: Ali y cols. (2021).

4.4.1.2. Modelos Inception-V3.

Como se describe en [Szegedy, Vanhoucke, Ioffe, Shlens, y Wojna \(2016\)](#), el modelo Inception-v3 fue entrenado utilizando imágenes de entrada con dimensiones de 299 x 299 píxeles y 3 canales de color (RGB). Este modelo pertenece a la familia de arquitecturas Inception, que se destacó en la competencia ImageNet Large Scale Visual Recognition Challenge (ILSVRC) debido a su capacidad para obtener resultados de vanguardia en la clasificación de imágenes.

Inception-v3 es conocido por su arquitectura modular y eficiente, diseñada para optimizar tanto la precisión como el uso de recursos computacionales. Aunque el modelo puede aceptar imágenes de menor resolución, esto suele alargar el tiempo de

entrenamiento. Sin embargo, el resultado final se mantiene comparable a la obtenida con imágenes de mayor resolución, lo que resalta su flexibilidad y capacidad de adaptación a diferentes escenarios de resolución. [Szegedy y cols. \(2016\)](#).

Este modelo es ampliamente utilizado en aplicaciones de transferencia de aprendizaje debido a su robustez en la extracción de características y su capacidad para manejar imágenes complejas con una alta eficiencia. Su estructura avanzada permite la integración de múltiples filtros de diferentes tamaños en una sola capa, lo que optimiza la captura de patrones visuales en las imágenes (Figura 4.37).

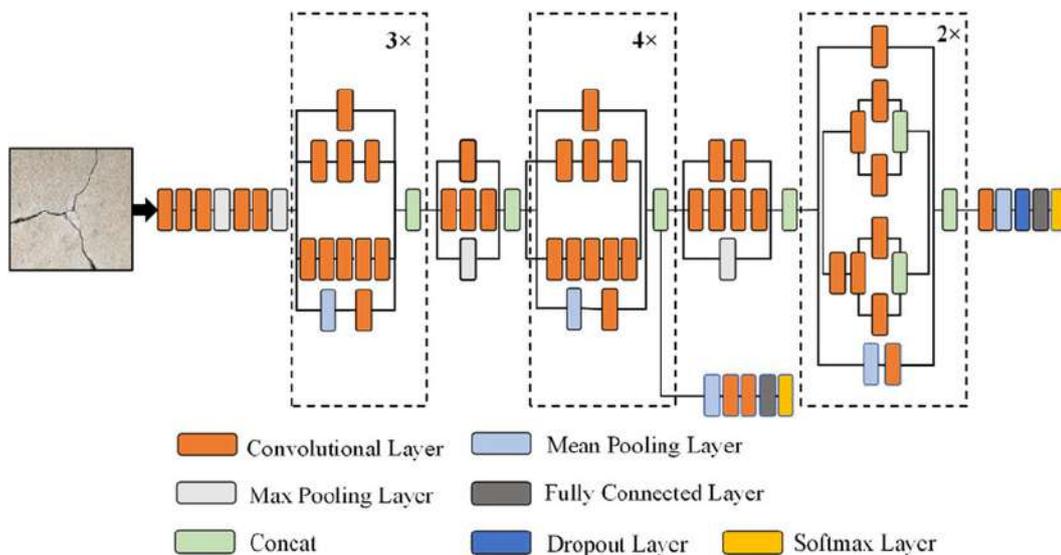


Figura 4.37: *Modelo Inception-V3*.

Fuente: [Ali y cols. \(2021\)](#).

4.4.2. Aumento de Datos.

Como indica [Høye y cols. \(2021\)](#), La necesidad de grandes volúmenes de datos de entrenamiento, cuya recopilación y etiquetado son procesos a menudo lentos, complejos y costosos, subraya la importancia de emplear técnicas que permitan entrenar modelos de aprendizaje profundo con conjuntos de datos relativamente pequeños. En este contexto, el aumento de datos es una técnica crucial en el campo del deep learning.

El aumento de datos, es un conjunto de métodos diseñados para incrementar artificialmente el tamaño y la diversidad de los datos de entrenamiento mediante transformaciones y manipulaciones de las imágenes originales. Esta técnica permite simular una variedad de escenarios y condiciones sin necesidad de recolectar datos adicionales. Entre los métodos básicos de aumento de datos se incluyen la rotación aleatoria de 180° , la inversión horizontal y vertical, como se muestra en la Figura 4.38. Estas técnicas han demostrado ser efectivas al ser combinadas en los antecedentes [González-López y cols. \(2022\)](#); [Martins y cols. \(2019\)](#); [Molina-Rotger y cols. \(2023\)](#).

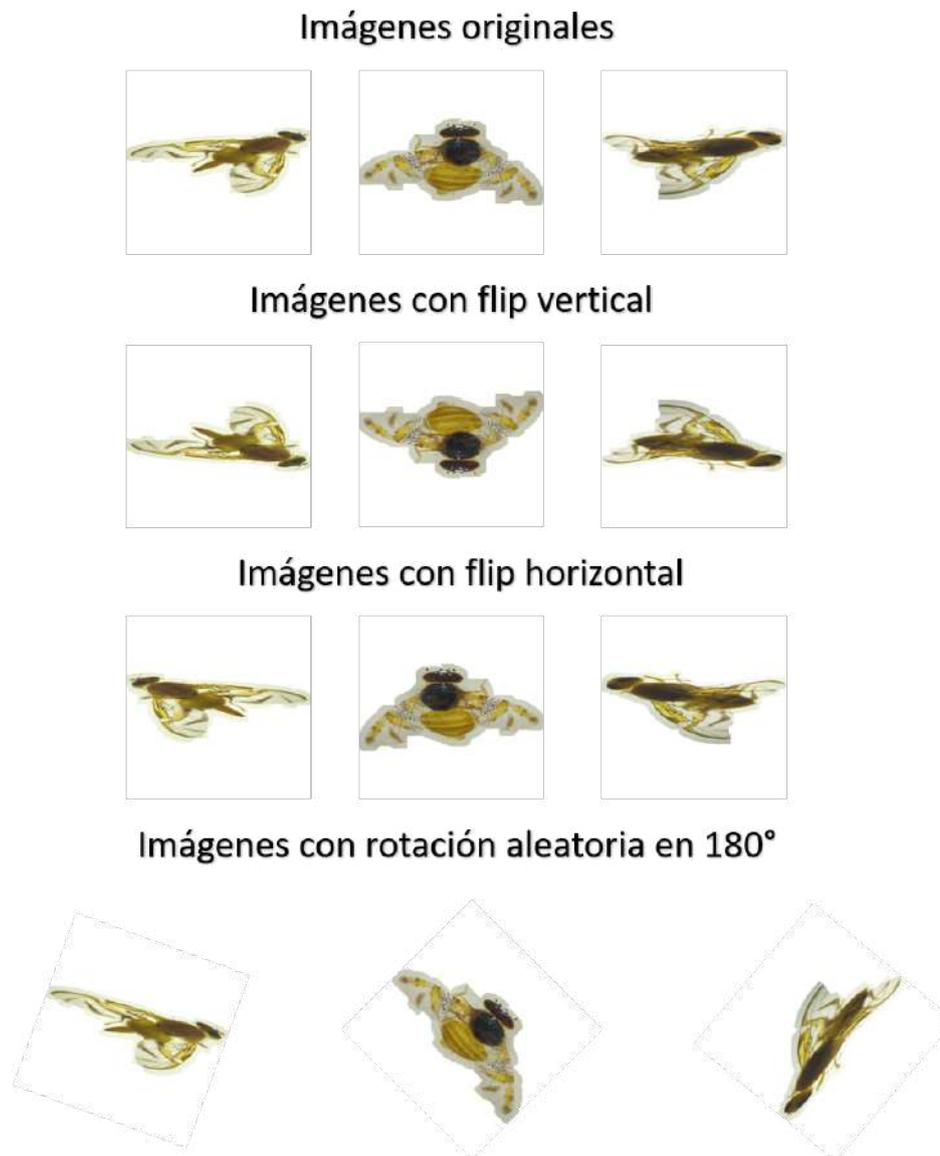


Figura 4.38: *Ejemplo del aumento de datos.*

Fuente: Elaboración propia.

Lo evidenciado en la literatura y la importancia de una gran cantidad de datos para el entrenamiento de nuestros modelos, aplicaremos las transformaciones previamente descritas a nuestro conjunto de datos (472 imágenes) durante el proceso de entrenamiento. Según [Yang y cols. \(s.f.\)](#), un aspecto crucial a tener en cuenta es que el incremento en la cantidad de datos de entrenamiento mediante el aumento de datos no siempre es de manera directa en una mejora proporcional en el rendimiento del modelo.

4.5. Clasificación.

Para la etapa de clasificación, se utilizó las características obtenidas por los modelos preentrenados VGG16, VGG19 e Inception-v3. Nuestro enfoque para la clasificación de las especies *Anastrepha fraterculus* y *Ceratitis capitata* se basó en la técnica de transferencia de aprendizaje. Esta técnica permite aprovechar los parámetros aprendidos por los modelos en grandes conjuntos de datos, como ImageNet, adaptándolos a un nuevo dominio con un conjunto de datos más reducido.

4.5.1. Descripción de las capas de salida y clasificación.

Las capas de salida en los modelos preentrenados suelen estar diseñadas para clasificar miles de categorías. Para adaptar estos modelos a las necesidades específicas de este estudio, realizamos modificaciones en las capas de salida.

La arquitectura final de la red incluye las siguientes capas adicionales

1. **BatchNormalization**: Se aplica normalización en batch para estabilizar y acelerar el entrenamiento al estandarizar las salidas de la capa anterior.
2. **GlobalAveragePooling2D**: Esta capa reduce la dimensionalidad del tensor de características, promediando los valores de cada característica a lo largo del espacio de las dimensiones, lo que facilita la generalización del modelo y reduce el riesgo de sobreajuste.
3. **Dropout (0.7)**: Se utiliza un dropout del 70 % para prevenir el sobreajuste, apagando aleatoriamente nodos en la red durante el entrenamiento y forzando al modelo a aprender representaciones más robustas.
4. **Dense (256, activation='relu')**: Se añade una capa densa con 256 neuronas y activación ReLU para capturar relaciones no lineales en los datos, proporcionando una representación más compleja de las características extraídas.
5. **Dropout (0.25)**: Un segundo dropout del 25 % se aplica antes de la capa de salida, aumentando la regularización y asegurando que el modelo no dependa excesivamente de una combinación específica de nodos.

6. **Dense (2, activation='softmax', trainable=False)**: La capa de salida es una densa con 2 neuronas y activación softmax, que produce una probabilidad para cada clase (especie) bajo estudio. Esta capa no es entrenable, ya que se utiliza como un clasificador de dos clases basado en las características extraídas.

Esta adaptación no solo mejora la precisión en la clasificación, sino que también optimiza el proceso de entrenamiento, ya que los pesos preentrenados se ajustan específicamente a las características de las especies bajo estudio. Con este enfoque, se maximiza la reutilización del conocimiento previamente adquirido por los modelos, al mismo tiempo que se logra una especialización adecuada para la tarea de clasificación.

4.5.2. Representación de la clasificación.

Como señala [Selvaraju y cols. \(2017\)](#), en la actualidad, los sistemas inteligentes a medida que son desarrollados, son integrados a nuestra vida cotidiana, pero para que estos sistemas sean útiles y confiables, deben ser “transparentes” y tener la capacidad de explicar “por qué predicen lo que predicen”.

En nuestra investigación, buscamos desarrollar un modelo que sea capaz de observar las mismas áreas que los expertos de laboratorio utilizan para clasificar las especies *Anastrepha fraterculus* y *Ceratitis capitata*. Para lograrlo, es esencial representar las predicciones del modelo de manera que puedan ser interpretadas. Con este propósito, utilizaremos la técnica Grad-CAM.

Capítulo 5

Experimentos y resultados.

5.1. Segmentación.

5.1.1. Procesos de segmentación.

En la fase inicial de la investigación, se entrenaron los modelos utilizando el conjunto de datos con el primer proceso de segmentación. Sin embargo, los resultados obtenidos durante las pruebas no fueron satisfactorios, reflejando una mala precisión en la clasificación de las especies *Anastrepha fraterculus* y *Ceratitis capitata*. Esto sugirió que el proceso de segmentación inicial no era lo suficientemente robusto para manejar las variaciones presentes en las imágenes.

Motivados por la necesidad de mejorar la segmentación y, en consecuencia, los resultados del modelo, se exploraron alternativas para perfeccionar este proceso. Finalmente, se identificó un segundo proceso de segmentación, diseñado para aislar de manera más precisa el área de interés en cada imagen, minimizando los efectos adversos de las variaciones en contraste, iluminación y brillo. Este nuevo proceso de segmentación fue implementado y utilizado en los entrenamientos subsecuentes, lo que permitió alcanzar los objetivos establecidos para esta investigación.

5.1.2. Construcción del conjunto de datos con el proceso seleccionado.

El conjunto de datos se obtuvo a partir de la captura manual de imágenes a través de los oculares de un estereomicroscopio. Este método, aunque efectivo para la captura rápida de imágenes, introdujo variaciones notables en el contraste, la iluminación y el brillo de las imágenes. Estas inconsistencias representan un desafío significativo en el procesamiento y segmentación de imágenes, ya que afectan la capacidad del modelo para extraer características consistentes y, por ende, realizar una clasificación precisa.

Durante la etapa de segmentación, se observó que variaciones en iluminación y contraste generaron errores de segmentación en ciertas imágenes. En particular, estas variaciones provocaron que áreas de interés, como las alas y el tórax de las especies *Anastrepha fraterculus* y *Ceratitis capitata*, no fueran correctamente identificadas, mientras que áreas irrelevantes se conservaron en el resultado segmentado. Este problema se ilustra en la Figura 5.1: en las imágenes de la fila superior, la segmentación es inadecuada, ya que, como se observa en la segunda imagen, no se segmenta solo la mosca, sino también partes del fondo que no son de interés para el modelo. En contraste, la segunda imagen de la fila inferior muestra una segmentación precisa que aísla únicamente la mosca, permitiendo que esta imagen sea utilizada en el proceso de segmentación, mientras que la otra sea descartada.



Figura 5.1: Segmentación incorrecta de *Anastrepha fraterculus* (arriba) y segmentación correcta de *Ceratitis capitata* (abajo).

Fuente: Elaboración propia.

Para asegurar que el conjunto de datos utilizado en el entrenamiento de los modelos fuera de calidad, se realizó el descarte de algunas imágenes. Este proceso consistió en revisar manualmente cada imagen segmentada y eliminar aquellas que no cumplieran con los criterios establecidos. Como resultado, el conjunto de datos original se redujo de forma significativa, quedando finalmente en 236 imágenes por clase. Este conjunto, aunque más pequeño, garantizó que las imágenes restantes fueran de calidad y repre-

sentativas de las características morfológicas de interés.

Este paso fue crucial para mejorar la fiabilidad del modelo en la etapa de entrenamiento y minimizar el impacto de las variaciones no controladas en las predicciones. La reducción del conjunto de datos también muestra la importancia de la calidad sobre la cantidad en la construcción de modelos de clasificación, especialmente cuando se trabaja con técnicas de aprendizaje profundo y transferencia de aprendizaje, como es el caso en esta investigación.

5.2. Entrenamiento.

Para garantizar un entrenamiento efectivo de nuestros modelos, se buscó homogeneizar el conjunto de datos antes de ser entregados al modelo.

Como se detalla en [Simonyan y Zisserman \(2015\)](#), los modelos VGG16 y VGG19 fueron originalmente entrenados con imágenes de 224 x 224 píxeles, mientras que en [Szegedy y cols. \(2016\)](#) se especifica que el modelo Inception-v3 fue entrenado con imágenes de 299 x 299 píxeles. Sin embargo, también se indica que el modelo Inception-v3 puede procesar imágenes de menor resolución sin comprometer significativamente su rendimiento.

Para lograr la homogeneización del conjunto de datos y asegurar la compatibilidad con los modelos, todas las imágenes fueron redimensionadas a 224 x 224 píxeles, respetando así la estructura de la capa de entrada de cada modelo. Este redimensionamiento se combinó con las funciones de preprocesamiento específicas de cada arquitectura.

La función `preprocess_input()` de los modelos VGG16 descrita en [TensorFlow Authors \(2024b\)](#) y VGG19 descrita en [TensorFlow Authors \(2024c\)](#), realiza varias transformaciones: convierte el array de la imagen al tipo `float32`, cambia el espacio de color de RGB a BGR, y aplica un proceso de centrado en cero, que consiste en restar la media de cada canal de color a cada píxel del canal correspondiente.

Por otro lado, la función `preprocess_input()` del modelo Inception-v3 descrita en [TensorFlow Authors \(2024a\)](#), transforma el array de la imagen al tipo `float32` y escala los valores de los píxeles a un rango de -1 a 1. Esta escala es crucial para aprovechar al máximo las funciones de activación de la red, particularmente en capas profundas.

5.2.1. Definición de hiperparámetros.

Para cada modelo, se utilizaron los siguientes hiperparámetros:

- Tasa de aprendizaje: 0.0001
- Número de épocas: 100

- Función de pérdida: *categorical_crossentropy*
- Optimizador: SGD con un momentum de 0.8
- Tamaño de lote: 16

5.2.2. Definición de callbacks.

Se utilizaron los siguientes *callbacks* en todos los modelos para mejorar la eficiencia y robustez del entrenamiento:

- **EarlyStopping.** Este *callback* interrumpe el entrenamiento cuando la métrica monitoreada deja de mejorar después de un número específico de épocas. Es esencial para evitar el sobreajuste del modelo.
- **ModelCheckpoint.** Este *callback* guarda periódicamente el modelo en archivos de puntos de control, ya sea al finalizar cada época o cuando se alcanza un nuevo rendimiento óptimo en la métrica seleccionada. Esto garantiza la conservación del mejor modelo generado durante el entrenamiento.

La combinación de ambos *callbacks* permite lograr un proceso de entrenamiento más robusto y eficiente. Por un lado, se previene el sobreajuste al detener el entrenamiento cuando no hay mejoras en la métrica monitoreada durante un número de épocas consecutivas. Por otro, se asegura la retención del mejor modelo entrenado hasta ese momento.

En nuestra investigación, configuramos el número de épocas para el *EarlyStopping* en 25 y utilizamos *val_accuracy* como métrica de monitoreo para ambos *callbacks*.

5.3. Resultados.

Después de completar la etapa de entrenamiento, analizamos el rendimiento de los modelos utilizando los hiperparámetros y técnicas descritas previamente. Los resultados presentados a continuación se centran en evaluar la capacidad de los modelos VGG16, VGG19 e Inception V3 para clasificar correctamente las especies *Anastrepha fraterculus* y *Ceratitis capitata*.

5.3.1. Entrenamiento del modelo VGG16.

El modelo VGG16 alcanzó su mejor rendimiento en la época 91, con un tiempo total de entrenamiento de 4750.1 segundos. Para el conjunto de prueba compuesto por 48 imágenes, el tiempo promedio de predicción por imagen fue de 0.2443 segundos, lo

que resultó en un tiempo total de predicción de 11.7275 segundos. Estos resultados se detallan en la Figura 5.2, mostrando la eficiencia del modelo tanto en el proceso de entrenamiento como en la predicción, también presentamos las curvas de rendimiento en la Figura 5.5 y la matriz de confusión resumida en la Tabla 5.1.

```
[20]: rutas_test, plot_predicciones_test, plot_label_test = predict_all_images(test_imagenes_test, label_img_test, modelo_cargado)
1/1 [=====] - 0s 252ms/step
1/1 [=====] - 0s 312ms/step
1/1 [=====] - 0s 213ms/step
1/1 [=====] - 0s 240ms/step
1/1 [=====] - 0s 199ms/step
1/1 [=====] - 0s 247ms/step
1/1 [=====] - 0s 188ms/step
1/1 [=====] - 0s 176ms/step
1/1 [=====] - 0s 185ms/step
1/1 [=====] - 0s 202ms/step
1/1 [=====] - 0s 178ms/step
1/1 [=====] - 0s 178ms/step
1/1 [=====] - 0s 225ms/step
Tiempo promedio de predicción por imagen: 0.2443 segundos
Tiempo total de predicción: 11.7275 segundos
Tiempo total de para coratititis: 6.4237 segundos
Tiempo total de para anastropha: 5.3037 segundos
Total de imágenes clasificadas: 48 imágenes
```

Figura 5.2: *Tiempo de clasificación del modelo VGG16.*

Fuente: Elaboración propia.

5.3.2. Entrenamiento del modelo VGG19.

El modelo VGG19 alcanzó su mejor rendimiento en la época 79, con un tiempo total de entrenamiento de 5831.29 segundos. Para el conjunto de prueba compuesto por 48 imágenes, el tiempo promedio de predicción por imagen fue de 0.2550 segundos, lo que resultó en un tiempo total de predicción de 12.2405 segundos. Estos resultados se detallan en la Figura 5.3, mostrando la eficiencia del modelo tanto en el proceso de entrenamiento como en la predicción, también presentamos las curvas de rendimiento en la Figura 5.6 y la matriz de confusión resumida en la Tabla 5.1.

```
[21]: rutas_test, plot_predicciones_test, plot_label_test = predict_all_images(test_imagenes_test, label_img_test, modelo_cargado)
1/1 [=====] - 0s 210ms/step
1/1 [=====] - 0s 231ms/step
1/1 [=====] - 0s 251ms/step
1/1 [=====] - 0s 242ms/step
1/1 [=====] - 0s 232ms/step
1/1 [=====] - 0s 225ms/step
1/1 [=====] - 0s 213ms/step
1/1 [=====] - 0s 233ms/step
1/1 [=====] - 0s 237ms/step
1/1 [=====] - 0s 255ms/step
1/1 [=====] - 0s 237ms/step
1/1 [=====] - 0s 234ms/step
1/1 [=====] - 0s 240ms/step
Tiempo promedio de predicción por imagen: 0.2550 segundos
Tiempo total de predicción: 12.2405 segundos
Tiempo total de para coratititis: 6.3103 segundos
Tiempo total de para anastropha: 5.9301 segundos
Total de imágenes clasificadas: 48 imágenes
```

Figura 5.3: *Tiempo de clasificación del modelo VGG19.*

Fuente: Elaboración propia.

5.3.3. Entrenamiento del modelo Inception-V3.

El modelo Inception-V3 alcanzó su mejor rendimiento en la época 41, con un tiempo total de entrenamiento de 806.56 segundos. Para el conjunto de prueba compuesto por 48 imágenes, el tiempo promedio de predicción por imagen fue de 0.2507 segundos, lo que resultó en un tiempo total de predicción de 12.0314 segundos. Estos resultados se detallan en la Figura 5.4, mostrando la eficiencia del modelo tanto en el proceso de entrenamiento como en la predicción, también presentamos las curvas de rendimiento en la Figura 5.7 y la matriz de confusión resumida en la Tabla 5.1.

```
[19]: rutas_test, plot_predicciones_test, plot_label_test = predict_all_images(test_imagenes_test, label_img_test, modelo_cargado)

1/1 [=====] - 0s 247ms/step
1/1 [=====] - 0s 238ms/step
1/1 [=====] - 0s 225ms/step
1/1 [=====] - 0s 240ms/step
1/1 [=====] - 0s 221ms/step
1/1 [=====] - 0s 206ms/step
1/1 [=====] - 0s 228ms/step
1/1 [=====] - 0s 244ms/step
1/1 [=====] - 0s 229ms/step
1/1 [=====] - 0s 203ms/step
1/1 [=====] - 0s 219ms/step
1/1 [=====] - 0s 209ms/step
1/1 [=====] - 0s 229ms/step
Tiempo promedio de predicción por imagen: 0.2507 segundos
Tiempo total de predicción: 12.0314 segundos
Tiempo total de para ceratitis: 6.1674 segundos
Tiempo total de para anastrepha: 5.8640 segundos
Total de imágenes clasificadas: 48 imágenes
```

Figura 5.4: *Tiempo de clasificación del modelo Inception-V3.*

Fuente: Elaboración propia.

Como se observa en las Figuras 5.5, 5.6, 5.7, las curvas de rendimiento para los modelos evaluados (VGG16, VGG19 e Inception V3) presentan el comportamiento de las métricas *Train Accuracy* y *Validation Accuracy* en las gráficas de la izquierda, mientras que *Train Loss* y *Validation Loss* se muestran en las gráficas de la derecha. Estas curvas son fundamentales para analizar el comportamiento de los modelos y evaluar su capacidad de generalización. De acuerdo con los resultados, no se evidencia la presencia de sobreajuste (*overfitting*) ni subajuste (*underfitting*), lo que valida la robustez del entrenamiento.

5.3.3.1. Análisis de las métricas de precisión para los 3 modelos (*Accuracy*)

- **Train Accuracy:** Las curvas de precisión de entrenamiento muestran que los modelos lograron aprender de manera efectiva los patrones de los datos de entrenamiento. Inicialmente, el porcentaje de aciertos comienza en valores bajos, como es esperado en las primeras épocas, pero a medida que avanza el entrenamiento, el modelo mejora progresivamente su desempeño. Este comportamiento refleja un aprendizaje consistente y efectivo, con un aumento sostenido de la precisión hasta estabilizarse en valores altos, lo que sugiere una correcta adaptación a los datos proporcionados.
- **Validation Accuracy:** En cuanto a la precisión de validación, se observa que el porcentaje de aciertos aumenta rápidamente durante las primeras épocas, superando

a la precisión de entrenamiento (*Train Accuracy*). Este comportamiento indica que el modelo logra generalizar bien desde etapas tempranas. Posteriormente, la curva de validación se estabiliza, manteniéndose ligeramente por encima de la curva de entrenamiento, lo que demuestra que los modelos no sufrieron sobreajuste. Al observar esta tendencia consistente y los altos valores obtenidos en la precisión de validación, se concluye que los modelos lograron identificar patrones en datos no vistos, mostrando una excelente capacidad de generalización.

5.3.3.2. Análisis de las métricas de pérdida para los 3 modelos (*Loss*)

- **Train Loss:** La pérdida de entrenamiento refleja cómo el modelo ajusta sus parámetros para minimizar los errores en los datos de entrenamiento. Inicialmente, los valores de pérdida son altos, debido a que el modelo no ha aprendido aún los patrones subyacentes en los datos. Sin embargo, a medida que avanza el entrenamiento, la curva muestra una disminución consistente, lo que indica que el modelo está mejorando en la minimización de los errores sobre los datos de entrenamiento.
- **Validation Loss:** La pérdida de validación sigue una tendencia similar a la de entrenamiento, comenzando con valores elevados y disminuyendo progresivamente. Lo relevante es que la curva de *Validation Loss* permanece cercana o incluso por debajo de la de *Train Loss* a lo largo del entrenamiento, lo que indica que el modelo no está memorizando los datos de entrenamiento (indicativo de sobreajuste). En su lugar, está generalizando correctamente, logrando buenos resultados en los datos de validación.

5.3.3.3. Conclusión de las curvas de rendimiento para los 3 modelos.

El análisis conjunto de estas métricas confirma que los modelos entrenados no presentan problemas de sobreajuste ni subajuste. Esto se evidencia en la estabilidad de las curvas de precisión y pérdida, donde:

- Las métricas de *Train Accuracy* y *Validation Accuracy* muestran mejoras sostenidas y valores altos, con la precisión de validación superando ligeramente la de entrenamiento.
- Las métricas de *Train Loss* y *Validation Loss* disminuyen de manera consistente, sin grandes discrepancias entre ambas curvas.

Estos resultados indican que los modelos lograron aprender patrones significativos de los datos de entrenamiento y generalizaron adecuadamente a datos no vistos, garantizando un desempeño robusto y confiable en tareas de clasificación.

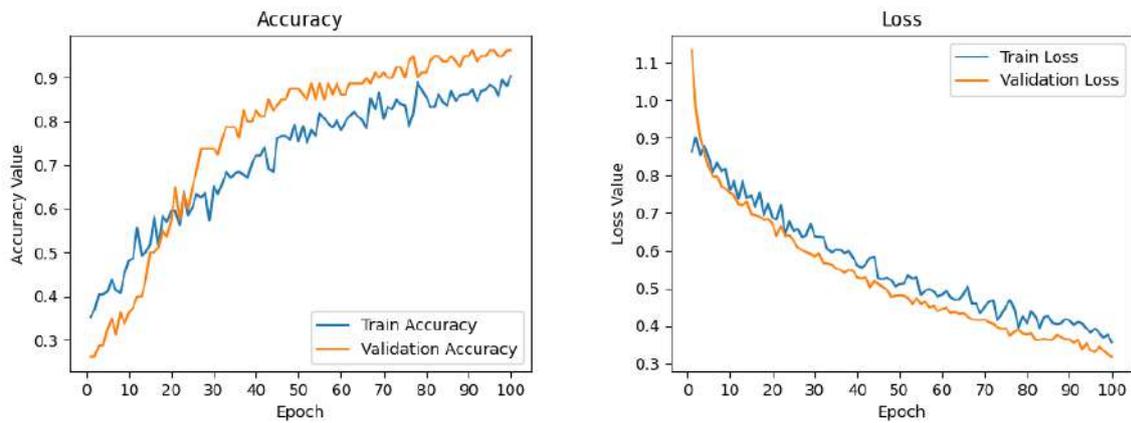


Figura 5.5: *Curvas de rendimiento del modelo VGG16.*

Fuente: Elaboración propia.

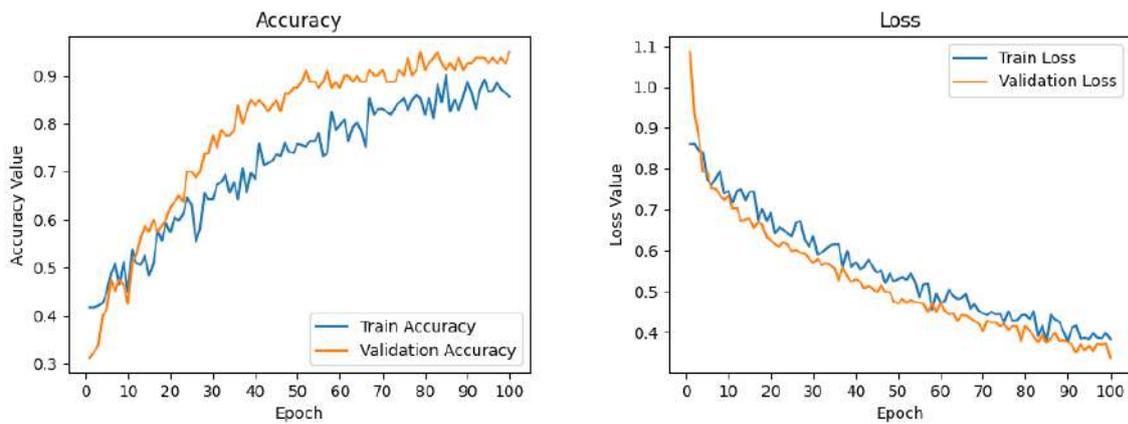


Figura 5.6: *Curvas de rendimiento del modelo VGG19.*

Fuente: Elaboración propia.

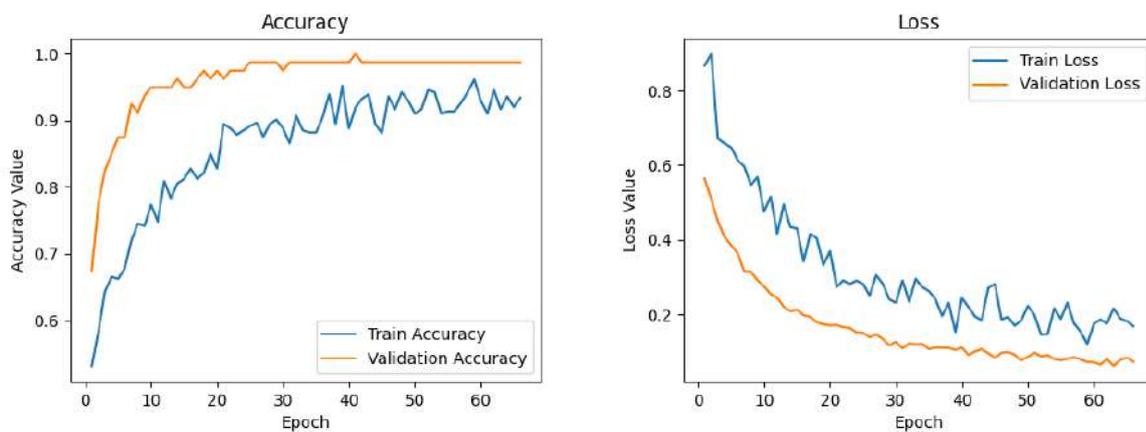


Figura 5.7: *Curvas de rendimiento del modelo Inception-V3.*

Fuente: Elaboración propia.

En la Tabla 5.1 se presenta un resumen de las matrices de confusión correspondientes a los tres modelos evaluados. Dichas matrices contienen los valores necesarios para el cálculo de las métricas que permitirán alcanzar los objetivos planteados en esta investigación. La matriz de confusión clasifica los resultados en casos positivos y negativos; en este estudio, se busca lograr una alta precisión en ambas clases. Por ello, se calculó una matriz de confusión para cada clase considerada como caso positivo, generando así dos matrices de confusión por modelo.

Cuadro 5.1: *Matriz de confusión resumida de los modelos. Verdaderos Positivos (TP), Falsos Positivos (FP), Falsos Negativos (FN) y Verdaderos Negativos (TN).*

MODELOS	TP	FN	FP	TN
VGG16 <i>A. fraterculus</i>	20	4	0	24
VGG16 <i>C. capitata</i>	24	0	4	20
VGG19 <i>A. fraterculus</i>	19	5	1	23
VGG19 <i>C. capitata</i>	23	1	5	19
Inception-v3 <i>A. fraterculus</i>	24	0	0	24
Inception-v3 <i>C. capitata</i>	24	0	0	24

Fuente: Elaboración propia.

5.4. Comparación de tiempos.

Uno de los objetivos clave en el uso de modelos de *machine learning* y *deep learning* es la reducción del tiempo necesario para llevar a cabo ciertos procesos, lo que permite a los expertos alcanzar sus metas de manera más rápida.

5.4.1. Toma de tiempos.

Durante el proceso de recolección de datos, se observó la considerable carga laboral de los expertos en laboratorio, así como la complejidad de su tarea. Debido a estas circunstancias, no fue posible realizar una medición directa del tiempo de clasificación en condiciones controladas, ya que se requirió otorgar al experto la libertad necesaria para desempeñar sus funciones sin la presión de concentrarse únicamente en la clasificación, lo que podría alterar sus decisiones. Por esta razón, se solicitó al experto proporcionar una estimación del tiempo promedio requerido para clasificar las muestras de las especies en estudio. Es importante destacar que el experto cuenta con tres años de experiencia en esta tarea, lo que aporta fiabilidad a su estimación. Según su reporte, el tiempo promedio de clasificación de las especies *Anastrepha fraterculus* y *Ceratitidis capitata* es de 10 segundos por muestra.

5.4.2. Comparación de Experto versus modelo.

Para evaluar el desempeño de los modelos desarrollados, se utilizaron 24 imágenes de moscas correspondientes a cada una de las especies objeto de estudio. Los resultados obtenidos se presentan en la Sección 5.3, donde se detallan los tiempos de clasificación para cada modelo.

Tiempo total de clasificación de *Anastrepha fraterculus* y *Ceratitis capitata* con el modelo VGG16.

$$\text{Tiempo para } \textit{Anastrepha fraterculus} = 5,3037 \text{ segundos} \quad (5.1)$$

$$\text{Tiempo para } \textit{Ceratitis capitata} = 6,4237 \text{ segundos} \quad (5.2)$$

$$\text{Tiempo total de clasificación} = 11,7275 \text{ segundos} \quad (5.3)$$

Tiempo total de clasificación de *Anastrepha fraterculus* y *Ceratitis capitata* con el modelo VGG19.

$$\text{Tiempo para } \textit{Anastrepha fraterculus} = 5,9301 \text{ segundos} \quad (5.4)$$

$$\text{Tiempo para } \textit{Ceratitis capitata} = 6,3103 \text{ segundos} \quad (5.5)$$

$$\text{Tiempo total de clasificación} = 12,2405 \text{ segundos} \quad (5.6)$$

Tiempo total de clasificación de *Anastrepha fraterculus* y *Ceratitis capitata* con el modelo Inception-V3.

$$\text{Tiempo para } \textit{Anastrepha fraterculus} = 5,8640 \text{ segundos} \quad (5.7)$$

$$\text{Tiempo para } \textit{Ceratitis capitata} = 6,1674 \text{ segundos} \quad (5.8)$$

$$\text{Tiempo total de clasificación} = 12,0314 \text{ segundos} \quad (5.9)$$

Utilizando las mismas 24 muestras para cada especie, previamente clasificadas por el experto, se asignaron los tiempos promedios indicados por este. Dado que el tiempo de clasificación por muestra para *Anastrepha fraterculus* y para *Ceratitis capitata* es de 10 segundos, calculamos el tiempo total de clasificación para cada especie.

Tiempo de clasificación de *Anastrepha fraterculus* por el experto

$$\text{Tiempo total } \textit{Anastrepha fraterculus} = 24 \times 10 = 240 \text{ segundos} \quad (5.10)$$

Tiempo de clasificación de *Ceratitis capitata* por el experto

$$\text{Tiempo total } \textit{Ceratitis capitata} = 24 \times 10 = 240 \text{ segundos} \quad (5.11)$$

Tiempo total de clasificación por el experto

El tiempo total de clasificación para ambas especies es la suma de los tiempos anteriores:

$$\text{Tiempo total} = 240 + 240 = 480 \text{ segundos} \quad (5.12)$$

Resumen de los resultados en la Tabla 5.2.

Cuadro 5.2: *Resumen de tiempo de los modelos y el experto en segundos.*

	Tiempo <i>Anastrepha fraterculus</i>	Tiempo <i>Ceratitis capitata</i>	Total
VGG16	5.3037	6.4237	11.7275
VGG19	5.9301	6.3103	12.2405
Inception-v3	5.8640	6.1674	12.0314
Experto	240	240	480

Fuente: Elaboración propia.

Es importante destacar que la comparación de tiempos se refiere únicamente al proceso de clasificación de las especies. Cabe mencionar que existen etapas previas, como las realizadas por el experto y el preprocesamiento de las imágenes, necesarias para que estas puedan ser clasificadas por el modelo. Sin embargo, los tiempos correspondientes a estas etapas no han sido considerados en la comparación.

Capítulo 6

Discusión.

En esta sección, se analizan los resultados obtenidos a partir de los experimentos realizados en la etapa de segmentación y con los modelos VGG16, VGG19 e Inception V3 para la clasificación de las especies *Anastrepha fraterculus* y *Ceratitis capitata*.

6.1. Segmentación.

Durante la etapa de segmentación, se observó que una parte considerable de las imágenes del conjunto de datos se vio afectada por varios factores externos relacionados con las condiciones en que fueron tomadas. Esto resultó en una reducción de las imágenes originales, reduciendo el número de muestras por clase de 286 a 236. Esta disminución del conjunto de datos se debió principalmente a problemas en la calidad de las imágenes capturadas.

Entre los factores que contribuyeron a la pérdida de imágenes se destacan el brillo, el contraste y la iluminación, que son fundamentales para la correcta segmentación del conjunto de datos que construimos de las especies *Anastrepha fraterculus* y *Ceratitis capitata*. Las imágenes capturadas manualmente con un dispositivo móvil, aunque permiten la obtención rápida y la facilidad de almacenamiento de datos, introdujeron variabilidad no controlada en estos parámetros. Esto dificulta la generalización de un algoritmo de segmentación preciso, ya que un modelo entrenado bajo estas condiciones puede no responder bien a nuevas imágenes con características similares.

6.2. Resultados.

En el contexto de nuestra investigación, la tarea de clasificación no se ajusta a los paradigmas comunes de clasificación binaria. En lugar de clasificar en términos de normales versus anormales, nuestro objetivo es distinguir entre dos clases específicas:

Anastrepha fraterculus y *Ceratitis capitata*. Esta diferenciación requiere un análisis exhaustivo de las métricas de rendimiento del clasificador para cada clase individualmente.

Dado que ambas especies son igualmente importantes para la investigación, es crucial evaluar el desempeño del modelo con precisión. Las métricas tradicionales como precisión y recall son fundamentales, pero no son suficientes por sí solas para una evaluación completa. En nuestro caso, es esencial considerar una métrica que integre la reducción de la tasa de falsos positivos y falsos negativos en una sola medida. Esto garantiza que la clasificación de ambas especies sea manejada con igual rigor y precisión, reflejando el meticuloso trabajo realizado por los especialistas del laboratorio de SENASA en la identificación de características morfológicas.

La reducción de la tasa de falsos positivos y falsos negativos es crucial para minimizar errores de clasificación, lo que impacta directamente en la precisión de los informes sobre el volumen poblacional de cada especie en distintas áreas. La integridad de estos informes es fundamental para evitar análisis erróneos que podrían influir negativamente en las decisiones basadas en los datos.

Para cumplir con los requisitos de este análisis, se empleará el f1-score, una métrica que ofrece un equilibrio entre la precisión y el recall, al combinar ambas mediante la media armónica. Esta métrica es especialmente útil en escenarios donde se necesita minimizar tanto los falsos positivos como los falsos negativos. Además, para generalizar los resultados y obtener una visión integral del rendimiento de los modelos, aplicaremos el enfoque de “macro average”. Este enfoque, según la documentación de [Scikitlearn \(s.f.\)](#), calcula la media de las métricas individuales de cada clase, asignando el mismo peso a cada una. De este modo, se logra una evaluación equilibrada del desempeño global del modelo, independientemente del desequilibrio en la distribución de clases. Los resultados detallados se presentan en las tablas 6.1, 6.2, 6.3.

Cuadro 6.1: *Métricas del modelo VGG16.*

	Precisión	Recall	F1-score
<i>Anastrepha fraterculus</i>	1.00	0.83	0.91
<i>Ceratitis capitata</i>	0.86	1.00	0.92
Promedio macro	0.93	0.92	0.92

Fuente: Elaboración propia.

Cuadro 6.2: *Métricas del modelo VGG19.*

	Precisión	Recall	F1-score
<i>Anastrepha fraterculus</i>	0.95	0.79	0.86
<i>Ceratitis capitata</i>	0.82	0.96	0.88
Promedio macro	0.89	0.88	0.87

Fuente: Elaboración propia.

Cuadro 6.3: Métricas del modelo Inception-V3.

	Precisión	Recall	F1-score
<i>Anastrepha fraterculus</i>	1.00	1.00	1.00
<i>Ceratitis capitata</i>	1.00	1.00	1.00
Promedio macro	1.00	1.00	1.00

Fuente: Elaboración propia.

6.3. Representación de los patrones que utilizan los modelos.

Al analizar los resultados de los tres modelos, observamos un rendimiento satisfactorio en la clasificación de las dos especies objetivo. Sin embargo, como mencionamos en la Sección 4.1.2, nuestros modelos deben ser capaces de identificar un conjunto específico de características morfológicas propias de cada especie.

Para profundizar en la interpretación de las decisiones del modelo, empleamos la técnica Grad-CAM, que nos permite visualizar las áreas de atención del modelo en cada imagen y comprender qué aspectos morfológicos son relevantes para la asignación a una clase. Para ilustrar esta técnica, utilizamos una imagen representativa de cada especie sacada de nuestro conjunto de datos de prueba. En la Figura 6.1 podemos observar estas imágenes representativas donde resaltamos en círculos de color negro las características morfológicas presentes.



Figura 6.1: Imágenes del conjunto de prueba con características resaltadas, *Anastrepha fraterculus* (izquierda) y *Ceratitis capitata* (derecha).

Fuente: Elaboración propia.

6.3.1. Grad-Cam.

Utilizando las imágenes del conjunto de prueba mostradas en la Figura 6.1, realizamos las predicciones correspondientes con cada uno de los modelos entrenados. Posteriormente, aplicamos la técnica Grad-CAM¹ para obtener una representación visual de las áreas de atención del modelo durante el proceso de clasificación. Los resultados de estas representaciones se pueden observar en las Figuras 6.2, 6.3, 6.4.

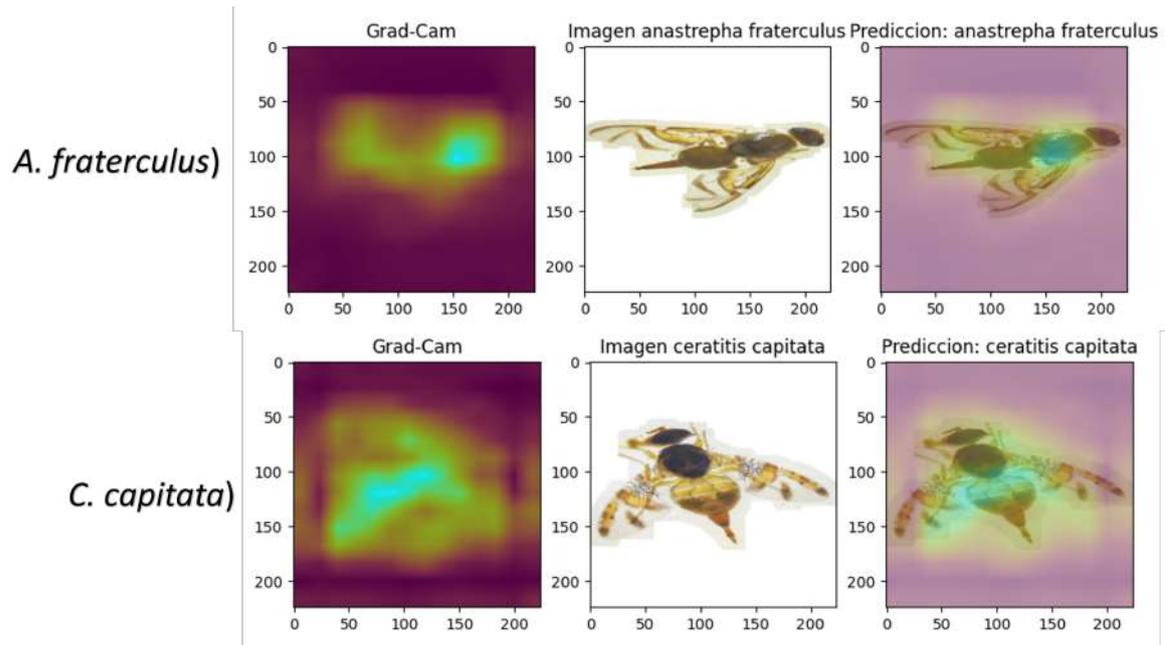


Figura 6.2: Predicción y representación con Grad-Cam del modelo VGG16.

Fuente: Elaboración propia.

En la figura 6.2 correspondiente al Grad-CAM de la especie *A. fraterculus* en la tercera imagen, se observa que el modelo resalta como área principal de interés el tórax, identificándolo con mayor intensidad. Asimismo, también considera una parte del ala izquierda, aunque esta región presenta una intensidad menor en comparación con el tórax.

Por otro lado, en el Grad-CAM de la especie *C. capitata* en la tercera imagen, se destaca que el modelo concentra su atención principalmente en una sección del ala izquierda y en la parte inferior del tórax, las cuales muestran las mayores intensidades. Además, otras regiones, como el abdomen, una pequeña porción del tórax superior y el ala derecha, son consideradas, pero con intensidades notablemente menores.

¹En los resultados, se observan áreas resaltadas con distintas intensidades, las cuales son utilizadas para la clasificación de los modelos. Esto sugiere que, aunque todas las áreas resaltadas contribuyen al proceso de clasificación, las regiones con mayor intensidad tienen un papel más determinante en la clasificación.

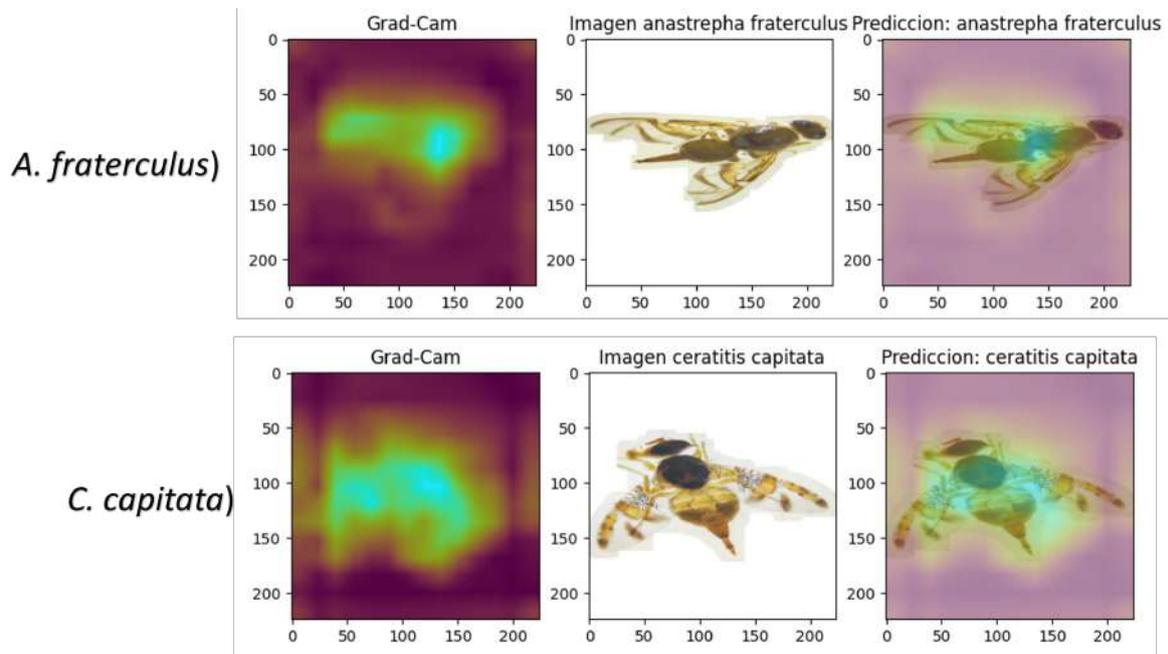


Figura 6.3: *Predicción y representación con Grad-Cam del modelo VGG19.*

Fuente: Elaboración propia.

En la figura 6.3 correspondiente al Grad-CAM de la especie *A. fraterculus* en la tercera imagen, se observa que el modelo identifica como área principal de interés para la clasificación la parte inferior del tórax, destacándola con mayor intensidad. Asimismo, el modelo considera una parte del ala izquierda, aunque con una menor intensidad².

Por otro lado, en el Grad-CAM de la especie *C. capitata* en la tercera imagen, se observa que el modelo enfoca su atención principalmente en una sección del ala derecha, el tórax y una porción del ala izquierda, siendo estas las áreas con mayor intensidad. Adicionalmente, considera otra región, como el abdomen, aunque con menor relevancia.

²Aunque este patrón se repite, al igual que en el modelo VGG16, es importante señalar que el modelo VGG19 resalta el área del ala izquierda con una intensidad mayor.

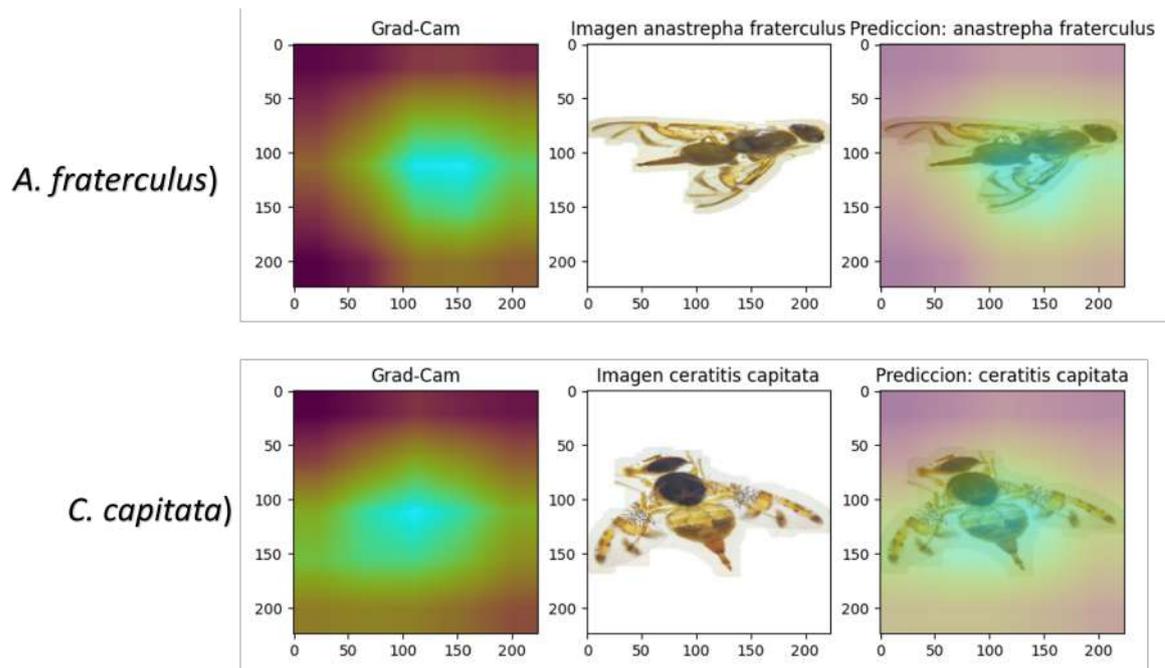


Figura 6.4: *Predicción y representación con Grad-Cam del modelo Inception-V3.*

Fuente: Elaboración propia.

En la figura 6.4 correspondiente al Grad-CAM de la especie *A. fraterculus* en la tercera imagen, se observa que el modelo identifica como áreas principales de interés para la clasificación el ala derecha completa, el tórax, el abdomen y la mitad superior del ala izquierda, destacándolas con mayor intensidad. Asimismo, el modelo considera la cabeza, aunque esta región presenta una menor intensidad.

Por otro lado, en el Grad-CAM de la especie *C. capitata* en la tercera imagen, se observa que el modelo enfoca su atención principalmente en ambas alas, el tórax y el abdomen, que son las áreas con mayor intensidad. Adicionalmente, considera la cabeza, aunque con menor relevancia en términos de intensidad.

En los resultados del Grad-CAM se puede observar que algunos modelos consideran regiones como el abdomen y la cabeza de la mosca. Aunque estas áreas no representan atributos clave según los objetivos de esta investigación, su inclusión en el análisis sugiere que el modelo las percibe como relevantes en casos específicos del conjunto de pruebas.

Es importante destacar que, mientras los modelos VGG16 y VGG19 tienden a utilizar áreas no conectadas y con intensidades dispares que pueden encontrarse en diferentes regiones de la mosca, el modelo Inception-V3 emplea áreas continuas que surgen desde una región con mayor intensidad. Además, abarca una mayor área de interés, generalizando de manera más efectiva las regiones clave para la clasificación de las especies. Esto también se refleja en los niveles de confianza en las clasificaciones de cada modelo, los cuales se resumen en la Tabla 6.4.

Cuadro 6.4: Niveles de confianza de los modelos en la clasificación de las imágenes de la Figura 6.1

Modelo	Confianza en <i>A. fraterculus</i>	Confianza en <i>C. capitata</i>
VGG16	72.77 %	84.66 %
VGG19	64.78 %	69.31 %
Inception-V3	93.09 %	98.18 %

Fuente: Elaboración propia.

6.4. Selección del mejor modelo.

El proceso de selección del mejor modelo se basó en una evaluación de varios criterios, incluyendo el tiempo de clasificación y las métricas de rendimiento, buscando equilibrar eficiencia y precisión en la tarea de clasificación de las muestras.

6.4.1. Evaluación del Tiempo de Clasificación.

Al comparar los tiempos de clasificación entre los modelos y el experto humano, el modelo VGG16 demostró ser el más eficiente, con un tiempo total de 11.73 segundos para clasificar las 48 muestras. Inception-V3 y VGG19 registraron tiempos ligeramente mayores, con 12.03 y 12.24 segundos, respectivamente. En contraste, el experto necesitó 480 segundos para completar la misma tarea.

Estos resultados destacan a VGG16 como el modelo más eficiente en términos de velocidad de clasificación, superando tanto a los otros modelos como al experto humano.

6.4.2. Evaluación de Métricas de Rendimiento.

En cuanto a las métricas de clasificación, el modelo Inception-V3 se destacó al alcanzar un F1-score del 100 %, lo que refleja un rendimiento sobresaliente en la identificación precisa de las muestras. Por otro lado, los modelos VGG16 y VGG19 lograron F1-scores de 92 % y 87 %, respectivamente, posicionando a VGG16 como el segundo mejor modelo en términos de precisión.

Dado que la tarea requiere un alto nivel de precisión para minimizar errores en la clasificación, se decidió priorizar las métricas de rendimiento en la selección del modelo final. Inception-V3, al alcanzar un F1-score perfecto, demostró una capacidad superior para aprender y generalizar las características morfológicas de las especies estudiadas, convirtiéndose en la mejor opción para este proyecto.

6.4.3. Evaluación mediante Grad-CAM.

En la sección 6.3 se describen los resultados obtenidos de los tres modelos a través de representaciones gráficas que muestran las áreas de interés que los modelos utilizan en las imágenes para realizar sus predicciones. En esa sección, analizamos las representaciones generadas con Grad-CAM para muestras donde los tres modelos realizaron predicciones correctas. Sin embargo, para validar de manera más exhaustiva la selección de un modelo utilizando la técnica Grad-CAM, es necesario examinar los casos en los que las predicciones no fueron correctas, con el fin de identificar posibles diferencias en la atención visual de cada modelo.

Aunque el modelo Inception-V3 alcanzó un 100% de precisión en sus predicciones, lo que inicialmente lo posiciona como el modelo superior, se hace fundamental comprender qué lo diferencia de los otros dos modelos, VGG16 y VGG19, al momento de hacer estas predicciones acertadas. Estas diferencias serán visualizadas en las imágenes 6.5 y 6.6, donde se representan las áreas de atención de cada modelo durante el proceso de clasificación.

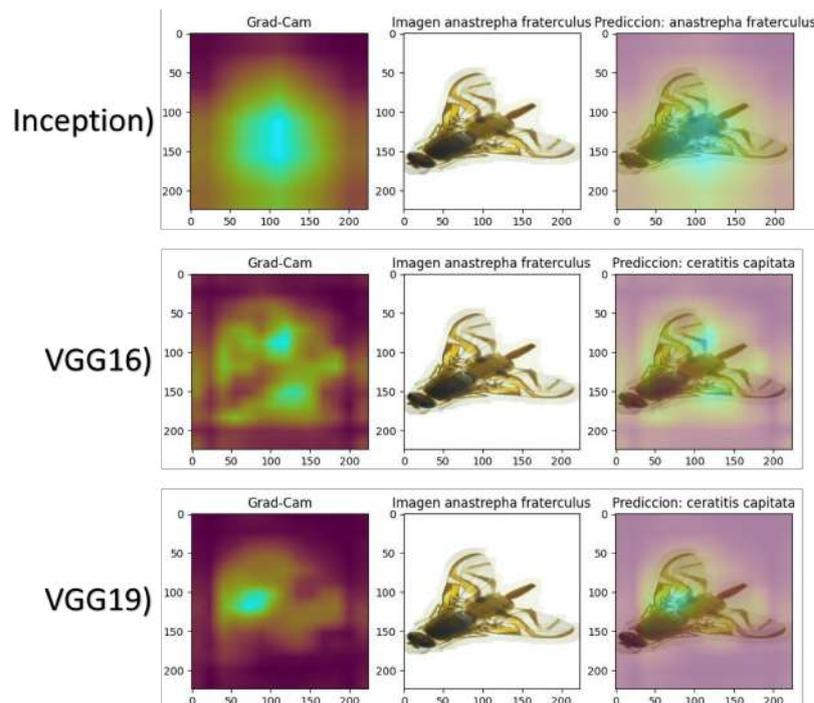


Figura 6.5: *Grad-Cam para la especie Anastrepha fraterculus.*

Fuente: Elaboración propia.

Al analizar los resultados de la clasificación y las representaciones de Grad-CAM mostradas en a Figura 6.5 para la especie *Anastrepha fraterculus*, en el caso del modelo VGG16 (tercera imagen), se observa que el modelo destaca regiones de las alas que no son relevantes para la clasificación de esta especie, siendo estas áreas las de mayor intensidad. En cambio, las áreas con menor intensidad no aportan información significativa para la clasificación.

En el modelo VGG19 (tercera imagen), se observa que el modelo identifica una región de alta intensidad que no corresponde a características relevantes de esta especie, lo que genera una clasificación errónea. Aunque las áreas de menor intensidad incluyen regiones de interés, el enfoque en la región incorrecta de mayor intensidad afecta negativamente la precisión de la clasificación.

Por otro lado, en el modelo Inception-V3 (tercera imagen), las áreas de mayor intensidad corresponden principalmente al tórax, abdomen y alas. Además, las áreas de menor intensidad abarcan el borde de la mosca, particularmente en las regiones de las alas y el tórax, lo que sugiere una distribución más coherente y precisa de las áreas de interés para la clasificación.

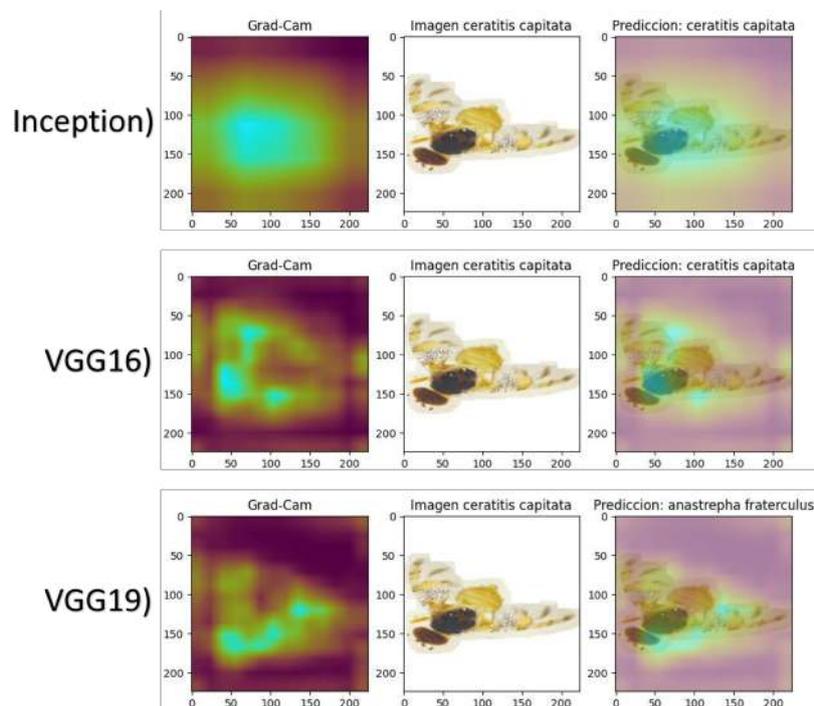


Figura 6.6: *Grad-Cam para la especie Ceratitis capitata.*

Fuente: Elaboración propia.

Al analizar los resultados de la clasificación y las representaciones Grad-CAM mostradas en la Figura 6.6 para la especie *Ceratitis capitata*, en el caso del modelo VGG16 (tercera imagen), se observa que el modelo destaca principalmente la región del tórax, junto con áreas de las alas que no son relevantes para la clasificación de esta especie. Estas regiones, que presentan la mayor intensidad en la representación Grad-CAM, incluyen también partes del fondo. Aunque el modelo utiliza patrones no relevantes para la clasificación, logró predecir correctamente la especie. Es importante señalar que las áreas de mayor intensidad influyeron en esta decisión, ya que algunas de ellas incluyen regiones con características morfológicas relevantes.

En el modelo VGG19 (tercera imagen), se observa que el modelo identifica una región de alta intensidad que abarca parcialmente el tórax, pero también incluye áreas fuera de la mosca, específicamente una porción del fondo. Adicionalmente, resalta una parte del ala que no corresponde a características morfológicas relevantes para esta

especie. Aunque existen áreas de menor intensidad que sí incluyen regiones con características morfológicas relevantes, el modelo no realizó una predicción correcta debido a la inclusión de regiones no relevantes en la áreas de mayor intensidad.

Por otro lado, en el modelo Inception-V3 (tercera imagen), presenta áreas de mayor intensidad que corresponden principalmente al tórax, abdomen, alas y, en menor medida, la cabeza. Estas áreas de interés abarcan características morfológicas relevantes para la especie. Además, las áreas de menor intensidad también incluyen regiones con características morfológicas relevantes, lo que refuerza la decisión del modelo.

Aunque tanto Inception-V3 como VGG16 realizaron una predicción correcta para la especie *C. capitata*, se observa que VGG16 resalta como áreas de mayor intensidad zonas fuera de la mosca, así como partes del ala que no son características morfológicas de esta especie. En cambio, Inception-V3 abarca una mayor proporción del área de interés, lo que le permite realizar una clasificación más precisa. Esta diferencia se refleja en los niveles de confianza de las predicciones, con VGG16 registrando un 66.47 % e Inception-V3 alcanzando un valor significativamente superior de 95.28 %.

Dado que el objetivo de este trabajo es desarrollar un modelo que sea capaz de replicar los criterios de un experto en la clasificación de especies, consideramos a Inception-V3 como el mejor modelo. Las áreas que este modelo identifica como relevantes para sus predicciones coinciden con las características morfológicas que los expertos utilizan para diferenciar una especie de otra, lo que confirma su idoneidad para esta tarea.

6.4.4. Evaluación en Escenarios No Controlados.

A pesar de que uno de los modelos alcanzó una precisión del 100 % en el conjunto de datos original, surgieron dudas sobre la capacidad de este resultado para generalizar a nuevos escenarios. Es poco común obtener una precisión perfecta en tareas complejas como la clasificación de especies, lo que motivó la realización de pruebas adicionales para validar su robustez.

6.4.4.1. Pruebas con Datos Descartados.

Como se menciona en la sección 6.1 el conjunto de datos inicial se redujo de 286 a 236 imágenes, descartando 50 imágenes para cada especie en estudio. De este modo, se obtuvo un nuevo conjunto de 100 imágenes que no fueron utilizadas durante el entrenamiento de los modelos.

Para evaluar la robustez y la capacidad de generalización de nuestros modelos, utilizamos este conjunto de datos descartados. Construimos dos conjuntos adicionales a partir de estas 100 imágenes: uno con imágenes sin preprocesar y otro con imágenes preprocesadas. Estas pruebas permitieron examinar cómo se comporta el modelo frente

a datos que no fueron parte del proceso de entrenamiento, y bajo condiciones que podrían estar más cercanas a escenarios reales o no controlados.

Resultados con los Datos sin Preprocesar. Los resultados obtenidos utilizando los datos sin preprocesar se resumen en las tablas 6.5, 6.6 y 6.7, donde se presenta de manera detallada la información clave de las evaluaciones realizadas.

Cuadro 6.5: *Resultados del modelo VGG16.*

	Precisión	Recall	F1-score
<i>Anastrepha fraterculus</i>	1.00	0.08	0.15
<i>Ceratitis capitata</i>	0.52	1.00	0.68
Promedio macro	0.76	0.54	0.42

Fuente: Elaboración propia.

Cuadro 6.6: *Resultados del modelo VGG19.*

	Precisión	Recall	F1-score
<i>Anastrepha fraterculus</i>	1.00	0.06	0.11
<i>Ceratitis capitata</i>	0.52	1.00	0.68
Promedio macro	0.75	0.53	0.40

Fuente: Elaboración propia.

Cuadro 6.7: *Resultados del modelo Inception V3.*

	Precisión	Recall	F1-score
<i>Anastrepha fraterculus</i>	0.95	0.78	0.86
<i>Ceratitis capitata</i>	0.81	0.96	0.88
Promedio macro	0.88	0.87	0.87

Fuente: Elaboración propia.

Resultados con los Datos Preprocesados. Los resultados obtenidos utilizando los datos preprocesados se encuentran resumidos en las tablas 6.8, 6.9 y 6.10, donde se detalla la información relevante de las evaluaciones realizadas.

Cuadro 6.8: Resultados del modelo VGG16.

	Precisión	Recall	F1-score
<i>Anastrepha fraterculus</i>	0.94	0.63	0.76
<i>Ceratitis capitata</i>	0.73	0.96	0.83
Promedio macro	0.83	0.80	0.79

Fuente: Elaboración propia.

Cuadro 6.9: Resultados del modelo VGG19.

	Precisión	Recall	F1-score
<i>Anastrepha fraterculus</i>	0.92	0.69	0.79
<i>Ceratitis capitata</i>	0.75	0.94	0.83
Promedio macro	0.83	0.82	0.81

Fuente: Elaboración propia.

Cuadro 6.10: Resultados del modelo Inception V3.

	Precisión	Recall	F1-score
<i>Anastrepha fraterculus</i>	0.93	0.88	0.91
<i>Ceratitis capitata</i>	0.87	0.94	0.91
Promedio macro	0.91	0.91	0.91

Fuente: Elaboración propia.

6.4.4.2. Pruebas con Datos Obtenidos de Internet.

Para realizar una evaluación más exhaustiva de la robustez del modelo, se empleó un conjunto de datos adicional compuesto por 36 imágenes recopiladas de diversas fuentes en internet. Estas imágenes correspondían a las dos especies objeto de estudio en esta investigación y fueron seleccionadas manualmente para representar escenarios de la vida real. En particular, se incluyeron imágenes de moscas de la fruta posadas sobre frutos, sobre telas, y algunas con fondos de color uniforme. El conjunto se conformó por 18 imágenes de cada clase, lo que permitió someter los modelos a condiciones representativas del mundo real³, donde la calidad y las características visuales de las imágenes pueden diferir considerablemente de aquellas utilizadas durante el entrenamiento. Los resultados de esta evaluación se detallan en las Tablas 6.11, 6.12 y 6.13, que presentan un análisis completo de los datos obtenidos.

Cuadro 6.11: *Resultados del modelo VGG16.*

	Precisión	Recall	F1-score
<i>Anastrepha fraterculus</i>	0.4	0.11	0.17
<i>Ceratitis capitata</i>	0.48	0.83	0.61
Promedio macro	0.44	0.47	0.39

Fuente: Elaboración propia.

Cuadro 6.12: *Resultados del modelo VGG19.*

	Precisión	Recall	F1-score
<i>Anastrepha fraterculus</i>	-	0	-
<i>Ceratitis capitata</i>	0.5	1.00	0.67
Promedio macro	-	0.5	-

Fuente: Elaboración propia.

Cuadro 6.13: *Resultados del modelo Inception V3.*

	Precisión	Recall	F1-score
<i>Anastrepha fraterculus</i>	0.73	0.61	0.67
<i>Ceratitis capitata</i>	0.67	0.78	0.72
Promedio macro	0.7	0.69	0.69

Fuente: Elaboración propia.

Los resultados indican que el modelo que demuestra un rendimiento superior en conjuntos de datos con circunstancias no controladas es Inception V3. Este modelo

³El conjunto de datos original fue recopilado en un entorno de laboratorio con condiciones homogéneas para todas las imágenes. En contraste, las imágenes obtenidas de internet introducen variabilidad en las condiciones de captura, lo que permite evaluar el desempeño de los modelos en escenarios reales fuera del laboratorio.

alcanzó un F1-score del 87 % para los datos descartados sin preprocesar y un 91 % para los datos descartados preprocesados. Estas cifras evidencian que Inception V3 presenta características que destacan su robustez y eficacia, incluso en situaciones donde el preprocesamiento de algunas imágenes resultó deficiente. Para validar aún más su desempeño, sometimos Inception V3 a pruebas utilizando un conjunto de datos obtenido de internet, donde los resultados siguieron siendo positivos, alcanzando un F1-score del 69 %. Este hallazgo refuerza la solidez del modelo en escenarios menos controlados.

La capacidad del modelo para mantener una precisión del 87 % al 91 % en datos previamente descartados y preprocesados respalda su robustez, dado que estos datos presentaban desafíos en la segmentación que no se encontraban en el conjunto original. Aunque el rendimiento disminuyó al 69 % en las imágenes obtenidas de internet, este descenso puede atribuirse a variaciones en la calidad, formato y contexto de las imágenes, lo que sugiere que el modelo sigue siendo un clasificador competente para las condiciones específicas de nuestro experimento.

La combinación de resultados sólidos en pruebas rigurosas, un tiempo de clasificación eficiente para las especies, y su excelente desempeño en el conjunto original, complementada por una representación más clara de las áreas morfológicas de interés mediante la técnica Grad-Cam, valida la elección de Inception V3 para nuestra investigación, asegurando tanto precisión como consistencia en sus predicciones.

Capítulo 7

Conclusiones.

7.1. Conclusiones.

En relación con el primer objetivo específico: Se logró construir un conjunto de datos robusto para la clasificación de las especies *Anastrepha fraterculus* y *Ceratitis capitata*. La selección de las muestras fue realizada meticulosamente por un experto en el área, quien aseguró la representación adecuada de cada especie. Las imágenes fueron capturadas utilizando un estereomicroscopio y un teléfono móvil, lo que permitió una alta resolución y detalle en las fotografías. Inicialmente, el conjunto de datos constaba de 286 imágenes por clase. Sin embargo, debido a variaciones en la calidad de las imágenes causadas por factores como iluminación y enfoque durante la captura manual, se redujo a 231 imágenes por clase. A pesar de esta reducción, el conjunto sigue siendo representativo y adecuado para el entrenamiento y evaluación de los modelos de clasificación.

En relación con el segundo objetivo específico: Para evaluar la eficacia en la reducción del tiempo de clasificación, se comparó el rendimiento de los modelos con el tiempo promedio de clasificación manual realizado por un experto en laboratorio. El tiempo estimado de clasificación manual para las 48 imágenes del conjunto de prueba, considerando que por muestra de *Anastrepha fraterculus* y por muestra de *Ceratitis capitata*, fue de 480 segundos en total. En contraste, el modelo VGG16 alcanzó un tiempo promedio de predicción de 5.3037 segundos por muestra de *Anastrepha fraterculus* y 6.4237 segundos por muestra de *Ceratitis capitata*, con un tiempo total de 11.7275 segundos para clasificar el mismo conjunto de imágenes.

No obstante, el modelo seleccionado para esta investigación fue Inception-V3, que logró un tiempo de 5.8640 segundos para muestras de *Anastrepha fraterculus* y 6.3103 segundos para muestras de *Ceratitis capitata*, resultando en un tiempo total de 12.0314 segundos, el segundo mejor tiempo entre los modelos evaluados y el experto. La elección de Inception-V3 sobre VGG16 se fundamentó no solo en los resultados obtenidos

mediante la técnica Grad-CAM y las pruebas realizadas con datos no controlados, sino también en su buen desempeño tanto en tiempo como en precisión en comparación con el experto.

Este notable contraste en los tiempos de procesamiento evidencia el éxito en la optimización del tiempo de clasificación, cumpliendo así el objetivo específico de reducir significativamente el tiempo requerido para la identificación de las especies de mosca de la fruta. La capacidad del modelo para manejar grandes volúmenes de datos con alta eficiencia subraya la efectividad de la técnica de transferencia de aprendizaje aplicada y demuestra una mejora sustancial en la velocidad de clasificación en comparación con métodos manuales tradicionales.

En relación con el tercer objetivo específico: Se identificó un modelo con un rendimiento excepcional, logrando un F1-score del 100 % en el conjunto de datos original. Este resultado es notable, ya que el F1-score combina tanto la precisión como el recall, lo que minimiza tanto los falsos positivos como los falsos negativos. Para asegurar la robustez del modelo, se realizaron pruebas adicionales con datos previamente descartados, obteniendo un F1-score de 87 % para datos sin preprocesar y un 91 % para datos procesados, y con un conjunto de imágenes extraídas al azar de internet, donde se alcanzó un 69 % de precisión.

Además del F1-score perfecto, el modelo Inception-V3 mostró un rendimiento eficiente en términos de tiempo, clasificando las 48 muestras en 12.0314 segundos, en comparación con los 480 segundos que le tomaría al experto humano realizar la misma tarea manualmente. Aunque el modelo VGG16 presentó un tiempo ligeramente menor de 11.7275 segundos, Inception-V3 fue elegido por su superioridad en métricas de precisión.

Finalmente, la técnica Grad-CAM permitió visualizar las áreas de interés consideradas por el modelo durante la clasificación, mostrando que Inception-V3 analiza una mayor cantidad de áreas relevantes en comparación con los otros modelos evaluados, consolidando así su capacidad para generalizar las características morfológicas clave de las especies en estudio.

Este notable resultado del 100 % en la métrica F1-score para el modelo Inception-V3 demuestra el éxito en la búsqueda de un modelo capaz de mitigar los factores humanos que afectan la toma de decisiones en la clasificación de las especies de mosca de la fruta. La capacidad del modelo para realizar clasificaciones rápidas basadas en un entrenamiento previo con imágenes ya clasificadas indica que puede ser una herramienta eficaz para reducir la influencia de la fatiga, distracciones y subjetividad en el proceso de identificación. Este enfoque no solo respalda el trabajo de los expertos en sus tareas de clasificación, sino que también ofrece una solución robusta y confiable en la identificación de estas especies.

En relación con el objetivo general: El cumplimiento de los objetivos específicos ha permitido alcanzar el objetivo general de esta investigación: implementar un modelo de visión computacional basado en transferencia de aprendizaje para la identificación y clasificación de las especies *Anastrepha fraterculus* y *Ceratitis capitata*. El modelo seleccionado, Inception-V3, no solo exhibe una alta precisión con un F1-score perfecto, sino que también emula eficazmente la labor de los especialistas en la identificación de características morfológicas clave.

En términos de eficiencia, Inception-V3 clasificó 48 muestras en un tiempo total de 12.0314 segundos, en comparación con los 480 segundos requeridos para la clasificación manual por un experto.

Además, la técnica Grad-CAM ha sido fundamental para comprender las áreas de interés del modelo, lo que respalda su potencial como una herramienta confiable que sirva de apoyo a los especialistas en el control de plagas, facilitando una identificación más rápida y precisa de las especies objetivo.

7.2. Recomendaciones.

Fotografías de las muestras: La variabilidad en las tomas fotográficas afectó significativamente la segmentación de las imágenes, lo que impactó el rendimiento de los modelos VGG16, VGG19 e Inception V3. Estos modelos requieren imágenes claras y homogéneas para aprender características discriminativas de manera efectiva. Las inconsistencias en las condiciones de captura, como brillo y enfoque, pueden reducir la capacidad de los modelos para generalizar y aumentar el riesgo de sobreajuste, resultando en un rendimiento subóptimo en imágenes nuevas.

Para mejorar la calidad de las imágenes y la segmentación, es crucial adoptar un enfoque más controlado durante la captura. Una solución eficaz sería utilizar un mecanismo que estabilice el teléfono móvil frente al ocular del estereomicroscopio o, idealmente, emplear un estereomicroscopio con una cámara integrada. Este enfoque garantizaría una mayor consistencia en las condiciones de captura, reduciendo la variabilidad y mejorando la calidad general del conjunto de datos. Además, aunque la reducción fue de 50 imágenes por cada clase, la aplicación de técnicas de preprocesamiento y aumento de datos demostró ser fundamental para mitigar el impacto y mejorar la robustez de los modelos.

Algoritmos de Segmentación: La segmentación efectiva es crucial para enfocar los modelos de clasificación en las áreas relevantes de las imágenes. En nuestra investigación, se implementó inicialmente un algoritmo de segmentación que, al evaluar los resultados con Grad-CAM, mostró que no lograba identificar adecuadamente las áreas de interés para la clasificación de las especies *Anastrepha fraterculus* y *Ceratitis capitata*. Esta deficiencia llevó a la implementación de un segundo algoritmo de segmentación, que permitió una mejora significativa en el rendimiento de los modelos. El nuevo al-

goritmo optimizó la extracción de características relevantes y mejoró la precisión en la clasificación, evidenciado por los resultados más consistentes y fiables en las pruebas.

Catidad de datos: Para mejorar la generalización y robustez del modelo, es fundamental contar con un conjunto de datos amplio y variado. La variabilidad en las condiciones de captura, como iluminación, brillo y contraste, afecta la calidad y utilidad de las imágenes. A pesar de que las técnicas de aumento de datos ayudan a mitigar estos problemas, la obtención de un mayor número de imágenes en condiciones controladas permitiría mejorar la representatividad del conjunto de datos. Esto facilitaría la construcción de modelos más robustos y generalizables, no solo para las especies *Anastrepha fraterculus* y *Ceratitis capitata*, sino también para una gama más amplia de especies. La incorporación de imágenes más orgánicas y variadas del mundo real, obtenidas bajo condiciones uniformes, contribuiría a una mejor representación de las características morfológicas y mejoraría el rendimiento del modelo en entornos prácticos.

Uso de Técnicas Avanzadas de Aumento de Datos: El aumento de datos es esencial para mejorar la robustez del modelo. Además de las técnicas utilizadas, como la rotación y el cambio de escala, se podrían explorar técnicas avanzadas como el recorte aleatorio, la deformación elástica y la síntesis de imágenes para generar un conjunto de datos más diverso. Estas técnicas pueden ayudar a simular una mayor variabilidad en las imágenes, mejorando así la capacidad del modelo para generalizar.

Colaboración con Especialistas en Entomología: Dado que el conocimiento experto es crucial en la identificación de características morfológicas específicas, colaborar estrechamente con entomólogos puede proporcionar valiosos insights y ayudar a validar los resultados del modelo. La retroalimentación de especialistas en el campo puede guiar la mejora continua del modelo y asegurar que las características relevantes sean correctamente identificadas y clasificadas.

Toma de tiempos controlado: Se sugiere realizar una toma de tiempos controlada en condiciones de laboratorio, lo que permitiría obtener una medición más precisa y confiable del tiempo real empleado por los expertos en el proceso de clasificación. Esto proporcionaría una mejor comparación entre el rendimiento de los modelos automáticos y los especialistas humanos.

7.3. Proyectos futuros.

Implementación para otras plagas: En proyectos futuros, se propone explorar la aplicación de los modelos utilizados en esta investigación para la identificación y clasificación de otras plagas agrícolas. Este enfoque permitirá evaluar la versatilidad y eficacia

de los modelos al adaptarse a diferentes especies, generando información valiosa que contribuya al control integrado de plagas. Además, el análisis de su desempeño frente a nuevas plagas ofrecerá una base para el desarrollo de soluciones más robustas y especializadas en el ámbito de la agricultura sostenible

Desarrollo de una interfaz de usuario: Como proyecto a futuro se plantea el desarrollo de una interfaz de usuario amigable que facilite la interacción con el modelo por parte de especialistas y técnicos. Esta interfaz permitiría a los usuarios cargar imágenes, visualizar los resultados de clasificación y recibir retroalimentación en tiempo real. La implementación de esta herramienta mejorará la usabilidad del sistema, potenciando su integración en aplicaciones prácticas y promoviendo su adopción en el ámbito profesional.

Bibliografía

- Ali, L., Alnajjar, F., Jassmi, H., Gochoo, M., Khan, W., y Serhani, M. (2021). Performance evaluation of deep cnn-based crack detection and localization techniques for concrete structures. *Sensors*, 21(5), 1688. doi: 10.3390/s21051688
- Ariza-López, F. J., Rodríguez-Avi, J., y Alba-Fernández, V. (2018). Control estricto de matrices de confusión por medio de distribuciones multinomiales. *Geofocus: Revista Internacional de Ciencia y Tecnología de la Información Geográfica*(21), 6. Artículo. Descargado de <https://www.geofocus.org/index.php/geofocus/article/view/591> doi: 10.21138/GF.591
- Bovik, A. C. (2005). *2.1 - basic gray-level image processing* (Second Edition ed.). Elsevier Academic Press. Descargado de <https://www.sciencedirect.com/science/article/pii/B9780121197926500668> doi: <https://doi.org/10.1016/B978-012119792-6/50066-8>
- Córdova Pérez, C. S. (2021). Aplicación de aprendizaje profundo para la detección y clasificación automática de insectos agrícolas en trampas pegantes. Descargado de <http://hdl.handle.net/20.500.12404/20520> (Pontificia Universidad Católica del Perú)
- Faria, F. A., Perre, P., Zucchi, R. A., Jorge, L. R., Lewinsohn, T. M., Rocha, A., y da S. Torres, R. (2014). Automatic identification of fruit flies (diptera: Tephritidae). *Journal of Visual Communication and Image Representation*, 25(7), 1516-1527. Descargado de <https://doi.org/10.1016/j.jvcir.2014.06.014> doi: 10.1016/j.jvcir.2014.06.014
- Galán-Cuenca, Á., Vázquez-Martín, R., Mandow, A., Morales, J., y García-Cerezo, A. (2021). Análisis de técnicas de aumento de datos y entrenamiento en yolov3 para detección de objetos en imágenes rgb y tir del uma-sar dataset. En *XlII jornadas de automática* (pp. 686–694).
- Gomez Matheus, H. (2005). *Las moscas de la fruta*. Líneas Digitales Ltda. (<https://www.ica.gov.co/getattachment/f2cd7a85-e934-418a-b294-ef04f1bbacb0/Publicacion-4.aspx>)
- González, L. (2022). *Qué es visión computacional*. <https://www.incentro.com/es-ES/blog/que-es-tensorflow>. (Consultado en junio de 2024)
- González, R. C., y Woods, R. E. (1996). *Tratamiento digital de imágenes*. Wilmington: Díaz de Santos, Addison-Wesley. (Libro)
- González, R. C., y Woods, R. E. (2017). *Digital image processing* (4th ed.). Hoboken, NJ: Pearson. (Libro)
- González-López, G. I., Valenzuela-Carrasco, G., Toledo-Mesa, E., Juárez-Durán, M., Tapia-McClung, H., y Pérez-Staples, D. (2022). Determination of the physio-

- logical age in two tephritid fruit fly species using artificial intelligence. *Journal of Economic Entomology*, 115(5), 1513-1520. Descargado de <https://doi.org/10.1093/jee/toac133> doi: 10.1093/jee/toac133
- Goodfellow, I., Bengio, Y., y Courville, A. (2016). *Deep learning*. Cambridge, MA: MIT Press. Descargado de <https://www.deeplearningbook.org>
- Hernández-Ortiz, V., Hernández-López, M., y Steck, G. (2020, 04). *Morfología y taxonomía de tephritidae: Especies de importancia económica y cuarentenaria en américa*.
- Høye, T., Ärje, J., Bjerger, K., Hansen, O., Iosifidis, A., Leese, F., ... Raitoharju, J. (2021). Deep learning and computer vision will transform entomology. *Proceedings of the National Academy of Sciences*, 118(2). doi: 10.1101/2020.07.03.187252
- Itseez. (2024, Julio). *The opencv reference manual*. <http://opencv.org/>.
- Jaramillo, M. A., Fernández Muñoz, J. A., y de Salazar, E. M. (s.f.). Filtro de mediana sobre redes neuronales.
- Larkin A., J. (2022). *¿qué es tensorflow y para qué sirve?* <https://www.incentro.com/es-ES/blog/que-es-tensorflow>.
- Leonardo, M. M., Carvalho, T. J., Rezende, E., Zucchi, R., y Faria, F. A. (2018). Deep feature-based classifiers for fruit fly identification (diptera: Tephritidae). En *2018 31st sibgrapi conference on graphics, patterns and images (sibgrapi)* (p. 41-47). Parana, Brazil. Descargado de <https://doi.org/10.1109/SIBGRAPI.2018.00012> doi: 10.1109/SIBGRAPI.2018.00012
- Loarte Albornoz, V. A. (2023). Cuarentena interna y proceso de inspección fitosanitaria de moscas de la fruta en el mercado mayorista de frutas, lima-perú. Descargado de <https://hdl.handle.net/20.500.12996/5984> (Repositorio Institucional Universidad Nacional Agraria La Molina)
- Lubinus Badillo, F., Rueda Hernández, C. A., Marconi Narváez, B., y Arias Trillos, Y. E. (2021). Redes neuronales convolucionales: un modelo de deep learning en imágenes diagnósticas. revisión de tema. *Revista Colombiana De Radiología*, 32(3), 5591-5599. doi: 10.53903/01212095.161
- López Grisales, N. (2020). Identificación y conteo de insectos (mosca blanca, trips y minador de hoja) capturados en trampa adhesiva mediante visión e inteligencia artificial. caso flores el trival. Descargado de <https://repository.eia.edu.co/handle/11190/2654> (Universidad EIA)
- Martineau, C., Conte, D., Raveaux, R., Arnault, I., Munier, D., y Venturini, G. (2017). A survey on image-based insect classification. *Pattern Recognition*, 65, 273-284. Descargado de <https://www.sciencedirect.com/science/article/pii/S0031320316304411> doi: <https://doi.org/10.1016/j.patcog.2016.12.020>
- Martins, V. A. M., Freitas, L. C., de Aguiar, M. S., de Brisolara, L. B., y Ferreira, P. R. (2019). Deep learning applied to the identification of fruit fly in intelligent traps. En *2019 ix brazilian symposium on computing systems engineering (sbesc)* (p. 1-8). Natal, Brazil. Descargado de <https://doi.org/10.1109/SBESC49506.2019.9046088> doi: 10.1109/SBESC49506.2019.9046088
- Matthes, E. (2023). *Python crash course 2nd edition: A hands-on project-based introduction to programming*. Public Domain Mark 1.0 Creative Commons License. <https://archive.org/details/python-crash-course-2nd-edition-a>

- hands-on-project-based-introduction-to-programming. (Consultado en octubre de 2024)
- Mohr, F., y van Rijn, J. N. (2021). Towards model selection using learning curve cross-validation. En *8th icml workshop on automated machine learning (automl)*. Descargado de https://openreview.net/forum?id=EC_IHbAaMG
- Molina-Rotger, M., Morán, A., Miranda, M. A., y Alorda-Ladaria, B. (2023). Remote fruit fly detection using computer vision and machine learning-based electronic trap. *Frontiers in Plant Science*, 14. Descargado de <https://doi.org/10.3389/fpls.2023.1241576> doi: 10.3389/fpls.2023.1241576
- Municipalidad de Echarati. (2011–2014). *Proyecto: Fortalecimiento de capacidades de los productores hortofrutícolas para el control de la mosca de la fruta en la zona de echarati, distrito de echarati – la convención – cusco*. Folleto informativo. (Consultado físicamente)
- Norrbon, A. L., Korytkowski, C. A., Zucchi, R. A., Uramoto, K., Venable, G. L., McCormick, J., y Dallwitz, M. J. (s.f.). *Anastrepha and toxotrypana: Descriptions, illustrations, and interactive keys*. <https://www.delta-intkey.com/anatox/morphol.htm>. (Consultado en julio de 2024)
- Ochoa-Montiel, R., Sánchez-López, C., Carbajal-Gómez, V., Carrasco-Aguilar, M., Morales-López, F., y Juárez-Guerra, E. (2018). Segmentation of microscopic images with nsga-ii. *Computación y Sistemas*, 22(2), 387–412. doi: 10.13053/cys-22-2-2944
- Ortiz Marin, W. H. (2021). *Entomología general*. Instituto de Educación Superior Tecnológico Huando. Descargado de <https://isthuando.edu.pe/archivos/entomologia.pdf>
- Palomino, N. L. S., y Concepción, L. (2010). Watershed: un algoritmo eficiente y flexible para segmentación de imágenes de geles 2-de. *Revista de investigación de Sistemas e Informática*, 7(2), 36–41.
- Pan, S. J., y Yang, Q. (2009). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345-1359. doi: 10.1109/TKDE.2009.191
- Peng, Y., Liao, M., Deng, H., Ao, L., Song, Y., Huang, W., y Hua, J. (2020). Cnn-svm: A classification method for fruit fly image with the complex background. *IET Cyber-Physical Systems: Theory & Applications*, 5(2), 181–185. Descargado de <https://doi.org/10.1049/iet-cps.2019.0069> doi: 10.1049/iet-cps.2019.0069
- Scikitlearn. (s.f.). *Scikit-learn: Métricas y puntuación de evaluación de modelos de clasificación*. https://scikit-learn.org/stable/modules/model_evaluation.html#classification-report. (Consultado en mayo de 202)
- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., y Batra, D. (2017). Grad-cam: Visual explanations from deep networks via gradient-based localization. En *2017 IEEE International Conference on Computer Vision (ICCV)* (p. 618-626). doi: 10.1109/ICCV.2017.74
- Servicio de Sanidad Agraria Perú. (2007). *Manual del sistema nacional de vigilancia de moscas de la fruta*. Lima, Perú. Libro. Descargado de https://www.senasa.gob.pe/senasa/wp-content/uploads/2014/12/MANUAL_VIGILANCIA_2007.pdf
- Servicio Nacional de Sanidad Agraria del Perú. (s.f.). *Información institucio-*

- nal.* <https://www.gob.pe/institucion/senasa/organizacion>. (Consultado en agosto de 2024)
- Servicio Nacional de Sanidad Agraria Perú. (2014). *Todo sobre las moscas de la fruta*. Folleto. Descargado de https://www.senasa.gob.pe/senasa/descargasarchivos/2014/12/todo_sobre_las_moscas_de_la_fruta.pdf
- Servicio Nacional de Sanidad Agropecuaria - SENASA. (2009). *Erradicación de moscas de la fruta (Ceratitis capitata y Anastrepha spp.) en las regiones de lima, ancash y la libertad*. (Documento no publicado)
- Simonyan, K., y Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. Descargado de <http://arxiv.org/abs/1409.1556>
- Sistema Nacional de Vigilancia de Moscas de la Fruta. (S. F.a). *Informe interno sobre [especies del género anastrepha]*. Información no publicada.
- Sistema Nacional de Vigilancia de Moscas de la Fruta. (S. F.b). *Informe interno sobre [familia: Tephritidae]*. Información no publicada.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., y Wojna, Z. (2016, jun). Rethinking the inception architecture for computer vision. En *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (p. 2818-2826). Los Alamitos, CA, USA: IEEE Computer Society. Descargado de <https://doi.ieeecomputersociety.org/10.1109/CVPR.2016.308> doi: 10.1109/CVPR.2016.308
- Sáfer. (2022). *Trampa mcphail*. <https://safer.com.co/wp-content/uploads/2022/11/F.T-Trampa-McPhail-1.pdf>. (Ficha técnica, PDF)
- Sánchez de la Cuadra, D. F. (2022). Sistema autónomo de detección de plagas en el olivar. Descargado de <https://hdl.handle.net/10953.1/19831> (Universidad de Jaén)
- TensorFlow. (2022). *Keras*. <https://www.tensorflow.org/guide/keras?hl=es-419>. (Consultado en julio de 2024)
- TensorFlow Authors. (2024a). *tf.keras.applications.inception_v3.preprocess_input*. https://www.tensorflow.org/api_docs/python/tf/keras/applications/vgg16/preprocess_input. (Consultado en mayo de 2024)
- TensorFlow Authors. (2024b). *tf.keras.applications.vgg16.preprocess_input*. https://www.tensorflow.org/api_docs/python/tf/keras/applications/vgg16/preprocess_input. (Consultado en mayo de 2024)
- TensorFlow Authors. (2024c). *tf.keras.applications.vgg19.preprocess_input*. https://www.tensorflow.org/api_docs/python/tf/keras/applications/vgg16/preprocess_input. (Consultado en mayo de 2024)
- Wikipedia. (2024). *Provincia de la convención*. https://es.wikipedia.org/wiki/Provincia_de_La_Convención. (Consultado en agosto de 2024)
- Yang, S., Xiao, W., Zhang, M., Guo, S., Zhao, J., y Shen, F. (s.f.). Image data augmentation for deep learning: A survey.
- Yosinski, J., Clune, J., Bengio, Y., y Lipson, H. (2014). How transferable are features in deep neural networks? *Advances in neural information processing systems*, 27.

Anexos

ROT		REGISTRO OFICIAL DE TRAMPEO		FECHA:	RUTA:	INSPECCION: SECCIONALES IDENTIFICADORA OPERACIONAL	SEMANA:
DIRECCION SENASA -							
CAMPO		IDENTIFICACION Y TAXONOMIA					
Trampa		Comaricá capazos		Anastreptis spp			
Código		Esteriles					
N°		Fertiles					
SS		Df. E.F.					
3		Uv. E.F.					
4		Uv. OE					
5		Uv. OE					
6		Uv. OE					
7		Uv. OE					
8		Uv. OE					
9		Uv. OE					
10		Uv. OE					
11		Uv. OE					
12		Uv. OE					
13		Uv. OE					
14		Uv. OE					
15		Uv. OE					
16		Uv. OE					
17		Uv. OE					
18		Uv. OE					
19		Uv. OE					
20		Uv. OE					
21		Uv. OE					
22		Uv. OE					
23		Uv. OE					
24		Uv. OE					
25		Uv. OE					
26		Uv. OE					
27		Uv. OE					
28		Uv. OE					
29		Uv. OE					
30		Uv. OE					
31		Uv. OE					
32		Uv. OE					
33		Uv. OE					
34		Uv. OE					
35		Uv. OE					
36		Uv. OE					
37		Uv. OE					
38		Uv. OE					
39		Uv. OE					
40		Uv. OE					
41		Uv. OE					
42		Uv. OE					
43		Uv. OE					
44		Uv. OE					
45		Uv. OE					
46		Uv. OE					
47		Uv. OE					
48		Uv. OE					
49		Uv. OE					
50		Uv. OE					
51		Uv. OE					
52		Uv. OE					
53		Uv. OE					
54		Uv. OE					
55		Uv. OE					
56		Uv. OE					
57		Uv. OE					
58		Uv. OE					
59		Uv. OE					
60		Uv. OE					
61		Uv. OE					
62		Uv. OE					
63		Uv. OE					
64		Uv. OE					
65		Uv. OE					
66		Uv. OE					
67		Uv. OE					
68		Uv. OE					
69		Uv. OE					
70		Uv. OE					
71		Uv. OE					
72		Uv. OE					
73		Uv. OE					
74		Uv. OE					
75		Uv. OE					
76		Uv. OE					
77		Uv. OE					
78		Uv. OE					
79		Uv. OE					
80		Uv. OE					
81		Uv. OE					
82		Uv. OE					
83		Uv. OE					
84		Uv. OE					
85		Uv. OE					
86		Uv. OE					
87		Uv. OE					
88		Uv. OE					
89		Uv. OE					
90		Uv. OE					
91		Uv. OE					
92		Uv. OE					
93		Uv. OE					
94		Uv. OE					
95		Uv. OE					
96		Uv. OE					
97		Uv. OE					
98		Uv. OE					
99		Uv. OE					
100		Uv. OE					
101		Uv. OE					
102		Uv. OE					
103		Uv. OE					
104		Uv. OE					
105		Uv. OE					
106		Uv. OE					
107		Uv. OE					
108		Uv. OE					
109		Uv. OE					
110		Uv. OE					
111		Uv. OE					
112		Uv. OE					
113		Uv. OE					
114		Uv. OE					
115		Uv. OE					
116		Uv. OE					
117		Uv. OE					
118		Uv. OE					
119		Uv. OE					
120		Uv. OE					
121		Uv. OE					
122		Uv. OE					
123		Uv. OE					
124		Uv. OE					
125		Uv. OE					
126		Uv. OE					
127		Uv. OE					
128		Uv. OE					
129		Uv. OE					
130		Uv. OE					
131		Uv. OE					
132		Uv. OE					
133		Uv. OE					
134		Uv. OE					
135		Uv. OE					
136		Uv. OE					
137		Uv. OE					
138		Uv. OE					
139		Uv. OE					
140		Uv. OE					
141		Uv. OE					
142		Uv. OE					
143		Uv. OE					
144		Uv. OE					
145		Uv. OE					
146		Uv. OE					
147		Uv. OE					
148		Uv. OE					
149		Uv. OE					
150		Uv. OE					
151		Uv. OE					
152		Uv. OE					
153		Uv. OE					
154		Uv. OE					
155		Uv. OE					
156		Uv. OE					
157		Uv. OE					
158		Uv. OE					
159		Uv. OE					
160		Uv. OE					
161		Uv. OE					
162		Uv. OE					
163		Uv. OE					
164		Uv. OE					
165		Uv. OE					
166		Uv. OE					
167		Uv. OE					
168		Uv. OE					
169		Uv. OE					
170		Uv. OE					
171		Uv. OE					
172		Uv. OE					
173		Uv. OE					
174		Uv. OE					
175		Uv. OE					
176		Uv. OE					
177		Uv. OE					
178		Uv. OE					
179		Uv. OE					
180		Uv. OE					
181		Uv. OE					
182		Uv. OE					
183		Uv. OE					
184		Uv. OE					
185		Uv. OE					
186		Uv. OE					
187		Uv. OE					
188		Uv. OE					
189		Uv. OE					
190		Uv. OE					
191		Uv. OE					
192		Uv. OE					
193		Uv. OE					
194		Uv. OE					
195		Uv. OE					
196		Uv. OE					
197		Uv. OE					
198		Uv. OE					
199		Uv. OE					
200		Uv. OE					
201		Uv. OE					
202		Uv. OE					
203		Uv. OE					
204		Uv. OE					
205		Uv. OE					
206		Uv. OE					
207		Uv. OE					
208		Uv. OE					
209		Uv. OE					
210		Uv. OE					
211		Uv. OE					
212		Uv. OE					
213		Uv. OE					
214		Uv. OE					
215		Uv. OE					
216		Uv. OE					
217		Uv. OE					
218		Uv. OE					
219		Uv. OE					
220		Uv. OE					
221		Uv. OE					
222		Uv. OE					
223							