UNIVERSIDAD TÉCNICA DE AMBATO

FACULTAD DE CIENCIAS AGROPECUARIAS

CARRERA DE INGENIERÍA AGRONÓMICA

Inteligencia artificial para la detección de dos enfermedades en manzana (*Malus domestica*, var. Emilia)

DOCUMENTO FINAL DEL PROYECTO DE INVESTIGACION COMO REQUISITO PARA OBTENER EL GRADO DE INGENIERIA AGRONOMICA

AUTOR :

Christian Ivan Alomalisa Machado

TUTOR:

Ing. Manolo Sebastián Muñoz Espinoza

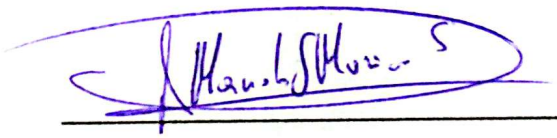
CEVALLOS – ECUADOR

2025

HOJA DE MIEMBROS DEL TRIBUNAL

INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN DE DOS ENFERMEDADES EN MANZANA (Malus domestica, VAR. EMILIA)

REVISADO POR:

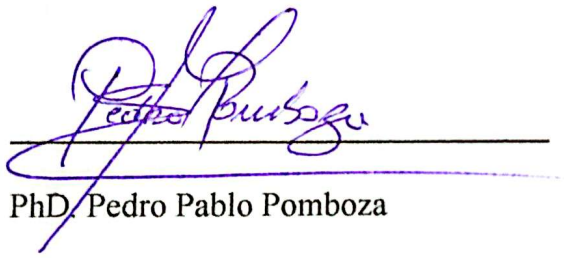


Ing. Manolo Sebastián Muñoz Espinoza

TUTOR

APROBADO POR LOS MIEMBROS DE CALIFICACIÓN:

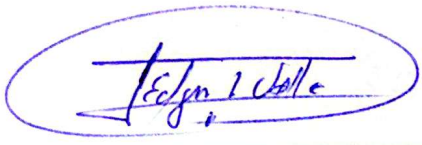
FECHA



22/07/2025

PhD. Pedro Pablo Pomboza

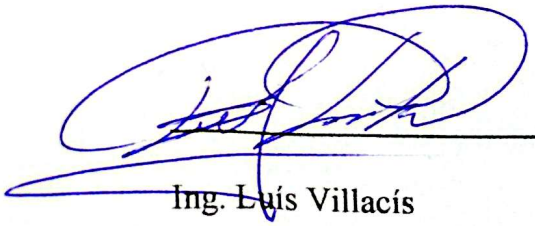
PRESIDENTE TRIBUNAL



22/07/2025

Ing. Luciano Valle

MIEMBRO DEL TRIBUNAL DE CALIFICACIÓN



22/07/2025

Ing. Luís Villacís

MIEMBRO DEL TRIBUNAL DE CALIFICACIÓN

AUTORIA DE LA INVESTIGACIÓN

El suscrito, CHRISTIAN IVAN ALOMALISA MACHADO, portador de la cédula de identidad número 1805136783, libre y voluntariamente declaro que el Informe Final del Proyecto de investigación titulado: INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN DE DOS ENFERMEDADES EN MANZANA (*Malus domestica*, VAR. EMILIA), es original, autentico y personal.

En tal virtud, declaro que el contenido es de mi responsabilidad legal y académica, excepto donde se indican las fuentes de información consultadas.



CHRISTIAN IVAN ALOMALISA MACHADO

DERECHOS DE AUTOR

Al presentar este Informe Final del Proyecto de Investigación titulado "INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN DE DOS ENFERMEDADES EN MANZANA (*Malus domestica*, VAR. EMILIA)", como uno de los requisitos previos para la obtención del título de grado de Ingeniero Agrónomo, en la Facultad de Ciencias Agropecuarias de la Universidad Técnica de Ambato, autorizo a la Biblioteca de la Facultad, para que este documento esté disponible para su lectura, según las normas de la Universidad.

Estoy de acuerdo en que se realice cualquier copia de este Informe Final, dentro de las regulaciones de la Universidad, siempre y cuando esta reproducción no suponga una ganancia económica potencial.

Sin perjuicio de ejercer mi derecho de autor, autorizo a la Universidad Técnica de Ambato la publicación de este Informe Final, o de parte de él.



CHRISTIAN IVAN ALOMALISA MACHADO

Dedicatoria

A mis docentes y mi familia que han sido una guía constante y un ejemplo de perseverancia y por encenderé en mi la pasión por el conocimiento su influencia ha sido una herramienta clave en mi formación profesional la confianza depositada en mi ha sido el combustible que me ha traído hasta aquí.

Agradecimiento

En primer lugar, agradezco a Dios por darme la vida y tener la oportunidad de disfrutar de las maravillas de su creación, a mis padres que con cuyo amor incondicional y apoyo constante han sido el motor silencioso detrás de cada uno de mis logros. A mi esposa por creer en mi incluso cuando yo dudaba. Este trabajo no solo refleja lo aprendido sino también todo lo vivido junto a las personas que han formado un vínculo junto a mí y mi familia muchas gracias por acompañarme en este camino.

Índice general de contenidos

Contenido

CAPÍTULO I.....1
MARCO TEÓRICO.....1
1.1 Antecedentes Investigativos.....1
1.2 Objetivos.....4
1.2.1 Objetivo general.....4
1.2.3 Objetivos Específicos.....4
CAPITULO II.....5
METODOLOGÍA.....5
2.1 Materiales y Métodos.....5
CAPITULO III.....12
RESULTADOS Y DISCUSIÓN.....12
3.1 Análisis y discusión de los resultados.....12
CAPÍTULO IV.....21
CONCLUSIONES Y RECOMENDACIONES.....21
C. MATERIALES DE REFERENCIA.....25

Índice de Tablas

Tabla 1. Resumen de métricas de evaluación…….. 17

Índice de Figuras

Figura 1. Etiquetas del conjunto de entrenamiento con sus clases..... 7
Figura 2. Etiquetas del conjunto de entrenamiento con sus clases..... 8
Figura 3. Matriz de confusión..... 13
Figura 4. Gráficos de pérdida y métricas..... 17
Figura 5. Imágenes de validación..... 18

Resumen Ejecutivo

La detección temprana de enfermedades en cultivos agrícolas es fundamental para garantizar una producción sostenible y rentable. En este contexto, la inteligencia artificial (IA) se ha convertido en una herramienta clave para el desarrollo de sistemas automatizados de diagnóstico fitosanitario. El presente trabajo tiene como objetivo general desarrollar un modelo basado en inteligencia artificial para la detección de dos enfermedades comunes en manzanos: oídio (*Podosphaera leucotricha*) y sarna del manzano *(Venturia inaequalis*), a partir de imágenes digitales de hojas.

Para alcanzar este propósito, se creó una base de datos de imágenes de hojas de manzana (variedad Emilia), clasificadas en tres categorías: sanas, con oídio y con sarna. Las imágenes fueron adquiridas, preprocesadas y etiquetadas mediante la plataforma Roboflow. Posteriormente, se entrenó un modelo de detección de objetos basado en YOLOv12, capaz de identificar y localizar visualmente las zonas afectadas en cada imagen.

El desempeño del modelo fue evaluado utilizando métricas como precisión, sensibilidad y especificidad, arrojando resultados prometedores, destacando un desempeño óptimo en la identificación de hojas sanas y afectadas por sarna, y un buen equilibrio entre sensibilidad y precisión en la detección del oídio. Estos resultados demuestran la viabilidad del uso de modelos de aprendizaje profundo en la detección automatizada de enfermedades foliares en frutales.

Este estudio contribuye al desarrollo de soluciones tecnológicas accesibles y escalables para el monitoreo eficiente de enfermedades en cultivos de manzana, facilitando la toma de decisiones informadas en el manejo integrado de plagas y enfermedades.

Palabras clave: Inteligencia artificial, detección de enfermedades, oídio, sarna, YOLOv12, manzano, *Malus domestica*, visión por computadora.

Abstract

Early detection of diseases in agricultural crops is essential to ensure sustainable and profitable production. In this context, artificial intelligence (AI) has become a key tool for the development of automated plant health diagnosis systems. This thesis aims to develop an AI-based model for the detection of two common diseases in apple trees: powdery mildew (*Podosphaera leucotricha*) and apple scab (*Venturia inaequalis*), using digital images of leaves.

To achieve this, a database of apple leaf images (cv. Emilia) was created, classified into three categories: healthy, with mildew, and with scab. The images were acquired, preprocessed, and annotated using the Roboflow platform. Subsequently, an object detection model based on YOLOv12 was trained to identify and visually locate affected areas in each image.

The performance of the model was evaluated using metrics such as precision, sensitivity, and specificity, yielding promising results. The model showed optimal performance in identifying healthy leaves and those affected by scabs, along with a good balance between sensitivity and precision in detecting mildew. These findings demonstrate the feasibility of using deep learning models for the automated detection of foliar diseases in fruit trees.

This study contributes to the development of accessible and scalable technological solutions for the efficient monitoring of diseases in apple crops, supporting informed decision-making in integrated pest and disease management.

Keywords: Artificial intelligence, disease detection, powdery mildew, apple scab, YOLOv12, apple tree, Malus domestica, computer vision.

CAPÍTULO I

MARCO TEÓRICO

1.1 Antecedentes Investigativos

El uso de inteligencia artificial para la detección de enfermedades en plantas ha ganado relevancia en los últimos años, con avances significativos en la aplicación de algoritmos de aprendizaje profundo. Las principales tecnologías son Big Data, Machine Learning, Deep Learning (Rodríguez Torres et al., 2023).

A continuación, se presentan estudios relevantes que sustentan la viabilidad de este proyecto:

Detección de gorgojo del maíz

En el trabajo de (Analuisa-Aroca et al., 2023), emplearon una red neuronal convolucional tipo ResNet-50 para detectar la presencia del gorgojo del maíz (*Sitophilus zeamais*) en granos almacenados. Utilizando un conjunto de 1380 imágenes de granos de maíz obtenidos de mercados locales en Ecuador, el modelo alcanzó niveles altos de precisión en la clasificación binaria entre granos afectados y no afectados, reportando valores superiores a 0.94 en métricas como precisión, F-score, AUC e índice de calidad. Además, destacó su capacidad para funcionar con un número reducido de muestras de entrenamiento, lo cual es fundamental en contextos donde la disponibilidad de datos etiquetados es limitada.

Algoritmos para detección de enfermedades fúngicas en el arroz

En los últimos años, el uso de algoritmos basados en inteligencia artificial (Facuy-Delgado et al., 2022) ha cobrado relevancia en la detección temprana de enfermedades fúngicas en cultivos de arroz (*Oryza sativa*). Estudios recientes han demostrado la eficacia de técnicas como las redes neuronales convolucionales (CNN), máquinas de soporte vectorial (SVM) y modelos de lógica difusa para identificar enfermedades como la pyriculariosis y la helmintosporiosis con niveles altos de precisión (>95%)

mediante análisis de imágenes de hojas afectadas. Estos sistemas no solo facilitan un diagnóstico rápido y preciso, sino que también representan una herramienta accesible para productores sin formación especializada, reduciendo significativamente las pérdidas agrícolas y mejorando la seguridad alimentaria.

Este tipo de enfoque se alinea con las tendencias actuales en agricultura de precisión, integrando tecnología avanzada para optimizar el control de plagas y enfermedades en condiciones reales de campo.

Detección de enfermedades en el cultivo de frijol

El estudio de (Saldaña Valenzuela, 2023) sobre la aplicación de Inteligencia Artificial (IA) en la detección de enfermedades en el cultivo de frijol forma parte de un enfoque innovador dentro de la Agricultura 4.0, orientado hacia prácticas sostenibles y eficientes que maximicen el rendimiento agrícola mientras minimizan el impacto ambiental. Los avances en técnicas de Deep Learning y Computación Visual han permitido desarrollar modelos predictivos capaces de identificar con alta precisión enfermedades como la Mancha angular y la Roya del frijol, a partir del análisis de imágenes obtenidas directamente en el campo. Estas tecnologías ofrecen una alternativa efectiva a los métodos tradicionales de diagnóstico, reduciendo pérdidas en la producción y optimizando el uso de insumos.

Detección de enfermedades foliares con arquitecturas de redes neuronales convolucionales

Estudios confirman que las redes neuronales convolucionales, especialmente VGG16 y Xception, son herramientas poderosas para la detección precisa de enfermedades en plantas. La posibilidad de implementar estos modelos en dispositivos económicos como Raspberry Pi abre camino a soluciones accesibles y escalables para agricultores. Además, el alto nivel de precisión alcanzado por algunos modelos indica que la inteligencia artificial puede convertirse en una herramienta clave en la Agricultura 4.0, ayudando a mitigar pérdidas de cosechas, optimizar el uso de insumos y reducir el impacto ambiental (Mora et al., 2021).

Redes neuronales convolucionales para la clasificación de mancha negra en cítricos

La investigación de (Huanca Namuche et al., 2025)demuestran la efectividad del modelo de redes neuronales convolucionales (CNN) desarrollado para la clasificación de la mancha negra en cítricos. El modelo alcanzó una precisión del 100% en la clasificación de frutas sanas y afectadas, respaldado por una curva ROC con un área bajo la curva (AUC) de 1.0, lo que indica un desempeño perfecto en la detección. Además, la matriz de confusión confirmó que no hubo errores en la identificación de los casos evaluados. Estos resultados fueron contrastados estadísticamente con otros modelos existentes mediante la prueba de McNemar, evidenciando que el modelo propuesto (modelo A) es significativamente superior tanto al modelo B como al modelo C en términos de precisión y fiabilidad. Esto posiciona al modelo desarrollado como una herramienta altamente eficaz y competitiva para la detección automatizada de enfermedades en cítricos.

Los principales resultados del estudio presentado por (Li et al., 2024) indican que el método propuesto, que integra tres componentes clave (DSCon, BiFormer e IF-CIoU), logra el mejor desempeño general en la detección de enfermedades en hojas de manzano. Este modelo alcanza un mAP50 (promedio de precisión a 50% de solapamiento) del 93.81% y un mAP50-95 del 95.69% , lo cual demuestra una mejora significativa respecto a versiones anteriores de YOLO y otros modelos existentes.

Además, se presenta una comparación con diferentes arquitecturas de YOLO como YOLOv3, YOLOv4, YOLOv5 y YOLOv7, donde el modelo propuesto supera consistentemente a estos en métricas como precisión (PR), exactitud (AC) y F1-Score, tanto en el conjunto de datos FGVC7 como en FGVC8.

Por otro lado, (Wang et al., 2022) presenta a MGA-YOLO, un modelo optimizado basado en YOLOv5s, que obtiene el máximo mAP del 89.3% en el conjunto de prueba ALDOD (Apple Leaf Disease Object Detection), superando a otros modelos avanzados como YOLOX-L. Este modelo también destaca por su eficiencia, alcanzando 84.13 FPS (cuadros por segundo), lo que lo hace adecuado para aplicaciones en tiempo real.

1.2 Objetivos

1.2.1 Objetivo general

Desarrollar un modelo basado en inteligencia artificial para la detección de enfermedades como oídio y *Venturia inaequalis* en hojas de manzana a partir de imágenes digitales.

1.2.3 Objetivos Específicos

1. Crear una base de datos de imágenes de hojas de manzana que incluya hojas sanas y hojas afectadas por oídio y *Venturia inaequalis*.
2. Entrenar un modelo de inteligencia artificial para clasificar imágenes de hojas sanas y enfermas.
3. Evaluar el desempeño del modelo entrenado en términos de precisión, sensibilidad y especificidad.

CAPITULO II

METODOLOGÍA

2.1 Materiales y Métodos

2.1.1 Adquisición y preparación de datos

Las imágenes fueron recopiladas de la plataforma Kaggle (*Plant Pathology 2021 - FGVC8*, 2021), incluyendo fotografías tomadas directamente en campo.

El dataset utilizado para el entrenamiento del modelo consistió en un total de 300 imágenes, divididas en tres clases:

Sarna: 100 imágenes.

Oídio: 100 imágenes.

Hoja sana: 100 imágenes.

2.1.2 Preprocesamiento de las imágenes

Para mejorar la robustez del modelo frente a variaciones en las condiciones de iluminación, ángulos de captura y otras variables ambientales, se aplicó data augmentation mediante la misma plataforma Roboflow.

Las técnicas de augmentación utilizadas incluyeron:

- Flip: Horizontal y vertical.
- Rotación: 90° en sentido horario, antihorario y hacia abajo.
- Desenfoque: Hasta 2.1 píxeles.
- Ruido: Añadir ruido a hasta el 3.78% de los píxeles.
- Rotación de bounding box: Entre -15° y +15°.
- Exposición: Variación entre -10% y +10%.

Como resultado del proceso de augmentación, el tamaño del conjunto de entrenamiento aumentó a 780 imágenes.

El dataset fue dividido en tres subconjuntos:

Entrenamiento: 780 imágenes.

Validación: 30 imágenes.

Prueba: 30 imágenes.

2.1.3. Etiquetado de las imágenes

El etiquetado fue realizado mediante la plataforma Roboflow (*Roboflow: Computer Vision Tools for Developers and Enterprises*, 2025), donde se definieron bounding boxes precisos alrededor de las áreas afectadas por cada enfermedad y se identificaron las hojas sanas como una clase separada.

Todas las imágenes fueron etiquetadas manualmente utilizando, las clases que se utilizaron fueron:

- Clase 0: “oidio”
- Clase 1: “sana”
- Clase 2: “sarna”

Cada imagen contó con su archivo en formato texto, de acuerdo con el estándar de la arquitectura YOLO.

En la Figura 1 y Figura 2 podemos observar las imágenes etiquetadas del conjunto de entrenamiento.

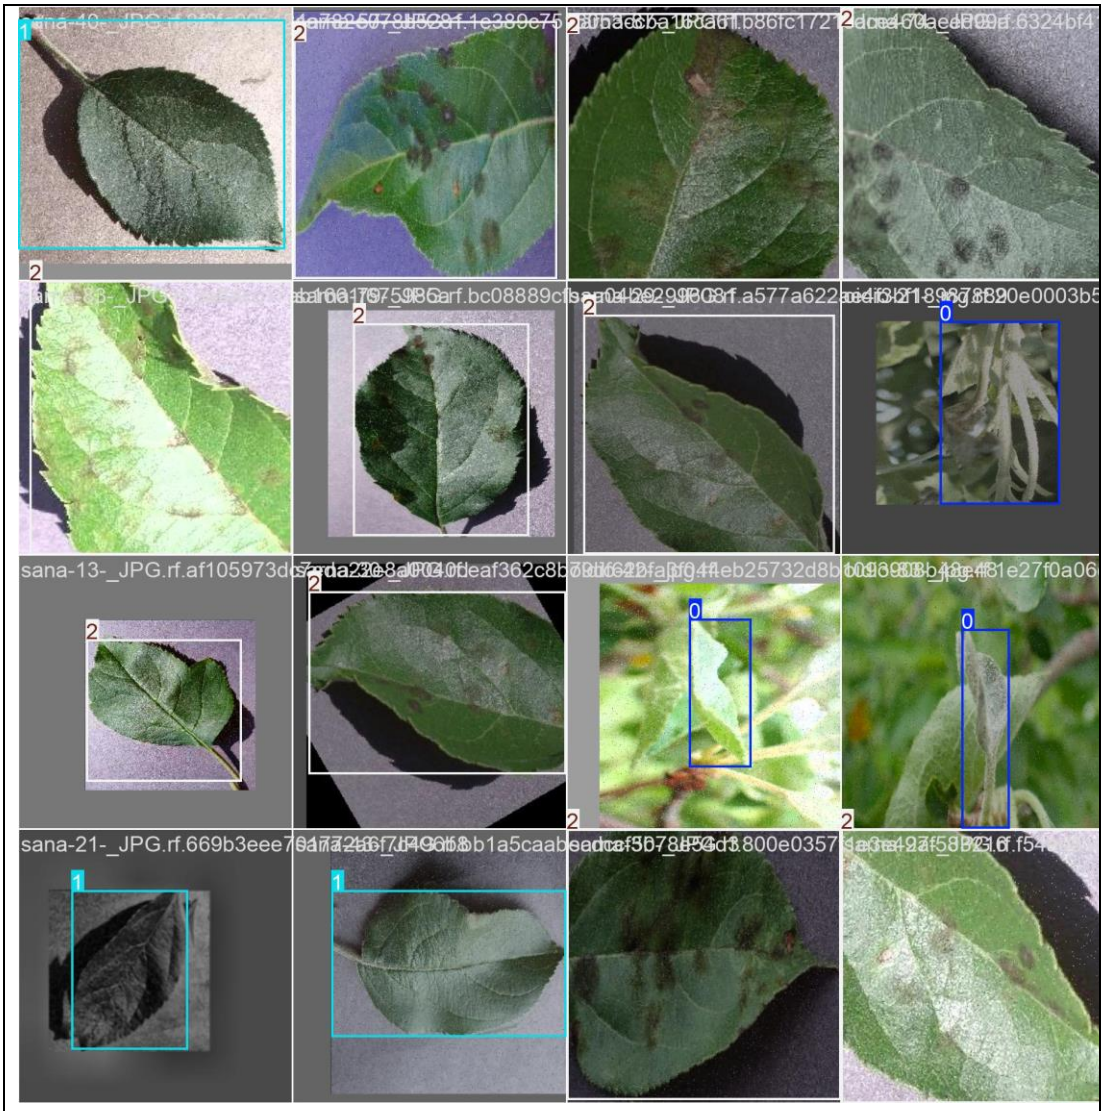


Figura 1. Etiquetas del conjunto de entrenamiento con sus clases.

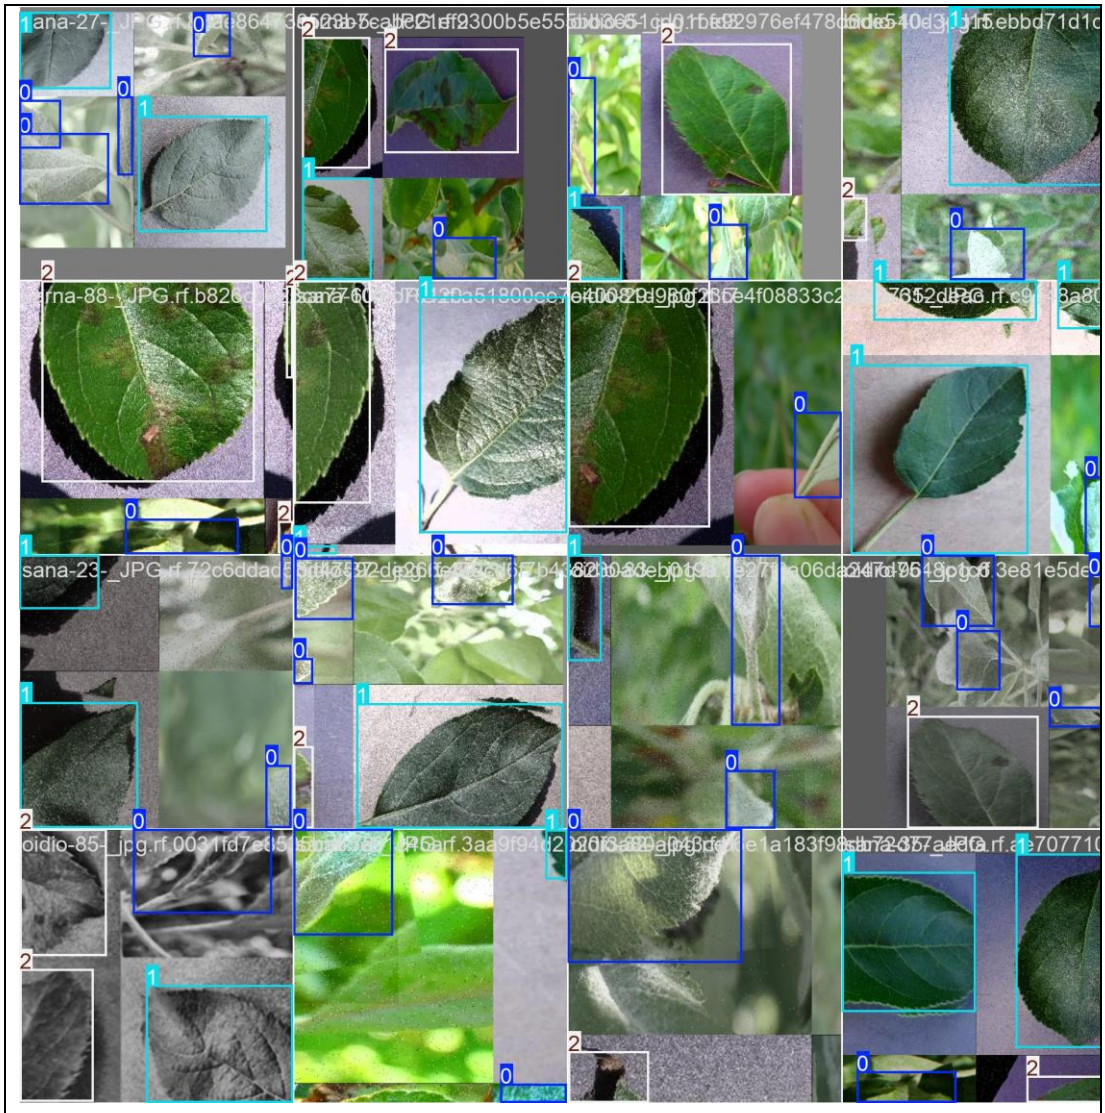


Figura 2. Etiquetas del conjunto de entrenamiento con sus clases.

2.1.4 Arquitectura del Modelo

Para el desarrollo del sistema de detección automática de enfermedades, se empleó la arquitectura YOLOv12 (Tian et al., 2025), última versión del modelo YOLO (You Only Look Once), implementada dentro del entorno Ultralytics YOLO.

El modelo seleccionado para la detección de enfermedades fue, implementado en Google Colab con GPU habilitada para acelerar el proceso de entrenamiento.

Características principales:

- Modelo basado en detalles visuales y aprendizaje profundo.
- Capaz de realizar detección y clasificación simultánea.

- Entrenamiento rápido y alto rendimiento en dispositivos con recursos limitados.

2.1.5 Entrenamiento del modelo

Los siguientes parámetros fueron configurados para el entrenamiento:

- Epochs: 100
- Batch size: 16
- Learning rate: Inicializado en 0.01, ajustado dinámicamente durante el entrenamiento.
- Optimizador: AdamW
- Pérdida: Combinación de pérdidas de caja (box loss), clasificación (cls loss) y distribución focal (dfl loss).

El entrenamiento se llevó a cabo en un entorno de desarrollo basado en Python, utilizando bibliotecas como PyTorch y Ultralytics YOLO. Los resultados del entrenamiento fueron monitoreados mediante métricas clave como precisión, recall y mAP.

2.1.5 Evaluación del modelo

El rendimiento del modelo fue evaluado utilizando el conjunto de prueba (30 imágenes). Las métricas principales empleadas fueron:

Una vez entrenado, el modelo fue evaluado con el conjunto de prueba, obteniendo:

- Precisión por clase
- Sensibilidad (recall)
- Especificidad
- Matriz de confusión

Precisión (Precision)

La precisión mide cuán correctas fueron las predicciones positivas del modelo. En otras palabras, de todas las hojas que el modelo identificó como "con oídio", ¿cuántas realmente lo estaban?

$$Precisión = \frac{Verdaderos\ Positivos\ (VP)}{Verdaderos\ Positivos\ (VP) + Falsos\ Positivos(FP)}$$

Sensibilidad (Recall)

La sensibilidad mide la capacidad del modelo para encontrar todos los casos reales de enfermedad. Es decir, de todas las hojas que realmente tenían oídio, ¿qué porcentaje fue correctamente detectado por el modelo?

$$Sensibilidad = \frac{Verdaderos\ Positivos\ (VP)}{Verdaderos\ Positivos\ (VP) + Falsos\ Negativos(FN)}$$

Especificidad (Tasa de Verdaderos Negativos - TNR)

La especificidad mide la capacidad del modelo para identificar correctamente los casos negativos (hojas sanas). De todas las hojas sanas, ¿qué porcentaje fue correctamente reconocido como tal?

$$Especificidad = \frac{Verdaderos\ Negativos\ (VN)}{Verdaderos\ Negativos\ (VN) + Falsos\ Positivos\ (FP)}$$

2.1.6 Recursos

Humanos

- Director de tesis con experiencia en IA y agricultura.
- Asistente para la recolección de datos.

Materiales

- Plantaciones de manzana.
- Equipos de captura de imágenes.
- Económicos
- Presupuesto para viajes de campo.

Software y herramientas utilizadas

- Entorno de programación: Python
- Framework de IA: Ultralytics YOLOv12
- Procesamiento de imágenes: Roboflow
- Visualización: Matplotlib
- Etiquetado: Roboflow
- Plataforma de entrenamiento: Google Colab
- Sistema operativo: Windows

CAPITULO III

RESULTADOS Y DISCUSIÓN

3.1 Análisis y discusión de los resultados

Resultados obtenidos

Una vez finalizado el entrenamiento del modelo YOLOv12 para la detección de tres clases —hojas sanas, hojas afectadas por oídio y hojas afectadas por sarna—, se procedió a evaluar su desempeño utilizando el conjunto de datos de validación. Este conjunto consistió en un total de 30 imágenes no vistas durante el entrenamiento, las cuales fueron previamente anotadas utilizando la plataforma Roboflow, garantizando una correcta identificación de las regiones de interés.

El modelo YOLOv12 alcanzó los siguientes resultados después de 100 epochs de entrenamiento:

- Precisión (Precision): Máximo de 0.9923.
- Recall (Recall): Máximo de 0.89524.
- mAP50 (Mean Average Precision at IoU=0.5): Máximo de 0.92512.

Estos resultados indican que el modelo tiene una alta capacidad para detectar correctamente las enfermedades de sarna y oídio, así como identificar correctamente las hojas sanas.

Análisis de la matriz de confusión

La matriz de confusión muestra el desempeño del modelo en términos de clasificación:

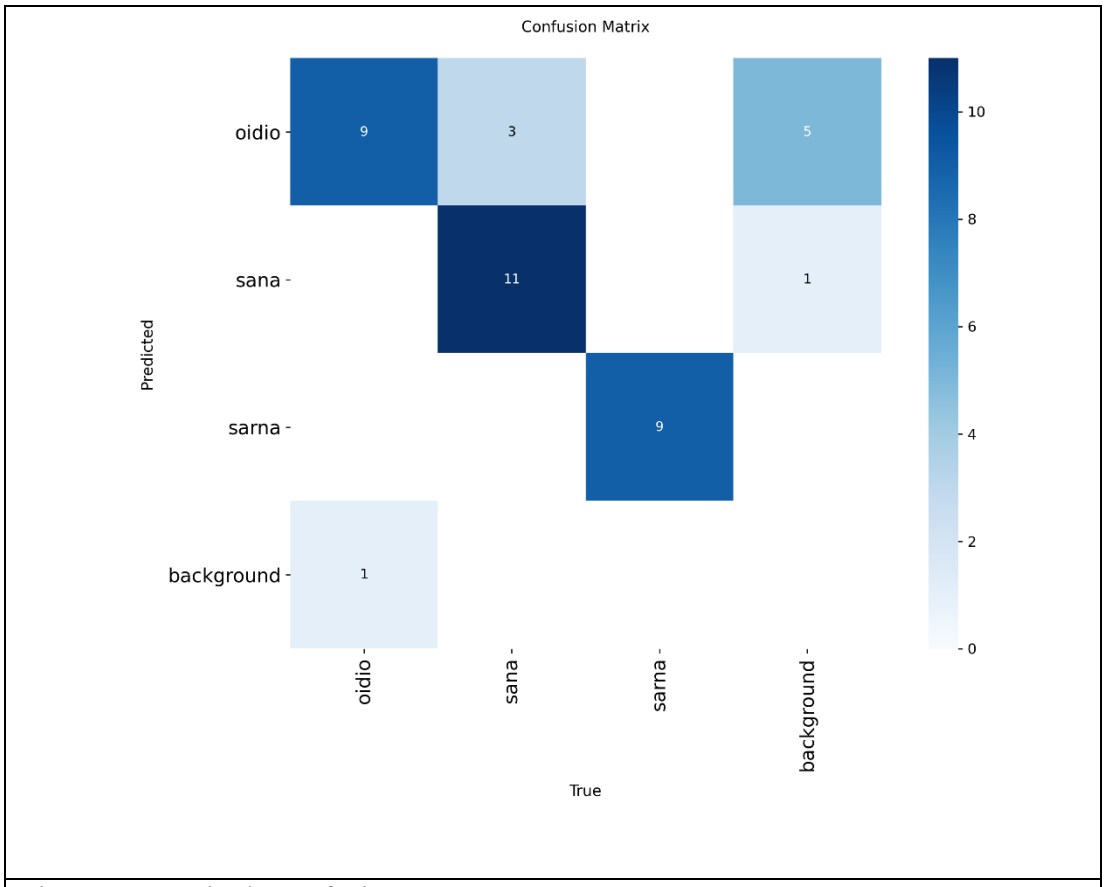


Figura 3. Matriz de confusión

Oídio: El modelo clasificó correctamente 9 imágenes de oídio, pero hubo 3 falsos positivos (clasificados como sana), 5 falsos positivos (clasificados como sarna) y un falso negativo (clasificado como background)

Sana: El modelo clasificó correctamente 11 imágenes de hojas sanas, pero hubo 3 falsos positivos (clasificados como oídio).

Sarna: El modelo clasificó correctamente 9 imágenes de sarna, sin falsos positivos ni falsos negativos significativos.

Background: Hubo un caso donde el modelo clasificó incorrectamente una imagen como background.

Estos resultados sugieren que el modelo tiene una buena capacidad para distinguir entre las clases, aunque existen algunas confusiones entre oídio y hojas sanas.

De acuerdo con los datos para evaluación y tomado en cuenta las enfermedades y las hojas sanas, la precisión, sensibilidad y especificidad, se muestra a continuación.

Clase "oidio":

Verdaderos Positivos (VP): 9 (predicción correcta de "oidio")

Falsos Positivos (FP): 3 (clasificadas como "oidio" pero eran "sana")

Falsos Negativos (VN): 0 (no hay casos de "oidio" clasificados como otra cosa)

Cálculos:

1. **Precisión:**

$$Precision = \frac{VP}{VP + VN}$$

$$Precision = \frac{9}{9 + 3} = 0.75$$

2. **Sensibilidad:**

$$Sensibilidad = \frac{VP}{VP + FN}$$

$$Sensibilidad = \frac{9}{9 + 0} = 1.00$$

3. **Especificidad:**

Para calcular la especificidad, consideramos las clases "sana" y "sarna" como negativas respecto a "oidio".

Verdaderos Negativos (TN): 11 (sana) + 9 (sarna) = 20

Falsos Positivos (FP): 3

$$Especificidad = \frac{VN}{VN + FP}$$

$$Especificidad = \frac{20}{20 + 3} = 0.86$$

Clase "sana":

Verdaderos Positivos (VP): 11 (predicción correcta de "sana")

Falsos Positivos (FP): 3 (clasificadas como "sana" pero eran "oidio") + 0 (clasificadas como "sana" pero eran "sarna") = 3

Falsos Negativos (VN): 0 (no hay casos de "sana" clasificados como otra cosa)

Cálculos:

1. **Precisión:**

$$Precision = \frac{VP}{VP + VN}$$

$$Precision = \frac{11}{11 + 3} = 0.78$$

2. **Sensibilidad:**

$$Sensibilidad = \frac{VP}{VP + FN}$$

$$Sensibilidad = \frac{11}{11 + 0} = 1.00$$

3. **Especificidad:**

Para calcular la especificidad, consideramos las clases "oidio" y "sarna" como negativas respecto a "sana".

Verdaderos Negativos (VN): 9 (oidio) + 9 (sarna) = 18

Falsos Positivos (FP): 3

$$Especificidad = \frac{VN}{VN + FP}$$

$$Especificidad = \frac{18}{18 + 3} = 0.85$$

Clase "sarna":

Verdaderos Positivos (VP): 9 (predicción correcta de "sarna")

Falsos Positivos (FP): 0 (clasificadas como "sarna" pero eran otra cosa)

Falsos Negativos (VN): 0 (no hay casos de "sarna" clasificados como otra cosa)

Cálculos:

1. **Precisión:**

$$Precision = \frac{VP}{VP + VN}$$

$$Precision = \frac{9}{9 + 0} = 1.00$$

2. **Sensibilidad:**

$$Sensibilidad = \frac{VP}{VP + FN}$$

$$Sensibilidad = \frac{9}{9 + 0} = 1.00$$

3. **Especificidad:**

Para calcular la especificidad, consideramos las clases "oídio" y "sana" como negativas respecto a "sarna".

Verdaderos Negativos (VN): 9 (oídio) + 11 (sana) = 20

Falsos Positivos (FP): 0

$$Especificidad = \frac{VN}{VN + FP}$$

$$Especificidad = \frac{20}{20 + 0} = 0.85$$

Tabla 1. Resumen de métricas de evaluación

	OIDIO	SANA	SARNA
Precision =	**0,75**	**0,785714286**	**1**
Sensibilidad =	**1**	**1**	**1**
Especificidad =	**0,86956522**	**0,857142857**	**1**

Gráficos de pérdida y métricas

Los gráficos de pérdida muestran una tendencia descendente en las pérdidas de caja (box loss), clasificación (cls loss) y distribución focal (dfl loss) tanto en el conjunto de entrenamiento como de validación. Esto indica que el modelo converge adecuadamente y mejora su rendimiento a medida que avanza el entrenamiento.

Las curvas de precisión y recall también muestran un comportamiento estable y alto desempeño, especialmente en el rango final de epochs. El mAP50 alcanzó valores cercanos a 0.92, lo cual es muy satisfactorio para este tipo de tareas de detección.

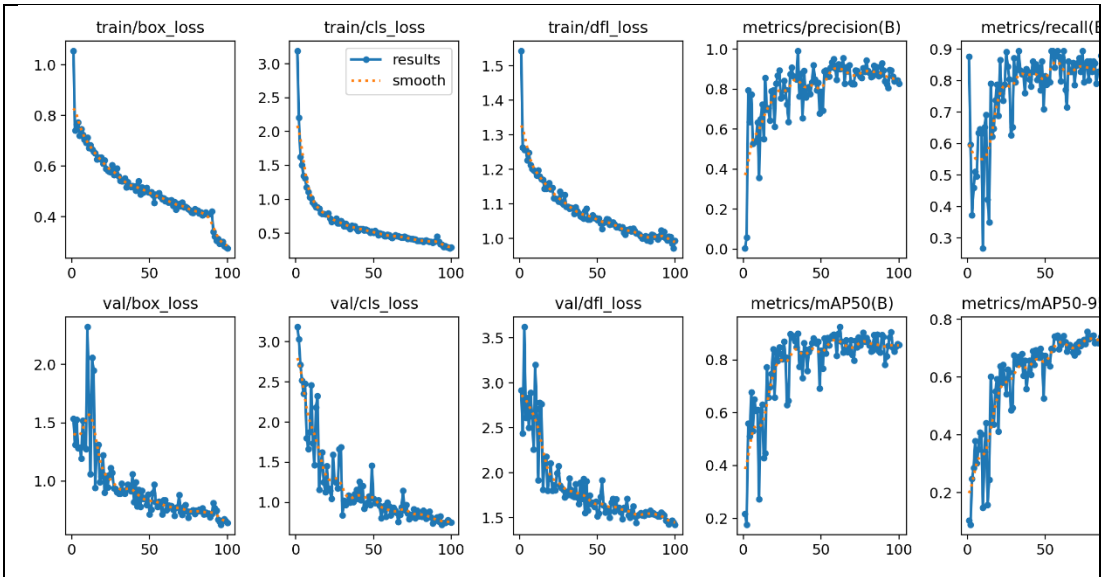


Figura 4. Gráficos de pérdida y métricas

Imágenes de los resultados

En la Figura 3 y Figura 4 se muestran algunas imágenes representativas del conjunto de validación, donde se puede observar el desempeño del modelo al momento de detectar y segmentar visualmente las diferentes condiciones foliares. En dichas imágenes, las cajas delimitadoras generadas por el modelo se superponen sobre las hojas clasificadas como sanas o enfermas, lo cual permite validar tanto la precisión espacial como la capacidad de reconocimiento semántico del sistema desarrollado.

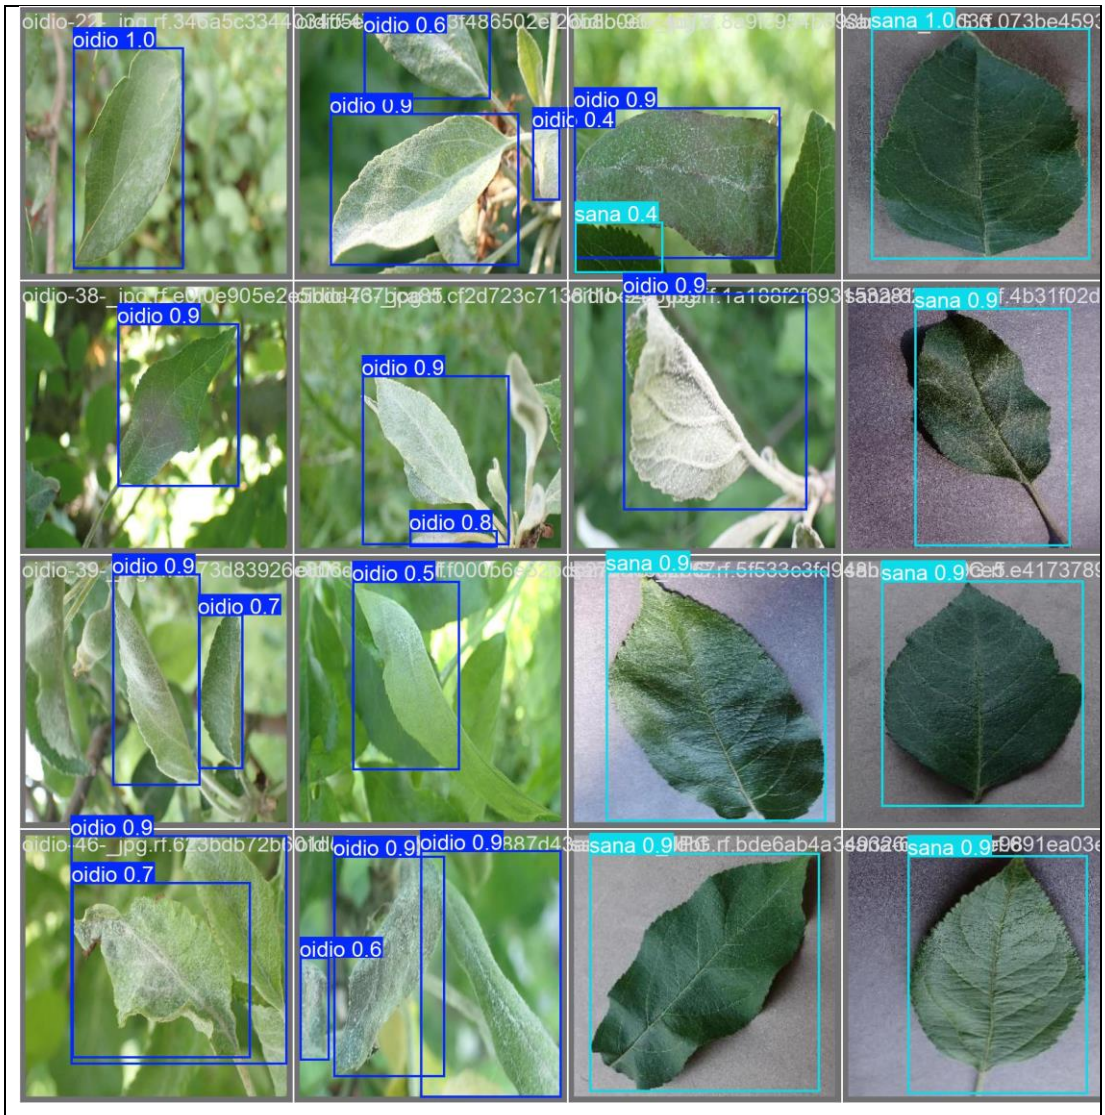


Figura 5. Imágenes de validación.

Discusión

El uso de modelos basados en inteligencia artificial, como YOLOv12, ha demostrado ser una herramienta poderosa para la detección de enfermedades en cultivos. En particular, el modelo desarrollado en este estudio logró una alta precisión, sensibilidad y especificidad en la identificación de hojas sanas y afectadas por oídio y sarna. Estos resultados son consistentes con estudios previos que han explorado la aplicación de redes neuronales convolucionales (CNN) en problemas de detección de enfermedades vegetales (Redmon & Farhadi, 2018).

Uno de los aspectos clave del presente trabajo es la importancia de la calidad de los datos de entrenamiento. La correcta anotación de las imágenes utilizando Roboflow garantizó que el modelo recibiera información precisa y bien estructurada, lo cual fue fundamental para obtener resultados confiables. Sin embargo, es necesario destacar que la calidad del modelo depende directamente de la cantidad y diversidad de los datos disponibles. Futuros estudios podrían beneficiarse de conjuntos de datos más grandes y diversificados, incluyendo imágenes capturadas bajo diferentes condiciones ambientales y en diferentes etapas de desarrollo de las enfermedades.

Además, la alta sensibilidad y especificidad observadas en el caso de la sarna (1.0) sugieren que el modelo tiene un excelente rendimiento en la detección de esta enfermedad. Sin embargo, la precisión ligeramente menor en el caso del oídio (0.75) indica que aún existen oportunidades para mejorar la capacidad del modelo en la diferenciación de esta enfermedad, especialmente en casos donde los síntomas sean menos evidentes.

Comparación con trabajos previos

La literatura muestra que otros estudios han utilizado modelos basados en CNN para la detección de enfermedades en plantas, con resultados similares en términos de precisión y sensibilidad (Singh et al., 2020). Sin embargo, muchos de estos trabajos se enfocan en enfermedades específicas o en cultivos distintos. El presente estudio

destaca por abordar dos enfermedades comunes en manzanos (oídio y sarna) simultáneamente, lo que aumenta su relevancia práctica en la gestión fitosanitaria.

El uso de data augmentation fue crucial para mejorar la generalización del modelo, permitiendo que este sea más robusto ante variaciones en las condiciones de captura de las imágenes. Las técnicas de rotación, flip, desenfoque y ruido ayudaron a simular diferentes escenarios en los que podrían presentarse las enfermedades en campo.

Sin embargo, la matriz de confusión revela algunos puntos débiles:

El modelo tiende a confundir las imágenes de oídio con hojas sanas, lo que podría deberse a similitudes visuales entre estas dos clases.

Existe un bajo número de falsos positivos en la clase "background", lo que sugiere que el modelo puede ser sensible a la presencia de elementos no relevantes en las imágenes.

CAPÍTULO IV

CONCLUSIONES Y RECOMENDACIONES

4.1 CONCLUSIONES

El presente trabajo tuvo como objetivo desarrollar un modelo basado en inteligencia artificial para la detección de enfermedades como oídio y *Venturia inaequalis* (sarna) en hojas de manzana, utilizando imágenes digitales. A lo largo del estudio, se lograron cumplir los objetivos generales y específicos propuestos, lo que se resume a continuación:

Cumplimiento de los Objetivos Específicos

Creación de una base de datos de imágenes: Se creó una base de datos compuesta por imágenes de hojas de manzana tanto sanas como afectadas por oídio y sarna. Las imágenes fueron etiquetadas cuidadosamente utilizando la plataforma Roboflow, asegurando la precisión y consistencia de las anotaciones. Este conjunto de datos fue dividido en conjuntos de entrenamiento, validación y prueba, permitiendo evaluar el desempeño del modelo de manera robusta.

Entrenamiento del modelo de inteligencia artificial: Se utilizó el algoritmo YOLOv12 para entrenar un modelo capaz de clasificar imágenes de hojas en tres categorías: hojas sanas, hojas afectadas por oídio y hojas afectadas por sarna. El modelo fue ajustado mediante técnicas de optimización de hiperparámetros, lo que mejoró su capacidad de detección y clasificación.

Evaluación del desempeño del modelo: El modelo entrenado fue evaluado en términos de precisión, sensibilidad y especificidad. Los resultados obtenidos muestran un alto desempeño en la detección de las enfermedades estudiadas:

Precisión:

Oídio: 0.75

Sana: 0.785714286

Sarna: 1.0

Sensibilidad:

Oídio: 1.0

Sana: 1.0

Sarna: 1.0

Especificidad:

Oídio: 0.869556522

Sana: 0.857142857

Sarna: 1.0

Estos resultados indican que el modelo es altamente efectivo en la identificación de hojas sanas y enfermas, especialmente en el caso de la sarna, donde alcanzó una precisión, sensibilidad y especificidad perfectas. En el caso del oídio, aunque la precisión es ligeramente menor, la sensibilidad y especificidad son muy altas, lo que sugiere que el modelo puede detectar correctamente la mayoría de las hojas afectadas por esta enfermedad.

Contribuciones del Trabajo

Este estudio contribuye significativamente al campo de la agricultura inteligente al proporcionar una solución automatizada y precisa para la detección temprana de enfermedades en cultivos de manzana. La implementación de técnicas de aprendizaje profundo, como YOLOv12, demuestra su potencial en aplicaciones agronómicas, permitiendo reducir costos y tiempo asociados con el monitoreo manual de cultivos. Además, la base de datos creada durante este proyecto puede ser útil para futuros estudios relacionados con la detección de enfermedades en plantas.

Limitaciones del Estudio

Aunque los resultados obtenidos son prometedores, es importante reconocer algunas limitaciones del presente trabajo:

Tamaño del conjunto de datos: El tamaño del conjunto de datos utilizado podría ser insuficiente para abordar todas las variaciones posibles en condiciones ambientales y etapas de desarrollo de las enfermedades. Esto podría limitar la generalización del modelo en entornos reales.

Variabilidad ambiental: Las condiciones de iluminación, ángulos de captura y presencia de sombras pueden influir en la precisión del modelo. Futuros trabajos deberían considerar estas variables para mejorar la robustez del sistema.

Complejidad de las enfermedades: Ambas enfermedades presentan síntomas similares en etapas tempranas, lo que puede dificultar la diferenciación. Aunque el modelo mostró buen desempeño, futuras investigaciones podrían explorar técnicas más avanzadas para mejorar la discriminación entre enfermedades similares.

4.2 RECOMENDACIONES

Ampliación del conjunto de datos: Se recomienda seguir recolectando imágenes bajo diferentes condiciones ambientales (luz natural variable, ángulos distintos, etapas tempranas de infección) para mejorar la capacidad de generalización del modelo y reducir el sobreajuste.

Uso de técnicas de aumento de datos (data augmentation): Es recomendable aplicar técnicas como rotación, escala, cambio de brillo e incluso métodos avanzados como Mosaic o MixUp durante el entrenamiento, con el fin de aumentar la diversidad del conjunto de datos y mejorar la robustez del modelo.

Implementación en dispositivos móviles o drones: Una posible extensión del sistema es su implementación en dispositivos portátiles o drones equipados con cámaras, permitiendo una detección automatizada en campo real. Esto facilitaría el monitoreo constante del estado sanitario de los cultivos sin necesidad de intervención manual intensiva.

Incorporación de modelos más ligeros para inferencia rápida: Si se busca desplegar el modelo en dispositivos con recursos limitados, se recomienda explorar versiones más ligeras de YOLO, como YOLOv8s o YOLO-NAS, que ofrecen buenos resultados manteniendo tiempos de inferencia bajos.

Integración con sistemas de alerta temprana: Se sugiere integrar el modelo desarrollado dentro de un sistema de alerta temprana que notifique al agricultor cuando se detecten niveles altos de infección, ayudando a tomar decisiones informadas sobre el manejo fitosanitario.

Expansión a otras enfermedades y cultivos: Una posible línea futura de investigación sería ampliar el modelo para identificar otras enfermedades comunes en manzanos u otros cultivos frutales, lo cual incrementaría la utilidad del sistema desarrollado.

Validación en condiciones reales de campo: Es recomendable realizar pruebas en condiciones reales de producción agrícola, ya que esto permitirá evaluar el desempeño del modelo en entornos no controlados, donde pueden surgir factores como sombras, hojas superpuestas o variaciones climáticas.

Uso de aprendizaje por transferencia: Para acelerar futuros entrenamientos, se puede aprovechar el modelo preentrenado desarrollado en este estudio como punto de partida, utilizando aprendizaje por transferencia para nuevos conjuntos de datos relacionados.

Análisis de interpretabilidad del modelo: Se recomienda aplicar técnicas como Grad-CAM para visualizar las regiones de interés en las imágenes que el modelo utiliza para tomar decisiones. Esto ayuda a validar si el modelo está aprendiendo características relevantes desde el punto de vista agronómico.

Documentación y disponibilidad del dataset: Sería muy valioso publicar el conjunto de datos utilizado (previa autorización y cumplimiento de normativas) junto con el código del modelo entrenado, para fomentar la reproducibilidad y el desarrollo de trabajos similares en otras regiones o cultivos.

C. MATERIALES DE REFERENCIA

Referencias Bibliográficas

Analuisa-Aroca, I., Vergara-Romero, A., Betzaida, I., & Almeida, P. (2023). Convolutional neural networks ResNet-50 for weevil detection in corn kernels Redes neuronales convolucionales ResNet-50 para la detección de gorgojo en granos de maíz. *Scientia Agropecuaria*, *14*(3), 385–394. https://doi.org/10.17268/sci.agropecu.2023.034

Facuy-Delgado, J., Molina-Oleas, W., & Ortega-Ponce, L. (2022). Revisión sistemática de los algoritmos para detección de enfermedades fúngicas en el arroz. *MQRInvestigar* , *6*(4), 608–620. https://doi.org/10.56048/MQR20225.6.4.2022.608-620

Huanca Namuche, A. A., Terry Alvarado, B. S., & García Estrella, C. (2025). Vista de Redes neuronales convolucionales para la clasificación de la mancha negra en los cítricos. *Sapiens International Multidisciplinary Journal*, *2*, 1–20. https://doi.org/https://doi.org/10.71068/4x9sw526

Li, T., Zhang, L., & Lin, J. (2024). Precision agriculture with YOLO-Leaf: advanced methods for detecting apple leaf diseases. *Frontiers in Plant Science*, *15*, 1452502. https://doi.org/10.3389/FPLS.2024.1452502/BIBTEX

Mora, E. A. H., Huitrón, V. G., Rangel, H. R., & Sosa, L. E. A. (2021). Detección de enfermedades foliares con arquitecturas de redes neuronales convolucionales. *RINDERESU*, *5*(1), 18–40. http://rinderesu.com/index.php/rinderesu/article/view/46

Plant Pathology 2021 - FGVC8. (2021, March 15). Https://Www.Kaggle.Com/Datasets/Itselif/Comprehensive-Plant-Disease-Dataset.

Roboflow: Computer vision tools for developers and enterprises. (2025). https://roboflow.com/

Rodríguez Torres, D. F., Garzón Alfonso, W., & Santiago Cely, C. P. (2023). Consejo DireCtivo De la esCuela Colombiana De ingeniería. *Revista de La Escuela Colombiana de Ingeniería*, *133*, 23–31. http://www.escuelaing.edu.co/revista.htm

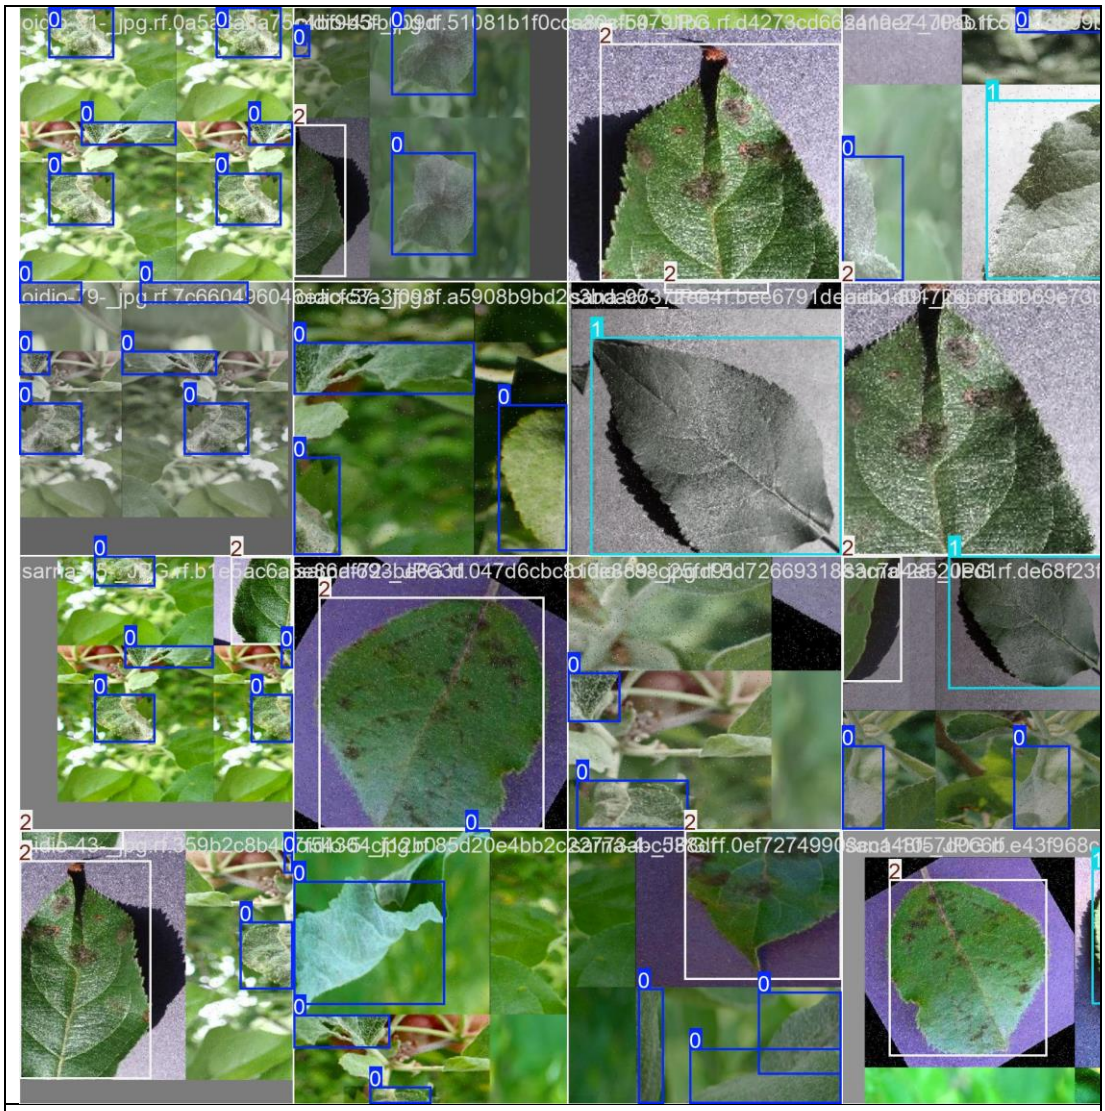
Saldaña Valenzuela, S. (2023). Vista de Inteligencia Artificial: Detección de enfermedades en el cultivo de frijol. *Revista Naturaleza, Sociedad Y*

Ambiente, *10*, 53–58. https://revistacunsurori.com/index.php/revista/article/view/87/115

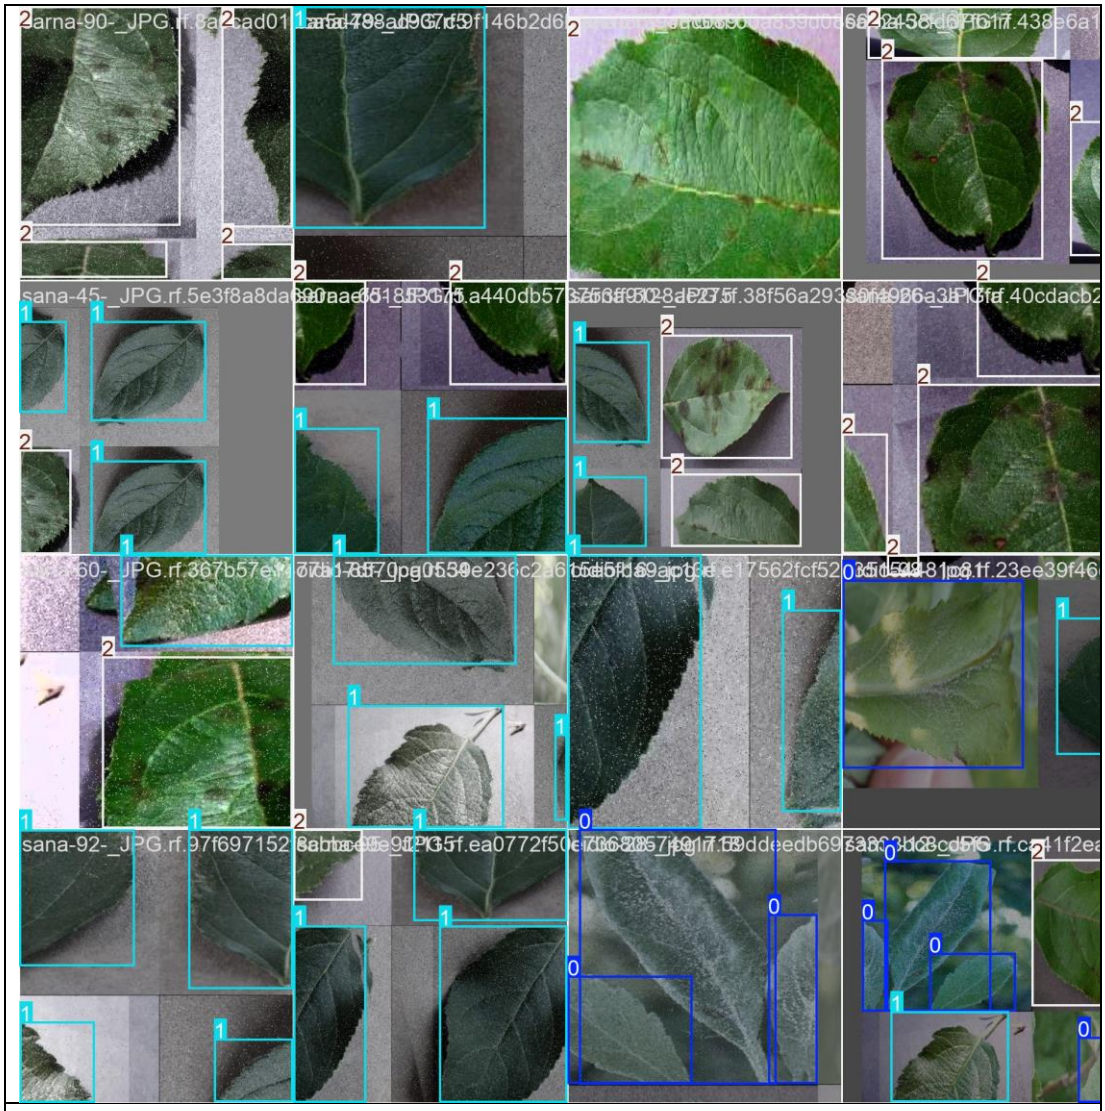
Tian, Y., Ye, Q., & Doermann, D. (2025). *YOLOv12: Attention-Centric Real-Time Object Detectors*. https://doi.org/10.0

Wang, Y., Wang, Y., & Zhao, J. (2022). MGA-YOLO: A lightweight one-stage network for apple leaf disease detection. *Frontiers in Plant Science*, *13*, 927424. https://doi.org/10.3389/FPLS.2022.927424/BIBTEX

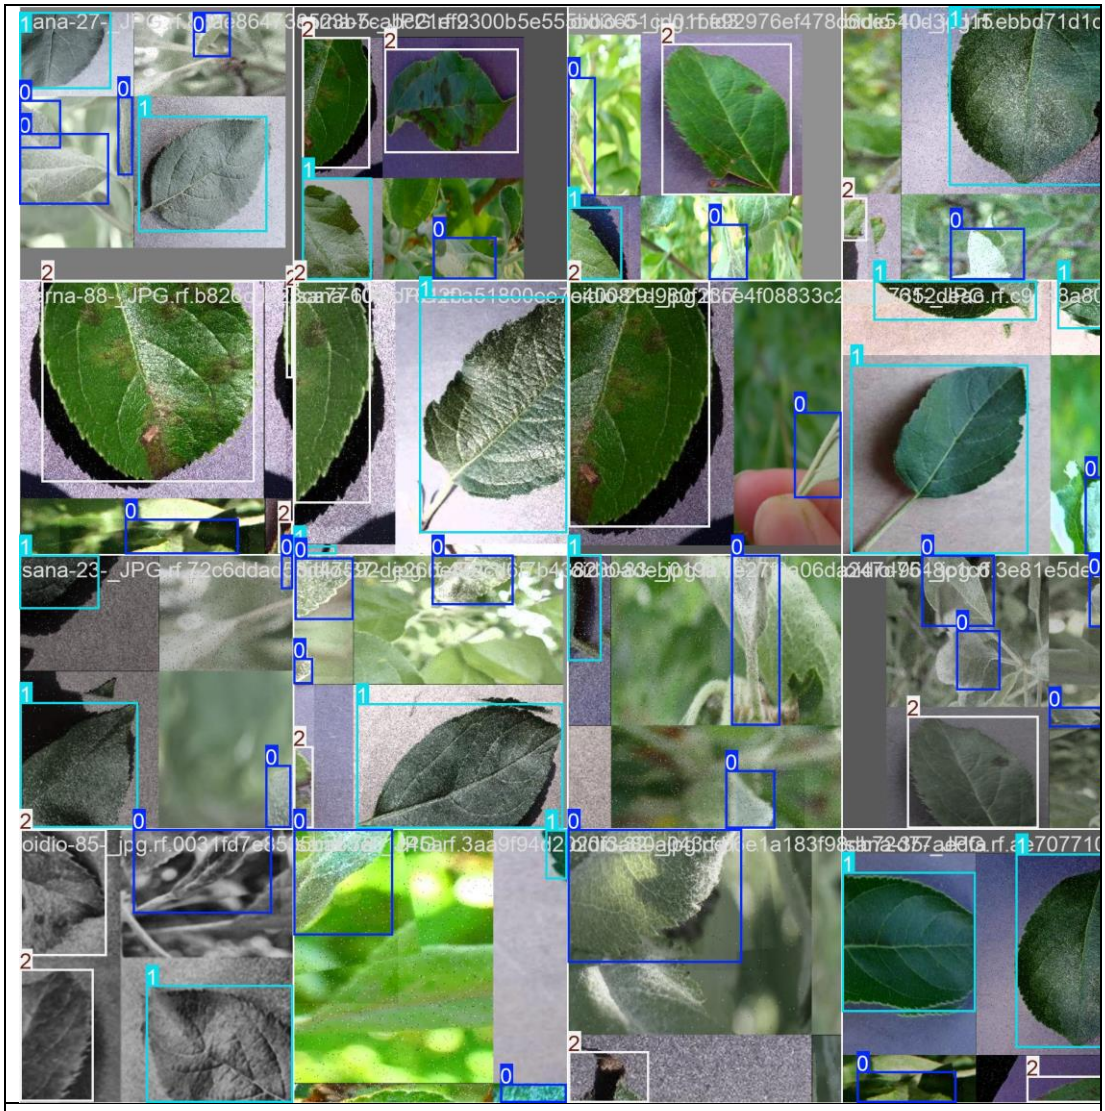
ANEXOS



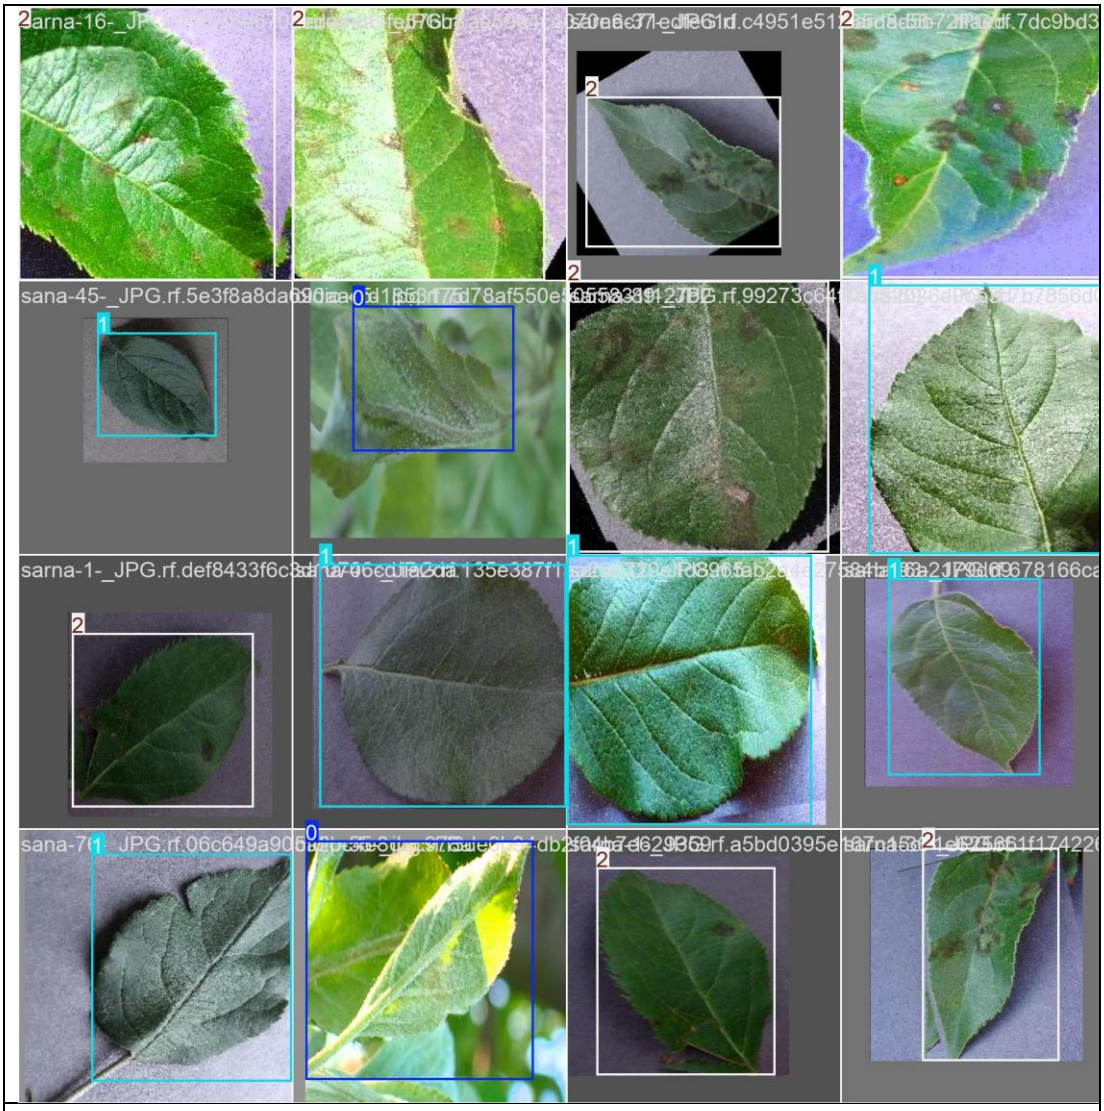
Etiquetado de las imágenes



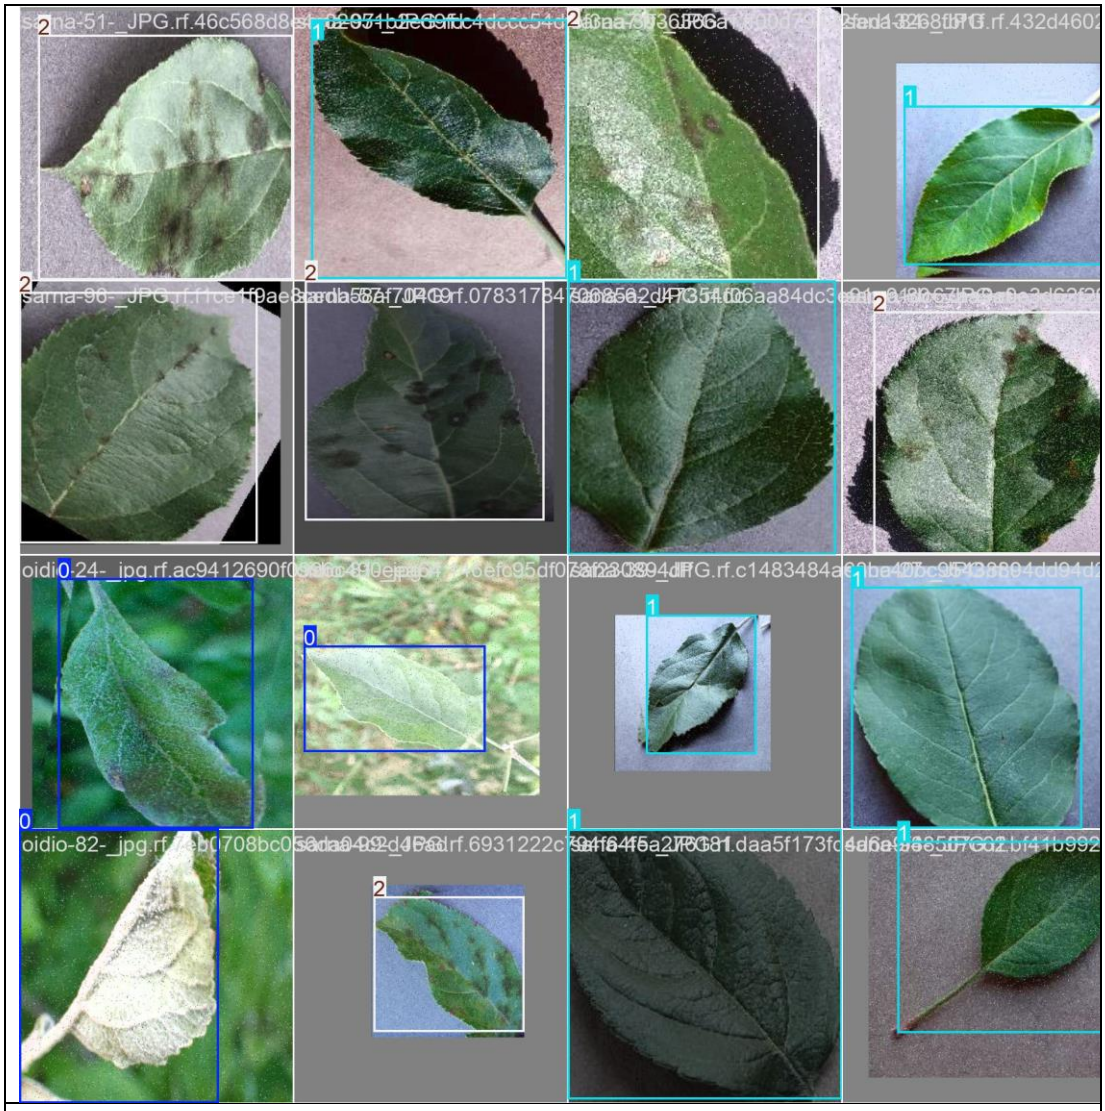
Etiquetado de las imágenes



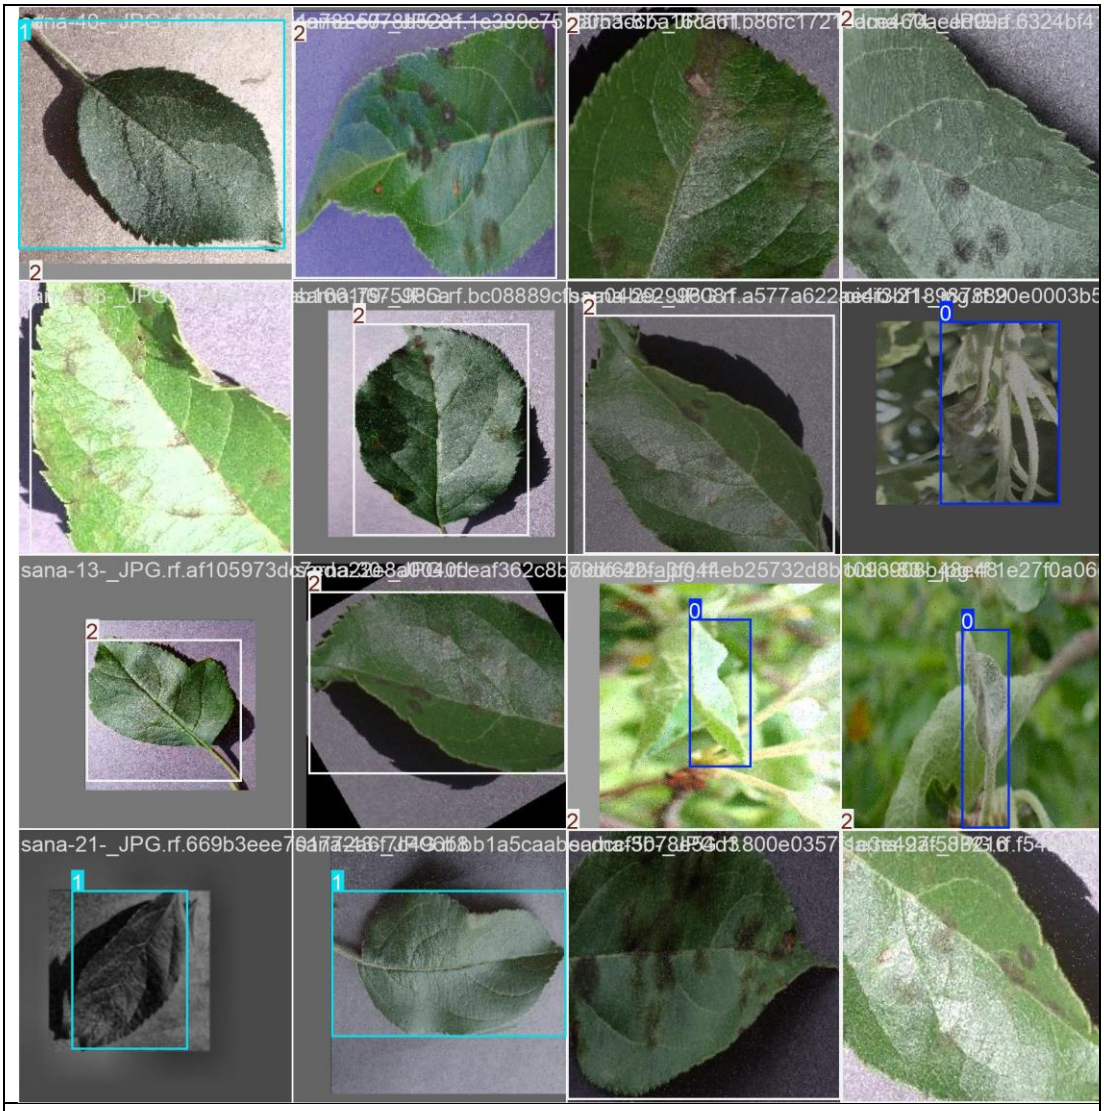
Etiquetado de las imágenes



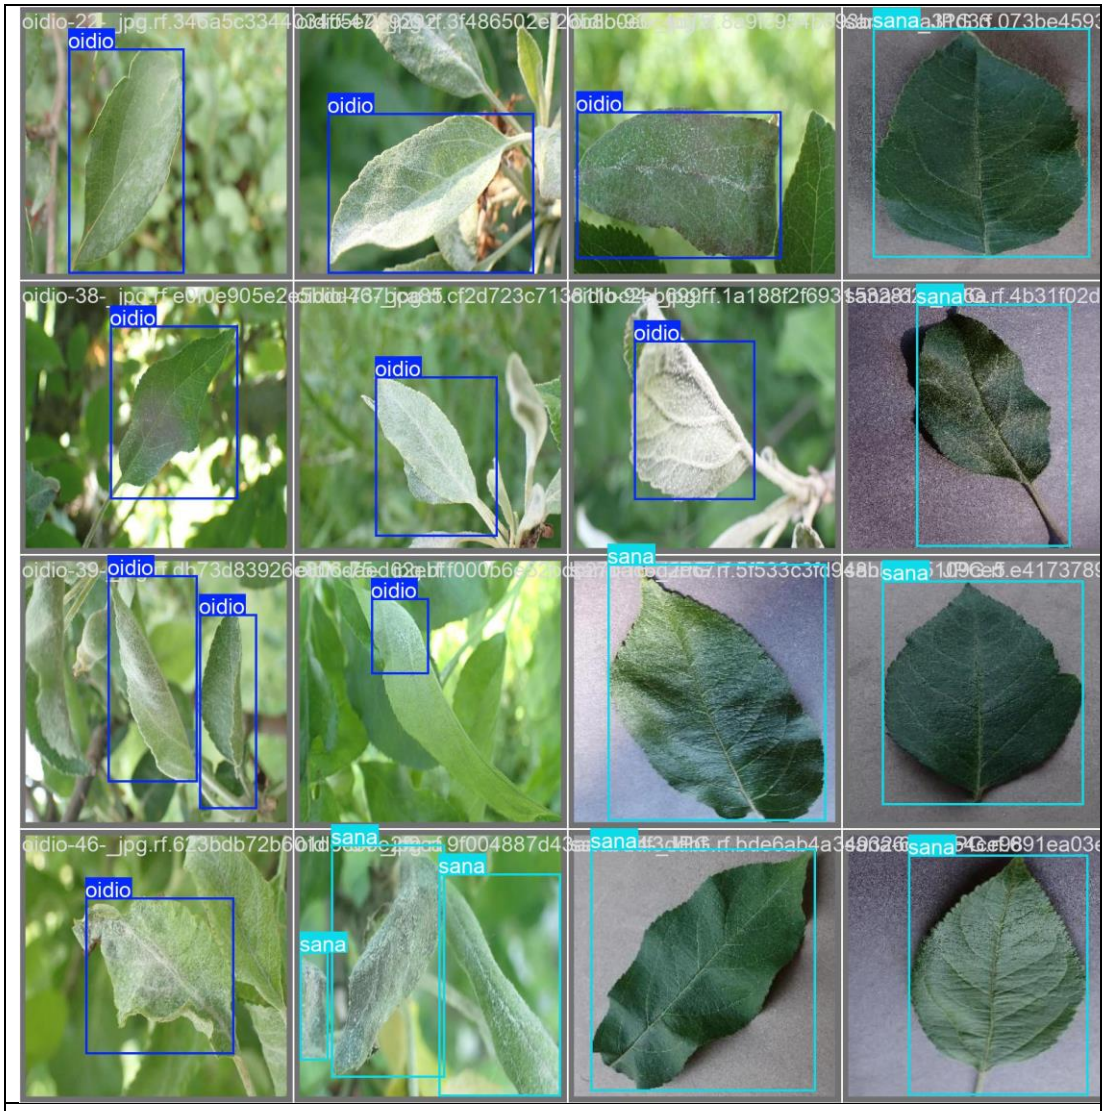
Etiquetado de las imágenes



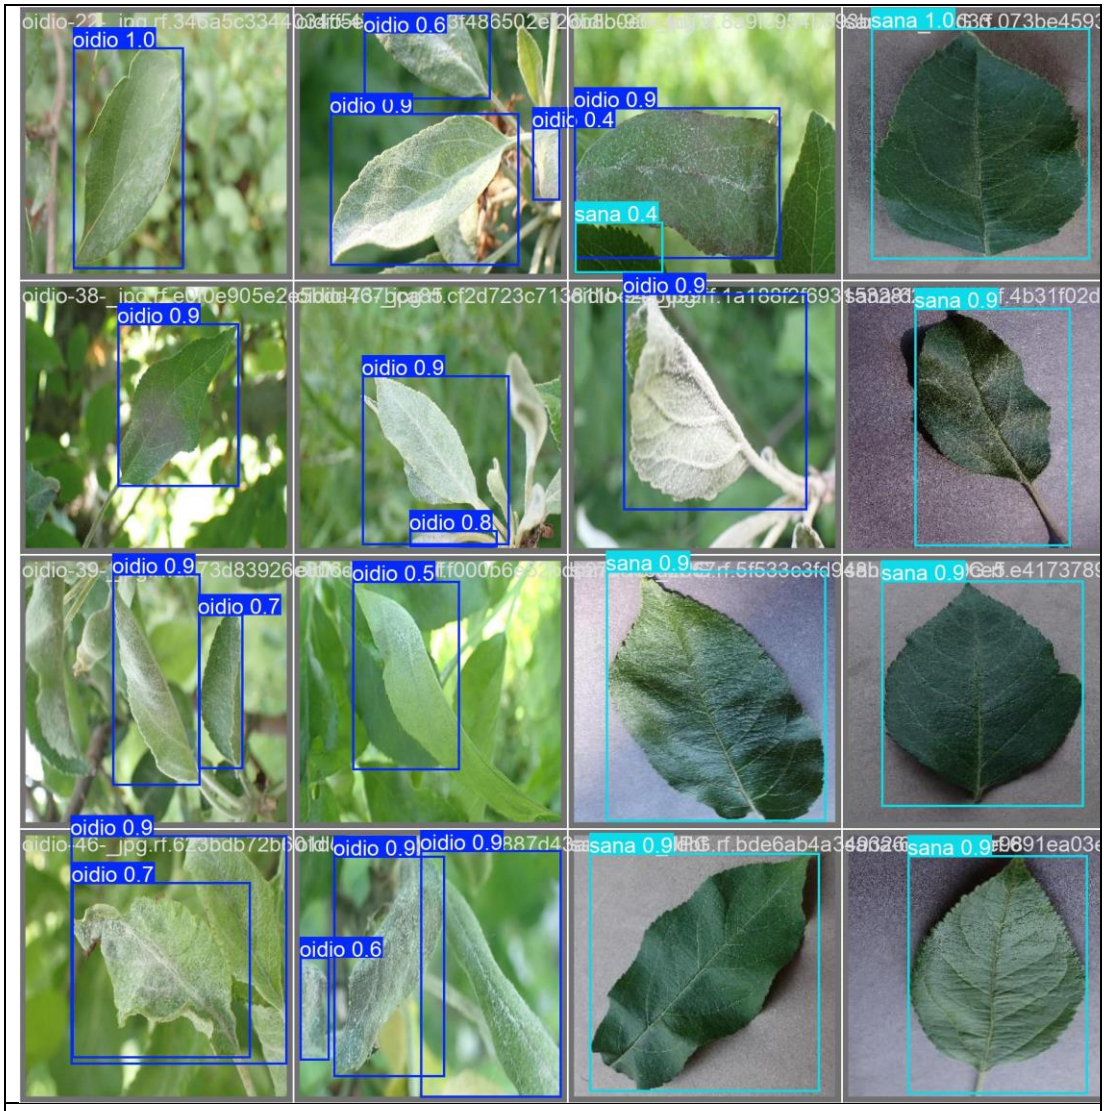
Etiquetado de las imágenes



Etiquetado de las imágenes



Dataset de validación con imágenes



Dataset de validación con imágenes