

**Escuela Agrícola Panamericana, Zamorano**

**Departamento de Ciencia y Producción Agropecuaria**

**Ingeniería Agronómica**



**Proyecto Especial de Graduación**

**Desarrollo de una Herramienta Digital para la Detección de  
Enfermedades en Hojas de Tomate (*Solanum lycopersicum* L.) Mediante  
Aprendizaje Automático**

**Estudiante**

**Roger Orlando Gaitán López**

**Asesores**

**Carolina Avellaneda, Ph.D.**

**Josue Molina, Ph.D.**

**Honduras, noviembre 2024**

**Autoridades**

**SERGIO ANDRÉS RODRÍGUEZ ROYO**

Rector

**ANA M. MAIER ACOSTA**

Vicepresidenta y Decana Académica

**CELIA O. TREJO RAMOS**

Directora del Departamento de Ciencia y Producción Agropecuaria

**JULIO NAVARRO**

Secretario General

## Contenido

Índice de Cuadros .....	4
Índice de Figuras .....	5
Resumen .....	6
Abstract .....	7
Introducción .....	8
Materiales y Métodos .....	11
Conjunto de Datos .....	11
Lenguaje de Programación .....	14
Modelos de Redes Neuronales .....	15
Resultados y Discusión .....	18
Conclusiones .....	27
Recomendaciones .....	28
Referencias .....	29

### Índice de Cuadros

Cuadro 1 Comparación general entre modelos EfficientNetb5 y YOLOv8 previo al entrenamiento ..	11
Cuadro 2 Enfermedades de tomate del conjunto de datos y su agente causal .....	14
Cuadro 3 Comparación general entre modelos EfficientNetb5 y YOLOv8 después del entrenamiento para la detección de enfermedades en hojas de tomate .....	25

## Índice de Figuras

Figura 1 Muestreo aleatorio del conjunto de datos de enfermedades de hojas de tomate modelo.	12
Figura 2 Muestreo del conjunto de datos de enfermedades en hojas de tomate modelo YOLOv8. A) Saludable B) Tizón Temprano y C) Mancha anillada del tomate .....	13
Figura 3 Estructura o distribución representativa de una red neuronal .....	16
Figura 4 Resultados de la etapa de entrenamiento y validación modelo EfficientNetB5 usado para la detección de enfermedades en hojas de tomate .....	19
Figura 5 Matriz de confusión o de resultados de detección de enfermedades en hojas de tomate en tiempo real modelo EfficientNetB .....	19
Figura 6 Demostración de predicción bajo conjunto de prueba modelo EfficientNetB5 para detección de enfermedades en hojas de tomate .....	20
Figura 7 Métricas de evaluación de la detección de enfermedades en hojas de tomate bajo conjunto de prueba modelo EfficientNetB5 .....	20
Figura 8 Resultados de la etapa de entrenamiento y validación modelo YOLOv8 para la detección de enfermedades en hojas de tomate .....	22
Figura 9 Matriz de confusión o de resultados de detección de enfermedades en hojas de tomate en tiempo real modelo .....	22
Figura 10 Métricas de evaluación de la detección de enfermedades en hojas de tomate bajo conjunto de prueba modelo YOLOv8 .....	23
Figura 11 Demostración de predicción bajo conjunto de prueba modelo YOLOv8 para detección de enfermedades en hojas de tomate .....	24

## Resumen

El cultivo de tomate (*Solanum lycopersicum* L.) es actualmente uno de los cultivos de hortalizas más importantes a nivel mundial y constituye un producto principal en Honduras debido a su alto valor económico y nutricional. La producción puede verse disminuida por factores fitosanitarios adversos, por lo que el diagnóstico correcto y temprano es clave para implementar un plan de manejo adecuado. Por ello, es necesario contar con una herramienta que permita a los agricultores identificar el tipo de enfermedad que afecta a su cultivo mediante el uso de tecnología agrícola. Este estudio evaluó, mediante aprendizaje automático, dos técnicas de redes neuronales: EfficientNetB5 y YOLOv8, que fueron capaces de detectar enfermedades en hojas de tomate. Para el conjunto de datos, se recopilaron 50,000 imágenes con origen del dataset de PlantVillage y se sometieron a diversas técnicas de aumento para mejorar la robustez, incrementando tanto la cantidad como la calidad de las imágenes. Los distintos modelos lograron identificar nueve enfermedades en las hojas de tomate: Tizón tardío, Tizón temprano, Mancha de la hoja por Septoria, Virus del rizado amarillo del tomate, Mancha bacteriana, Mancha anillada, Virus del mosaico del tomate, Moho de la hoja y Moho polvoriento. Siendo el modelo EfficientNetB5 el que presentó los mejores resultados debido a su alto grado de precisión.

*Palabras clave:* Aprendizaje automatizado, conjunto de datos, redes neuronales

### **Abstract**

The production of tomatoes (*Solanum lycopersicum* L.) is currently one of the most important vegetable crops worldwide and is a principal commodity in Honduras due to its high economic and nutritional value. Production can be diminished by adverse phytosanitary factors, making correct and early diagnosis key to implementing an appropriate management plan. Therefore, it is necessary to have a tool that allows farmers to identify what type of disease is affecting their crop through the use of agricultural technology. Using machine learning, the study evaluated two neural network techniques: EfficientNetB5 and YOLOv8, which were capable of detecting diseases in tomato leaves. For the dataset, 50,000 images source from the PlantVillage dataset were collected and subjected to various augmentation techniques for greater robustness, increasing both the number and quality of images. The different models were able to identify nine diseases in tomato leaves: Late blight, Early blight, Septoria leaf spot, Tomato yellow leaf curl virus, Bacterial spot, Target spot, Tomato mosaic virus, Leaf mold, and Powdery mildew. With the EfficientNetB5 model the one that presented the best results due to its high degree of accuracy.

*Keywords:* Dataset, Machine learning, Neural networks

## Introducción

El cultivo de tomate (*Solanum lycopersicum* L.) es una de las hortalizas más consumidas a nivel mundial, representando un alto impacto nutricional y cultural, lo que lo cataloga como un cultivo de alto valor. Su uso diversificado en la forma en que se consume diariamente lo convierte en uno de los cultivos más importantes económicamente, aportando vitaminas, minerales y antioxidantes en su ingesta (Fundación hondureña de investigación agrícola [FHIA], 2023). Su relevancia en la industria agrícola ha ido en aumento, al igual que su producción. Se estima que la producción de tomate ha aumentado un 70% desde comienzos del siglo hasta la actualidad, siendo uno de los cultivos más importantes de Honduras, país clave en la productividad de la región, representando el 18.7% de la producción total de Centroamérica, (Organización para la Agricultura y la Alimentación [FAO], 2022).

A pesar del aumento en la productividad a nivel mundial, esta se ve mermada por los desafíos fitosanitarios que enfrentan los productores. Los patógenos de plantas representan un enorme problema para la seguridad alimentaria global y son variables en el tiempo, el espacio y en sus características genéticas (Strange y Scott, 2005) La identificación temprana de la enfermedad que afecta al cultivo es de suma importancia, ya que permite desarrollar un plan de manejo específico para cada organismo. El tiempo es un factor crucial al manejar problemas fitosanitarios, pues la detección temprana de enfermedades ayuda a controlar su propagación, facilita las prácticas de manejo y garantiza beneficios económicos asociados (Wang et al., 2019)

La identificación de enfermedades es un proceso que requiere diferentes recursos, como personal especializado y acceso a laboratorio, para realizar los análisis necesarios que permitan identificar al organismo observado en campo. Sin embargo, a pesar de las metodologías tradicionales existentes para la detección de enfermedades, no todos los productores pueden acceder a ellas debido a cuestiones logísticas y/o económicas. Estimar con precisión la incidencia y severidad de las

enfermedades y comprender sus impactos en la producción agrícola es esencial para mejorar el manejo de cultivos y la eficacia de los fungicidas (Mahlein, 2016), por lo tanto, es necesaria una herramienta de fácil acceso que permita a los productores detectar las enfermedades que afectan a sus cultivos de manera rápida y confiable.

Es crucial un enfoque específico en la detección de enfermedades en tomates para garantizar resultados y recomendaciones adecuadas que permitan a los agricultores realizar un manejo fitosanitario efectivo. Existen varias técnicas para la identificación de enfermedades en tomate desarrolladas en la región, como el uso de claves multi entrada propuestas por (Luna, 2019), que permiten identificar enfermedades mediante una serie de preguntas. No obstante, los resultados pueden verse afectados por el sesgo subjetivo del usuario, lo que limita su precisión y confiabilidad en algunos casos.

El uso de redes neuronales representa un recurso innovador en esta tarea, como el modelo propuesto por (Erazo y Uema, 2020), en donde se logró la identificación adecuada del tizón temprano (*Alternaria solani*) y de la mancha foliar por septoria (*Septoria lycopersici*). Las redes neuronales son una técnica de aprendizaje artificial que se basa en emular la estructura sináptica del cerebro, de manera simplificada. Estas permiten el aprendizaje de diferentes tareas en base a un conjunto de datos previamente procesado. Una red neuronal está conformada por nodos o neuronas artificiales distribuidos en capas: una capa de entrada, una o varias capas ocultas y una capa de salida, donde cada neurona está conectada entre sí, (International Business Machines Corporation [IBM], 2023). Según (Google Cloud, 2024), el aprendizaje automático consiste en proporcionar cantidades considerables de datos a un algoritmo o modelo para que este aprenda y mejore sus resultados sin necesidad de programarlo de manera directa.

Para la realización de esta investigación se delimitó que el conjunto de datos a utilizar sería exclusivamente de enfermedades que afectan a las hojas de tomate, debido a la disponibilidad y practicidad de este tipo de datos. Se empleó un conjunto de datos que consta de diez clases: nueve clases de enfermedades y una clase sana. Una clase es un patrón u objeto que será clasificado por la red neuronal. El conjunto de datos fue obtenido de PlantVillage, una unidad de desarrollo e investigación de la Universidad Estatal de Pensilvania, cuyo propósito es apoyar a los pequeños agricultores a salir de la pobreza mediante el uso de tecnología e innovación (PlantVillage, 2023).

Con base en un conjunto de datos apropiado, se desarrollarán diferentes algoritmos de inteligencia artificial, que estarán constituidos por diversas técnicas de aprendizaje automático (ML), una rama de la inteligencia artificial que permite la creación de sistemas capaces de aprender datos, identificar patrones y realizar predicciones con mínima intervención humana (SAS, 2023). Se seleccionará el mejor modelo capaz de predecir enfermedades en hojas de tomate, basado en su precisión y resultados, lo que proporcionará la base para la creación de una aplicación móvil que permita a los agricultores una identificación práctica, fácil y rápida en el campo.

Los objetivos de esta investigación son: 1. Comparar diferentes técnicas de aprendizaje automático para identificar enfermedades en hojas de tomate 2. Desarrollar múltiples modelos de redes neuronales y evaluar su eficacia en la detección de enfermedades en hojas de tomate. 3. Crear una plataforma utilizando el modelo más preciso entrenado, permitiendo un diagnóstico fitosanitario confiable y validar la aplicación mediante pruebas de detección en tiempo real.

## Materiales y Métodos

### Conjunto de Datos

En el entrenamiento de los diferentes modelos, se empleó un conjunto de datos común. Un conjunto de datos es una colección estructurada de datos, organizada para ser analizada o procesada (Databricks, 2024). Estos datos pueden proceder de una o varias fuentes, según su naturaleza. En esta investigación se utilizaron dos conjuntos de datos específicos con origen de la organización PlantVillage, que tiene como objetivo fomentar el desarrollo de comunidades rurales en riesgo mediante la tecnología. El conjunto de datos base contiene más de 50,000 imágenes validadas de 14 cultivos distintos, incluidas hojas sanas e infectadas, tomadas en estaciones de investigación experimental asociadas a universidades de concesión de tierras en Estados Unidos, como Penn State, Florida State y Cornell (Hughes y Salathé, 2019) Sin embargo, para este estudio se emplearon únicamente los datos relacionados con el cultivo de tomate y sus respectivas enfermedades. Se decidió el uso de los siguientes modelos de redes neuronales debido a sus siguientes características, comparación general se observa en el Cuadro 1.

### Cuadro 1

*Comparación general entre modelos EfficientNetb5 y YOLOv8 previo al entrenamiento*

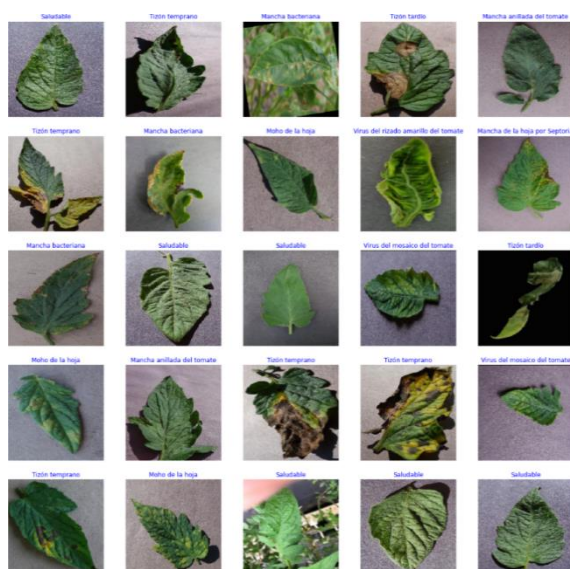
Modelo	Precisión / mAP	Ventajas	Desventajas
EfficientNetB3	Mayor a 95 % precisión	Alta precisión y uso eficiente de recursos computacionales	Mayor complejidad y mayor requisito de computo
YOLOv8	Alto mAP	Detección en tiempo real, identifica múltiples áreas afectadas por enfermedades en una misma hoja	Requiere anotaciones detalladas

Para el modelo EfficientNetB5, se recopiló un conjunto de datos exclusivo de tomate, al cual se le aplicaron técnicas de depuración para asegurar la compatibilidad durante la ejecución del entrenamiento. La versión final del conjunto de datos consta de más de 30,000 imágenes con 9 clases de enfermedades y 1 clase sana como se observa en Figura 1. Se implementaron técnicas avanzadas como inmersión de imágenes, corrección de gamma, inyección de ruido, aumento de color PCA, rotación y escalado, entre otras. Esto tiene como objetivo proporcionar al modelo datos robustos, que permitan la identificación en diferentes entornos, aumentando su versatilidad.

Las clases de enfermedades del conjunto de datos son: Tizón tardío, Saludable, Tizón temprano, Mancha de la hoja por Septoria, Virus del rizado amarillo del tomate, Mancha bacteriana, Mancha anillada del tomate, Virus del mosaico del tomate, Moho de la hoja, Oídio (o Moho polvoriento)

### Figura 1

*Muestreo aleatorio del conjunto de datos de enfermedades de hojas de tomate modelo.*

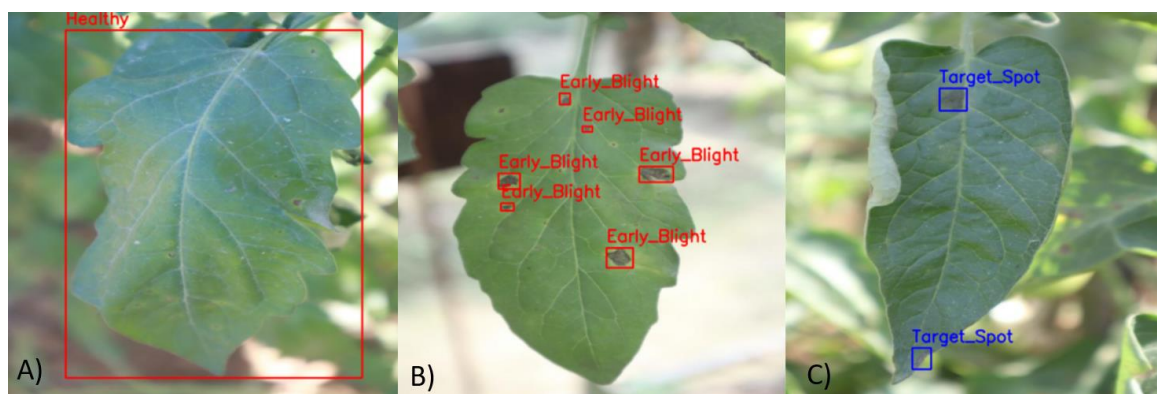


*Nota.* Tomado de PlantVillage (2023)

Para el modelo YOLOv8, se empleó un conjunto de datos adaptado para la detección de objetos, ya que, este es el formato requerido por YOLOv8. El conjunto de datos es diferente al descrito anteriormente (PlantVillage, 2023), pero representa un conjunto de datos valioso para la detección de enfermedades en hojas de tomate. El formato utilizado en la detección de objetos es diferente a las etiquetas utilizadas para clasificación de imágenes, ya que, se utilizan cajas delimitadoras, que encierran el objeto de interés, mostrando el área afectada como podemos en la Figura 2.

## Figura 2

*Muestreo del conjunto de datos de enfermedades en hojas de tomate modelo YOLOv8. A) Saludable B) Tizón Temprano y C) Mancha anillada del tomate*



La distribución de clases del conjunto de datos para YOLOv8 es la siguiente: Mancha bacteriana, Tizón temprano, Sano, Tizón tardío, Moho de la hoja, Mancha de la hoja, Mancha negra y Mancha anillada del tomate. Ambos conjuntos de datos cuentan con diferentes tipos de agentes causales de enfermedades, los cuales son descritos en el Cuadro 2.

## Cuadro 2

### *Enfermedades de tomate del conjunto de datos y su agente causal*

Tipo de enfermedad	Nombre común	Agente causal
Enfermedades causadas por hongos	Tizón Temprano	<i>Alternaria solani</i>
	Mancha de la hoja por Septoria	<i>Septoria lycopersici</i>
	Mancha anillada del tomate	<i>Corynespora cassiicola</i>
	Moho de la hoja	<i>Passalora fulva</i>
Enfermedades causadas por bacterias	Oídio (o Moho polvoriento)	<i>Erysiphe orontii</i>
	Mancha bacteriana	<i>Xanthomonas campestris pv vesicatoria</i>
Enfermedades causadas por virus	Virus del rizado amarillo del tomate	<i>Tomato yellow leaf curl virus (TYLCV)</i>
	Virus del mosaico del tomate	<i>Tomato mosaic virus</i>
Enfermedades causadas por Oomicetos	Tizón Tardío	<i>Phytophthora infestans</i>

## Lenguaje de Programación

Para poder programar y ejecutar un código, es necesario hacerlo en un lenguaje de programación, el cual está diseñado según su propósito y uso, existen diferentes lenguajes de programación con diferentes orientaciones según al sistema que están diseñados, como se Java, C++, R, Python entre otros. Para esta investigación se hará uso del lenguaje de programación Python el cual es ideal para trabajar en el campo de la inteligencia artificial. Python es un lenguaje de programación de gran uso a nivel mundial, esto se debe a su versatilidad, que permite la implementación de diferentes proyectos. Su programación orientada a objetos lo convierte en un lenguaje de alto nivel, interpretado y de propósito general. (Python, 2024) Fue elegido en este proyecto debido a su amplia cantidad de librerías especializadas en el procesamiento de imágenes y en el aprendizaje automatizado, como TensorFlow, Keras y Scikit-learn, que permiten el entrenamiento de modelos para la clasificación de imágenes. El código de este proyecto fue escrito en este lenguaje y ejecutado en el entorno de Jupyter Notebook, lo que ofrece un mejor control sobre la ejecución del código, además de permitir la experimentación y la facilidad para visualizar los resultados a medida que se

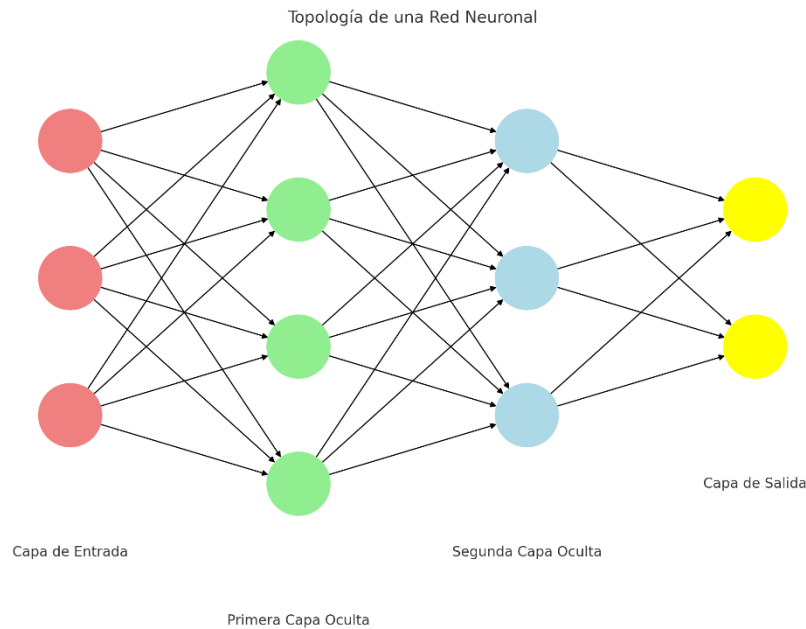
ejecuta, lo que hace más eficiente el proceso de entrenamiento y evaluación de un modelo de red neuronal.

### **Modelos de Redes Neuronales**

Las redes neuronales artificiales son estructuras sinápticas, las cuales imitan el funcionamiento del cerebro humano de manera simplificada. Según (Amazon Web Services [AWS], 2024), una red neuronal permite a las computadoras analizar datos como lo hace una persona. Las redes neuronales se componen de nodos interconectados (neuronas), dichos nodos están divididos en capas como podemos ver en Figura 3, las cuales procesan los datos de entrada múltiples veces, permitiendo que el aprendizaje artificial ocurra. La capa de entrada es como su nombre lo indica, la ventana donde los datos son recibidos por la red, su número de nodos dependerá directamente de las características o variables de los datos de entrada. La información del mundo exterior es recibida por esta capa para luego ser procesada por los diferentes datos (AWS, 2024). Luego siguen las capas ocultas, se denominan ocultas porque el usuario no tiene acceso a ellas, en cada capa oculta se realizan diferentes cálculos, para extraer las características de los datos, lo que permite la identificación de enfermedades en nuestro caso, el número de nodos de estas capas serán potencias de dos, por ejemplo 64, 128, 256, etc. Según las necesidades de la red y su complejidad estos números pueden variar. Finalmente, la capa de salida, siendo esta la última capa, su número de nodos dependerá del número de clases a clasificar en modelos de clasificación, por ejemplo, un conjunto de datos con 9 enfermedades y una clase sana, tendrá 10 nodos de salida, los cuales representaran una probabilidad de predicción, siendo el nodo de salida con mayor probabilidad, el resultado más confiable del modelo.

**Figura 3**

*Estructura o distribución representativa de una red neuronal*



Para poder evaluar el rendimiento de las redes neuronales, es necesario contar con métricas de evaluación que nos permitan medir el rendimiento de nuestro modelo en las diferentes etapas de su desarrollo, para así evaluar la efectividad al momento de realizar tareas, como la clasificación de una hoja enferma, respecto a una sana y el tipo de enfermedad que esta hoja contiene de ser el caso. Para evaluar redes neuronales para clasificación de imágenes se cuentan con las siguientes métricas según la naturaleza del modelo.

$$\text{Precisión entrenamiento} = \frac{\text{Número de predicciones correctas}}{\text{Número total de predicciones}} \quad [1]$$

$$\text{Pérdida} = - \sum_{i=1}^C y_i \times \log(\hat{y}_i) \quad [2]$$

$$\text{Precisión} = \frac{\text{Verdaderos positivos (VP)}}{\text{Verdaderos positivos (VP)} + \text{Falsos positivos (FP)}} \quad [3]$$

$$\text{Exhaustividad (Recall)} = \frac{\text{Verdaderos positivos (VP)}}{\text{Verdaderos positivos (VP)} + \text{Falsos Negativos (FN)}} \quad [4]$$

$$F1 - \text{Score} = 2 \times \frac{\text{Precisión} \times \text{Exhaustividad}}{\text{Precisión} + \text{Exhaustividad}} \quad [5]$$

$$mAP50 = \text{Promedio de APs a IoU} \geq 0.50 \quad [6]$$

$$mAP75 = \text{Promedio de APs a IoU} \geq 0.75 \quad [7]$$

YOLOv8 (*You Only Look Once*) es un modelo especializado en la detección de objetos, ya sea en imágenes o videos. Es un modelo de red neuronal convolucional (CNN). Dicho algoritmo fue propuesto por (Redmon et al., 2015), en donde los autores destacan la tarea de detección de objetos como una tarea de regresión y no de clasificación tradicional, por regresión se refiere a que el algoritmo predice las coordenadas de las cajas delimitadoras que encierran al objeto de interés. Además de la detección, tiene funciones adicionales como segmentación y clasificación. Este modelo destaca por su capacidad para implementarse en tiempo real, lo que amplía sus aplicaciones, desde sistemas de seguridad hasta el desarrollo de cosechadoras automáticas, ya que, permite el seguimiento de objetos a lo largo de un video. Se decidió utilizar este modelo en esta investigación debido a su capacidad para localizar de manera precisa las áreas afectadas en las hojas de tomate, lo cual es fundamental para un diagnóstico certero.

EfficientNetB5: Es un modelo de red neuronal convolucional (CNN) que forma parte de la familia EfficientNet, desarrollada por el equipo de Google AI, (Tan y Le V, 2019). Dicho modelo es uno de los más potentes de la familia, contando con más de 28,000,000 de parámetros, siendo entrenado con el conjunto de datos ImageNet el cual cuenta con más de 14, 000, 000 de imágenes, presentando resultados muy buenos en la detección de objetos.

## Resultados y Discusión

Los resultados obtenidos del entrenamiento con diferentes arquitecturas de redes neuronales fueron satisfactorios, ya que lograron un rango de detección aceptable, lo que los convierte en una fuerte alternativa para la implementación en la detección de enfermedades en hojas de tomate. Los modelos entrenados fueron EfficientNetB5 y YOLOv8. Cada modelo se entrenó en la plataforma Kaggle, la cual ofrece un poder de cómputo gratuito limitado que hizo posible el desarrollo de esta investigación. EfficientNetB5 resultó ser el modelo con mejor rendimiento y adaptabilidad para la tarea de detección.

EfficientNetB5: El modelo basado en redes convolucionales demostró una mayor precisión en la tarea de detección, alcanzando una precisión final del 97.8% (Figura 4). Este alto rendimiento se debe a la calidad y cantidad de los datos de entrenamiento, lo cual evitó el sobreajuste del modelo y, por lo tanto, previno un sesgo al trabajar con datos nuevos, mostrando resultados excelentes en las pruebas de predicciones de la matriz de confusión (Figura 5). En la Figura 6 se muestran las etiquetas predichas y las reales. Los resultados de evaluación, que se consideran adecuados para este tipo de modelos, se pueden observar en la Figura 7.




**Figura 6**

*Demostración de predicción bajo conjunto de prueba modelo EfficentNetB5 para detección de enfermedades en hojas de tomate*



**Figura 7**

*Métricas de evaluación de la detección de enfermedades en hojas de tomate bajo conjunto de prueba modelo EfficentNetB5*

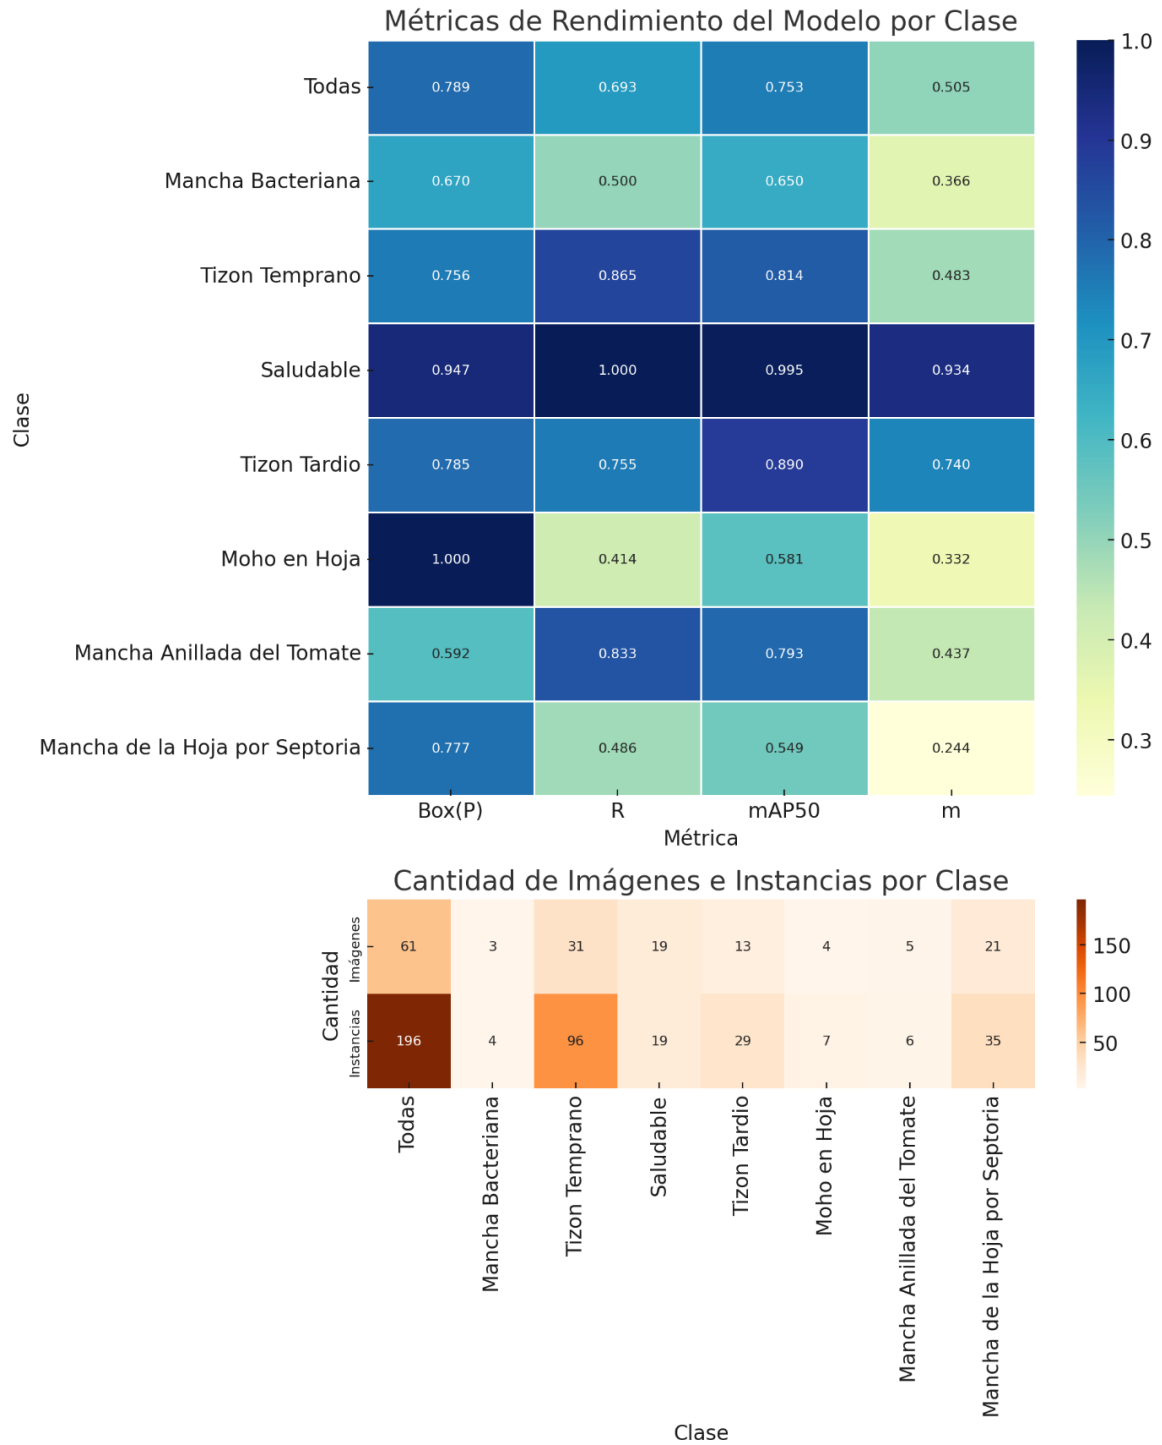


YOLOv8: Este modelo, especializado en la detección de objetos en tiempo real, no solo clasifica las hojas de tomate como saludables o enfermas, sino que también identifica las áreas específicas de la hoja afectadas por la enfermedad. Durante su entrenamiento y validación, el modelo YOLOv8 alcanzó un Mean Average Precision (mAP) al 50% de IoU (mAP50) de 75.41% (Figura 8). Esta métrica mide la precisión promedio de las predicciones cuando la intersección sobre la unión (IoU) entre la predicción y el objeto real es al menos del 50%. La métrica mAP50-95, que promedia las precisiones para IoU en el rango del 50% al 95%, proporciona una visión más detallada del rendimiento en diferentes niveles de superposición; el modelo logró un 50.59% en esta métrica (Figura 10). La precisión, con un valor de 0.82, indica la proporción de verdaderos positivos sobre todas las predicciones positivas, mientras que el recall, con un valor de 0.69, mide la proporción de verdaderos positivos detectados sobre el total de objetos reales. Estos resultados reflejan la capacidad del modelo para detectar y clasificar múltiples zonas afectadas dentro de una hoja de manera simultánea. Como se observa en la Figura 9, la matriz de confusión ilustra tanto los aciertos como las áreas de confusión en la clasificación de enfermedades de hojas de tomate. La clase "Tizón Temprano" tiene un desempeño notable, con 87 de 114 instancias clasificadas correctamente, lo que refleja un nivel de precisión aceptable en la detección de esta enfermedad. Sin embargo, se observan errores en clases como "Mancha por Septoria," donde 8 instancias fueron clasificadas erróneamente como "Tizón Temprano." Estos resultados indican que el modelo presenta un rendimiento adecuado en algunas categorías, aunque aún podrían explorarse ajustes para mejorar su precisión en la identificación de ciertas enfermedades.



**Figura 10**


*Métricas de evaluación de la detección de enfermedades en hojas de tomate bajo conjunto de prueba modelo YOLOv8*



En la figura 11, podemos observar los resultados de una predicción utilizando YOLOv8, donde se delimita cada zona afectada de la hoja, al mismo tiempo que se identifica el tipo de enfermedad que la afecta. En el Cuadro 3 se comparan los resultados obtenidos mediante distintas técnicas de aprendizaje automatizado. Se evaluaron métricas como la precisión/mAP, así como las ventajas y desventajas de cada modelo. Esta comparación permite identificar las capacidades y limitaciones específicas de cada técnica para la detección de enfermedades en hojas de tomate.

### Figura 11

*Demostración de predicción bajo conjunto de prueba modelo YOLOv8 para detección de enfermedades en hojas de tomate*



### Cuadro 3

*Comparación general entre modelos EfficientNetb5 y YOLOv8 después del entrenamiento para la detección de enfermedades en hojas de tomate*

Modelo	Precisión / mAP	Ventajas	Desventajas
EfficientNetB5	97.8% precisión	Predice 10 clases correctamente	Requiere mayor capacidad de cómputo
YOLOv8	Alto mAP50 y moderado mAP50-90	Detección en tiempo real; identifica múltiples áreas afectadas por enfermedades en una sola hoja	Solo predice correctamente 3 clases

Los resultados obtenidos en esta investigación, donde el modelo EfficientNetB5 alcanzó una precisión del 98% en la clasificación de diez clases de enfermedades, son comparables a estudios previos que utilizaron el mismo enfoque. Por ejemplo, (Hridoy et al., 2022), entrenaron EfficientNetB5 para el reconocimiento de enfermedades en hojas de betel, logrando una precisión del 98,84%. Asimismo, (Bhandari et al., 2023), emplearon el modelo EfficientNetB5 preentrenado en un conjunto de datos de 11,000 imágenes de hojas de tomate con diez clases de enfermedades—incluyendo saludable, mancha bacteriana, tizón temprano, mancha foliar de Septoria, tizón tardío, moho de la hoja, araña roja de dos manchas, virus del mosaico, mancha anillada del tomate y virus del rizado amarillo de la hoja y obtuvieron una precisión del 99%, lo que avala la eficacia del modelo en este tipo de aplicaciones.

Finalmente, Lu (2023) reportó una precisión del 99,2% al entrenar EfficientNetB5 en un conjunto de datos con 38 categorías diferentes de enfermedades en diversas plantas. Estos hallazgos refuerzan la validez y precisión del modelo entrenado en esta investigación, demostrando la capacidad de EfficientNetB5 para clasificar eficazmente múltiples enfermedades en distintos cultivos. En conjunto, estos estudios respaldan el uso de EfficientNetB5 como una herramienta robusta para el

diagnóstico de enfermedades en plantas, alineándose con los resultados exitosos obtenidos en nuestro trabajo.

En base a la comparación entre los diferentes modelos y sus resultados, en donde se concluye que el modelo a utilizar será EffientNetB5 por su precisión superior en comparación a las demás técnicas abordadas. Para el despliegue de la herramienta se hará uso de la plataforma streamlit, la cual es alternativa que permite desarrollar páginas web con facilidad y poco poder de cómputo.

## Conclusiones

La base de datos cuenta con 9 enfermedades que se manifiestan en las hojas de tomate, y todas han sido programadas para ser detectadas correctamente.

YOLOv8 fue capaz de detectar correctamente las clases Saludable, tizón temprano y tizón tardío.

El modelo EfficientNetb5 tiene la capacidad de realizar predicciones con un alto nivel de precisión, permitiendo un diagnóstico eficiente de las 9 enfermedades bajo las cuales fue entrenado.

La implementación del modelo EfficientNetb5 obtuvo los resultados satisfactorios, permitiendo detecciones en tiempo real de hojas afectadas.

### **Recomendaciones**

Expandir el conjunto de datos con imágenes tomadas en laboratorio como en campo, para aumentar la profundidad y robustez de los datos.

Incrementar el número de clases o enfermedades del conjunto de datos, añadiendo enfermedades de interés regional.

Trabajar en la implementación de un servidor privado para el alojamiento y funcionamiento del modelo.

Desarrollar en distintas plataformas la aplicación del modelo para detección de enfermedades, aumentando la disponibilidad de esta herramienta.

## Referencias

- Amazon Web Services. (2024). *¿Qué es una red neuronal?* <https://aws.amazon.com/es/what-is/neural-network/>
- Bhandari, M., Shahi, T. B., Neupane, A. y Walsh, K. B. (2023). Botanicx-AI: Identificación de enfermedades de las hojas de tomate mediante un modelo de aprendizaje profundo basado en explicaciones. *Journal of Imaging*, 9(2), 53. <https://doi.org/10.3390/jimaging9020053>
- Databricks. (2024). *Conjunto de datos*. <https://www.databricks.com/glossary/what-is-dataset>
- Erazo, J. y Uema, K. (2020). *Redes neuronales para la identificación de enfermedades en el cultivo de tomate (Solanum lycopersicum L.) en Honduras* [Proyecto especial de graduación, Escuela Agrícola Panamericana Zamorano, Honduras]. [bdigital.zamorano.edu. https://bdigital.zamorano.edu/server/api/core/bitstreams/81ce1ae9-66c9-4f5e-b25f-62c55c013745/content](https://bdigital.zamorano.edu/server/api/core/bitstreams/81ce1ae9-66c9-4f5e-b25f-62c55c013745/content)
- Fundación hondureña de investigación agrícola (2023). Programa de hortalizas. [http://www.fhia.org.hn/descargas/informes\\_tecnicos/inf\\_Programa\\_de\\_Hortalizas-2023.pdf](http://www.fhia.org.hn/descargas/informes_tecnicos/inf_Programa_de_Hortalizas-2023.pdf)
- Google Cloud. (2024). *¿Qué es el aprendizaje automático?* <https://cloud.google.com/learn/what-is-machine-learning>
- Hridoy, R. H., Tarek Habib, M., Sadekur Rahman, M. y Uddin, M. S. (2022). Reconocimiento de enfermedades de la planta de betel basado en redes neuronales profundas mediante clasificación de imágenes de hojas. *Evolutionary Computing and Mobile Sustainable Networks*, 116, 227–241. [https://doi.org/10.1007/978-981-16-9605-3\\_16](https://doi.org/10.1007/978-981-16-9605-3_16)
- Hughes, D. y Salathé, M. (2019). Un repositorio de acceso abierto de imágenes sobre sanidad vegetal para permitir el desarrollo de diagnósticos móviles de enfermedades. <https://arxiv.org/pdf/1511.08060v2>
- International Business Machines Corporation. (2023). *¿Qué es una red neuronal?* <https://www.ibm.com/es-es/topics/neural-networks>
- Lu, Q. (2023). Un enfoque para la clasificación de enfermedades en las hojas. [https://thesai.org/Downloads/Volume14No10/Paper\\_112-An\\_Approach\\_for\\_Classification\\_of\\_Diseases\\_on\\_Leaves.pdf](https://thesai.org/Downloads/Volume14No10/Paper_112-An_Approach_for_Classification_of_Diseases_on_Leaves.pdf)
- Luna, E. (2019). *Elaboración de un prototipo de aplicación electrónica para la identificación de las enfermedades más comunes del cultivo de tomate (Solanum lycopersicum L.) en Honduras* [Proyecto especial de graduación, Escuela Agrícola Panamericana Zamorano, Honduras]. [bdigital.zamorano.edu. https://bdigital.zamorano.edu/server/api/core/bitstreams/e16d76c4-b4d8-4753-944b-08bc3ea26da4/content](https://bdigital.zamorano.edu/server/api/core/bitstreams/e16d76c4-b4d8-4753-944b-08bc3ea26da4/content)
- Mahlein, A.-K. (2016). Detección de enfermedades de las plantas mediante sensores de imágenes: Paralelismos y demandas específicas para la agricultura de precisión y el fenotipado de plantas. *Plant Disease*, 100(2), 241–251. <https://doi.org/10.1094/PDIS-03-15-0340-FE>

- Organización para la Agricultura y la Alimentación. (2022). *Datos sobre alimentación y agricultura*. <https://www.fao.org/faostat/en/#home>
- PlantVillage. (2023). *Ayudamos a los pequeños agricultores de África, Asia y las Américas a adaptarse al cambio climático*. <https://plantvillage.psu.edu/>
- Python. (2024). *Python*. <https://www.python.org/>
- Redmon, J., Divvala, S., Girshick, R. y Farhadi, A. (2015, 8 de junio). *Sólo se mira una vez: detección unificada de objetos en tiempo real*. <http://arxiv.org/pdf/1506.02640>
- SAS. (2023). *Aprendizaje automático*. [https://www.sas.com/es\\_mx/insights/analytics/machine-learning.html](https://www.sas.com/es_mx/insights/analytics/machine-learning.html)
- Strange, R. N. y Scott, P. R. (2005). Enfermedades vegetales: Una amenaza para la seguridad alimentaria mundial. *Annual Review of Phytopathology*, 43(1), 83–116. <https://doi.org/10.1146/annurev.phyto.43.113004.133839>
- Tan, M. y Le V, Q. (2019). EfficientNet: replanteando el escalamiento de modelos para redes neuronales convolucionales. *International Conference on Machine Learning*. <http://arxiv.org/pdf/1905.11946>
- Wang, D., Vinson, R., Holmes, M., Seibel, G., Bechar, A., Nof, S. y Tao, Y. (2019). Detección temprana del virus del marchitamiento moteado del tomate mediante imágenes hiperespectrales y eliminación de valores atípicos Redes generativas adversarias del clasificador auxiliar (OR-ACGAN). *Scientific Reports*, 9(1), 4377. <https://doi.org/10.1038/s41598-019-40066-y>