

# Development an artificial vision algorithm to detect the Alternaria Alternata disease in the citrus limon plant of the “Fundo Amada”

León León, Ryan Abraham<sup>1</sup> ; García Morales Nathaly Nicolle<sup>1</sup> ; Tirado Palacios, Elia Teresa<sup>1</sup> 

<sup>1</sup>Escuela de Ingeniería Industrial, Universidad Privada del Norte, Trujillo, Perú, ryan.leon@upn.edu.pe, N00199185@upn.pe, N00211869@upn.pe.

*Abstract- In the period from August to October 2023, lemon production in Peru was affected by unusual weather conditions linked to the El Niño phenomenon, generating a crisis. Factors such as the proliferation of pests and diseases, including penicillium, exocortis and mealy bug, as well as the threat of Alternaria Alternata, led to a decrease in availability and a 500% increase in the price of lemons. Faced with this scenario, Fundo Amada also experienced economic losses. To address Alternaria Alternata disease, an innovative approach was proposed by developing an artificial vision algorithm based on convolutional neural networks and Python. This algorithm demonstrated an efficiency of 95.8%, with only 5 errors out of a total of 120 samples, surpassing previous research with an accuracy of 98.3% and an effectiveness of 93.5%. The implementation of this system not only simplifies disease detection for farmers, but also lays the foundation for future research in agriculture and biological pest control. The visit to Fundo Amada validated the need for the project and highlighted its significant contribution to the development of innovative solutions to improve disease management in lemon plants and provide efficient responses to agricultural crises. This project stands out for its positive impact on the agricultural sector and its potential to drive future research in the field.*

**Keywords:** artificial vision, Python, Alternaria Alternata, neural networks

**Digital Object Identifier:** (only for full papers, inserted by LACCEI).  
**ISSN, ISBN:** (to be inserted by LACCEI).  
**DO NOT REMOVE**

# Desarrollo de un algoritmo de visión artificial para detectar la enfermedad *Alternaria Alternata* en la planta de limón cítrico del “Fundo Amada”

León León, Ryan Abraham<sup>1</sup> ; García Morales Nathaly Nicolle<sup>1</sup> ; Tirado Palacios, Elia Teresa<sup>1</sup> 

<sup>1</sup>Escuela de Ingeniería Industrial, Universidad Privada del Norte, Trujillo, Perú, ryan.leon@upn.edu.pe, N00199185@upn.pe, N00211869@upn.pe.

**Resumen-** *En el periodo de agosto a octubre de 2023, la producción de limones en Perú se vio afectada por condiciones climáticas inusuales vinculadas al Fenómeno del Niño, generando una crisis. Factores como la proliferación de plagas y enfermedades, incluyendo penicillium, exocortis y la cochinilla algodonosa, así como la amenaza de la Alternaria Alternata, llevaron a una disminución en la disponibilidad y un aumento del precio del limón en un 500%. Ante este escenario, el Fundo Amada también experimentó pérdidas económicas. Para abordar la enfermedad de la Alternaria Alternata, se propuso un innovador enfoque mediante el desarrollo de un algoritmo de visión artificial basado en redes neuronales convolucionales y Python. Este algoritmo demostró una eficacia del 95.8%, con solo 5 errores de un total de 120 muestras, superando investigaciones previas con una precisión del 98.3% y una efectividad del 93.5%. La implementación de este sistema no solo simplifica la detección de enfermedades para los agricultores, sino que también sienta las bases para futuras investigaciones en agricultura y control biológico de plagas. La visita al Fundo Amada validó la necesidad del proyecto y destacó su contribución significativa al desarrollo de soluciones innovadoras para mejorar la gestión de enfermedades en plantas de limón y ofrecer respuestas eficientes a crisis agrícolas. Este proyecto destaca por su impacto positivo en el sector agrícola y su potencial para impulsar investigaciones futuras en el campo.*

Palabras claves: visión artificial, Python, *Alternaria Alternata*, redes neuronales

## I. INTRODUCCIÓN

En Perú, se cultiva limón de manera continua durante todo el año, pero es durante los meses de enero a junio cuando se registra el 60% de la producción nacional. En los últimos meses, en nuestro país, enfrentamos una crisis en la cosecha de limones. En las últimas semanas, muchas personas han tenido que reducir su consumo debido a un aumento del precio en un 500% causado por la falta de disponibilidad. Esto ha llevado a que los costos elevados de los limones provoquen un aumento en la inflación del país. Esta situación se debe a las lluvias y las condiciones climáticas inusuales causadas por el Fenómeno del Niño en los meses de abril, que han resultado en la proliferación de diferentes plagas y enfermedades, lo que ha generado su escasez en la actualidad. El fundo Amada no fue la excepción, puesto que la planta del limón está llena de

plagas y enfermedades como penicillium, exocortis, *Alternaria Alternata* y la cochinilla algodonosa, a causa del fenómeno del Niño. De todas estas plagas y enfermedades la más riesgosa y la que más abunda es la *Alternaria Alternata*, esta enfermedad es a causa de la humedad y de los riegos excesivos, y se nota por sus hojas arrugadas y amarillas, y empeoran conforme la planta se debilita hasta ponerse marrones, marchitarse y caer. La *Alternaria Alternata* debe ser tratada a tiempo por los agricultores y, sobre todo, estos deben saber que químicos aplicar para evitar su expansión. Por lo que se busca ejecutar un algoritmo de visión artificial para detectar esta enfermedad en la planta del limón y así poder diferenciarla de cualquier otra enfermedad y los agricultores sepan que métodos y tratamientos emplear exactamente. Por ende, en este trabajo se aprovechará la visión e inteligencia artificial. La visión artificial permite que las máquinas "vean" y procesan imágenes y videos de manera análoga a los seres humanos. Esta tecnología encuentra aplicación en diversos campos como seguridad, robótica, automatización industrial, control de calidad, diagnóstico médico y realidad aumentada [1]. Por otro lado, la inteligencia artificial engloba la capacidad de las máquinas y sistemas informáticos para llevar a cabo tareas que normalmente requieren habilidades humanas, la adquisición de conocimientos, la interpretación de información, el proceso lógico y la elección entre opciones [2]. Además, se utilizarán las redes neuronales convolucionales, un tipo de red neuronal profunda altamente efectiva en tareas de visión artificial como la categorización visual de imágenes y la identificación de objetos en una escena. [3]. Para implementar estos procesos, se utilizará Python, un lenguaje de programación versátil, de fácil aprendizaje y ampliamente empleado en diversos campos, desde desarrollo web y ciencia de datos hasta aprendizaje automático e inteligencia artificial [4]. Además, en este proyecto, se emplea la visión artificial para identificar la presencia de la enfermedad *Alternaria Alternata* en los limoneros, distinguiéndose de otras afecciones. El enfoque de la investigación se centra en este hongo fitopatógeno, ampliamente distribuido y responsable de la "mancha marrón", que se caracteriza por la formación de áreas necrosadas en las plantas. Esta enfermedad ha causado considerables pérdidas económicas en España. Actualmente, el método predominante de control implica el uso de productos químicos; no obstante, existe un interés creciente en desarrollar soluciones basadas en agentes de control biológico como alternativa para reducir la dependencia de sustancias químicas [5]. Asimismo, es una

enfermedad que resulta complicada de gestionar en variedades altamente susceptibles y en áreas donde ha estado presente durante varios años. Este patógeno presenta un breve período de incubación, manifestándose los síntomas entre 24 y 48 horas después de la infección, especialmente tras condiciones ambientales propicias. La enfermedad se propaga con eficacia en temperaturas ambientales que oscilan entre 23 y 27°C, y con una alta humedad relativa (85%) que favorece que la superficie de las hojas u otros órganos permanezca húmeda durante al menos 8-12 horas; estas condiciones son comunes en la primavera y otoño en nuestro país. Estas cualidades demandan la aplicación frecuente de fungicidas como medida preventiva durante los periodos de brotación y desarrollo de la fruta [6]. Eventualmente, en las hojas se generan inicialmente pequeñas manchas marrones que evolucionan con la formación de halos amarillos. Estas lesiones se propagan adoptando formas circulares o irregulares, extendiéndose para abarcar una parte considerable de la lámina. En casos de infestaciones graves, se produce la defoliación. En cuanto a los frutos, los síntomas inician como diminutas manchas oscuras, desarrollándose posteriormente en grandes lesiones negras o protuberancias corchosas. Dichas protuberancias pueden desprenderse, dejando cráteres en la superficie de la hoja. La fruta gravemente afectada tiende a caerse. [7] Por otro lado, como se sabe la inteligencia artificial es una herramienta que si bien en el momento que salió no tuvo el acogimiento esperado, es de gran utilidad en las manos correctas; subdividiendo los tipos de inteligencia artificial, este trabajo se enfocara en el uso de la visión artificial, un campo con grandes usos desde civiles hasta militares [8]. Hay diversos campos en los que las técnicas de visión artificial pueden ser implementadas con éxito, tales como la biología, medicina, seguridad, industria, robótica, geología, meteorología, cartografía, agricultura, entre otros. Implementar algoritmos de visión por computadora en estos diversos campos constituye un problema complejo que suscita gran curiosidad. Dichos algoritmos deben ser diseñados para exhibir características específicas de robustez, precisión y velocidad de cálculo, de manera que puedan hacer frente a las circunstancias particulares asociadas al problema que se busca resolver [9]. En la actualidad, el ámbito de la visión artificial está estrechamente vinculado con la inteligencia artificial, donde ya no se limita únicamente a la determinación de ciertos parámetros de una imagen, sino que implica que una computadora sea capaz de proporcionar una descripción de la imagen. Todo esto parte desde el procesamiento de imágenes, una etapa indispensable que posibilita la interpretación de imágenes o la captura de videos, permitiendo así mejorar el rendimiento de un algoritmo [10]. En este contexto, en una investigación previa en Trujillo, se implementó el uso de inteligencia artificial para identificar los daños ocasionados por plagas en cultivos de palto. El objetivo principal fue explorar y describir la información contenida en imágenes capturadas por un dron específico. Estas imágenes se sometieron a análisis digital utilizando herramientas como Anaconda Spyder y diversas bibliotecas para la identificación de objetos y la delimitación por tonalidades de colorA, junto

con Numpy para análisis basados en matrices. El modelo de predicción utilizado fue el algoritmo Random Forest, con el propósito de evaluar el estado de infección [11]. Por otro lado, en Colombia, en el sector de exportación, se está implementando un sistema basado en visión artificial para detectar plagas y enfermedades en crisantemos. Se realizaron ajustes y mejoras en parámetros como los tiempos de adquisición de imágenes y la reducción de ruido. Se analizaron las firmas espectrales de hojas de crisantemo en busca de señales de enfermedades o plagas. Una vez optimizado el sistema, se desarrolló una metodología para identificar muestras sanas o con enfermedades detectadas [12]. Así mismo en Colombia, se llevó a cabo una tesis sobre el desarrollo de un sistema de visión artificial para la detección de hongos en plantas de cannabis mediante redes neuronales en ambientes controlados [13]. Se implementó un sistema automático para detectar tres clases de hongos en cultivos de cannabis. Se tomaron imágenes de cambios en las hojas, como cambios de color o forma, y se procesaron para identificar patrones asociados con cada tipo de enfermedad y plaga. Sin embargo, los resultados no cumplieron las expectativas, ya que la precisión alcanzada fue del 75%, considerada insuficiente para una clasificación efectiva. Finalmente, como último antecedente se tiene que, en Chiclayo, se realizó un estudio de tesis sobre la "Utilización de técnicas de visión artificial para la detección automática de defectos externos del mango". La orientación se centra en la automatización para identificar imperfecciones superficiales en los mangos mediante información de color y textura en imágenes. El estudio logró una efectividad del 87.79% [14] Así pues, este proyecto es importante porque busca proponer una manera de detectar artificialmente la plaga denominada *Alternaria Alternata*, un hongo fitopatógeno ampliamente extendido que provoca la "mancha marrón" con síntomas de zonas necrosadas. Se desea hacer uso de redes neuronales que son un subconjunto de unidades llamadas neuronas artificiales que imitan la forma en la que las neuronas biológicas se señalan entre sí. Este tipo de redes neuronales convolucionales ya es usado para identificar diferentes plagas en diferente tipo de frutos [15]. Se utilizará un sistema de código abierto de YOLOv5, que es un modelo avanzado para la identificación de elementos en imágenes, creado por la comunidad de inteligencia artificial. Esta versión representa una evolución de la serie YOLO, reconocida por su habilidad para realizar la detección de objetos en tiempo real mediante un solo recorrido de la red neuronal a través de la imagen. YOLOv5 destaca por mejorar tanto la precisión como la eficiencia en comparación con sus predecesores, lo que lo ha convertido en una opción popular para aplicaciones de visión por computadora [16].

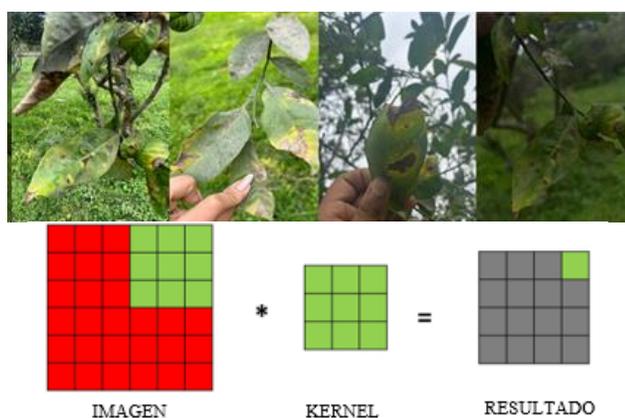
La visita al cultivo de limón en el fundo Amada dejó en evidencia la existencia de enfermedades en las plantas, siendo una de las principales causas que genera el robo de nutrientes. Es por eso, que la presente investigación tiene por justificación el desarrollo de un sistema de visión artificial que permita identificar la enfermedad *Alternaria Alternata* de la planta citrus limón para que así el agricultor tenga una herramienta

de apoyo y logre detectar con mejor precisión la enfermedad que ataca a la cosecha y además dejar un precedente para futuras investigaciones que den solución y mejoren la situación de la agricultura. El objetivo general es desarrollar un algoritmo de visión artificial para la detección de la enfermedad de la Alternaria Alternata en la planta citrus limón en el “Fundo Amada”, para lo cual se establecieron los siguientes objetivos específicos: trabajar en cualquier ambiente sea controlado o no y utilizar la red neuronal YOLOv5 existente para el proyecto.

## II. MATERIALES Y MÉTODOS

Para empezar, se observó el estado de las plantas de limón y se recolectaron fotografías en donde se pueda apreciar la presencia de la enfermedad Alternaria Alternata con el objetivo de observar la apariencia, forma y color de las hojas e identificar sus defectos, teniendo en cuenta que estas fotografías tengan la iluminación y enfoque necesarios y siendo captadas en distintas horas del día para lograr tener una mayor presión a la hora de usar el programa.

Para esta base de datos se recolectaron un total de 150 imágenes tomadas en diferentes horas del día, diversos cambios de luz, posiciones y ángulos, tal como se puede apreciar en la Figura 1. De las cuales, 50 imágenes fueron descartadas ya que no eran adecuadas para el procesamiento. Después de esto, las fotografías fueron recortadas y redimensionadas para que el entrenamiento no sea tan complejo. Luego se procederá a la asignación de etiquetas de las imágenes en donde se procede a la identificación gráfica de la Alternaria Alternata en las hojas de la planta de limón haciendo uso de la herramienta LabelMe. El etiquetado de las fotografías tiene como finalidad reconocer las características de las hojas en buen estado y las infectadas. Las características de las hojas que se recopilan son el color, la forma y textura. Asimismo, los principales rasgos para identificar las hojas infectadas por la Alternaria Alternata son manchas marrones o negras y hojas arrugadas o amarillentas.



Alternaria Alternata a las 8:00 pm  
 Figura 1. Alternaria Alternata a las 12:00 pm  
 Alternaria Alternata a las 4:00 pm  
 Alternaria Alternata a las 6:00 pm

Se hará uso de las redes neuronales convolucionales (CNN), las cuales procesan sus capas de manera que imita el funcionamiento del córtex visual del cerebro humano, con el objetivo de identificar diversas características en las entradas. Esta CNN cuenta con múltiples capas ocultas especializadas dispuestas en una jerarquía. En este contexto, las primeras capas se encargan de detectar propiedades o formas elementales, y a medida que avanzamos en las capas, la red se especializa cada vez más, culminando en capas más profundas capaces de reconocer formas complejas, como rostros o siluetas [17]. La red neuronal necesita procesar un extenso conjunto de imágenes para identificar las características distintivas de cada objeto y, al mismo tiempo, lograr generalizar. Cada imagen se representa como una cuadrícula de píxeles con valores que oscilan entre 0 y 255, pero se normaliza en un rango de 0 a 1 para facilitar la interpretación por parte de la red neuronal [18].

Además, se hará uso de la integración del modelo YOLOv5 con la biblioteca OpenCV que facilita la obtención en tiempo real de los resultados de la detección [19]. YOLOv5 utiliza una variante de la arquitectura Darknet, llamada CSPDarknet53, como espinaza (backbone) de la red. Esta arquitectura se caracteriza por bloques de conexión y separación (CSP) que mejoran el flujo de datos a través de la red y promueven la eficiencia en el entrenamiento [20]. Los cuadros delimitadores, las etiquetas y el recuento total de hojas de la planta de limón detectadas se superponen en cada fotograma de la cámara, ofreciendo una herramienta efectiva para la evaluación constante de las hojas sanas y enfermas.

Para el proceso de entrenamiento de las redes neuronales, se emplea el lenguaje de programación Python, reconocido por su eficacia en el procesamiento de imágenes y vídeos. Su sintaxis clara y legible ha contribuido significativamente a su popularidad en la comunidad de desarrollo [21]. La fase inicial del entrenamiento de la red comienza con un análisis exhaustivo de todas las imágenes que cuentan con etiquetas adecuadas. El objetivo principal de este análisis es resumir las representaciones de las características presentes en las imágenes. Durante el proceso de entrenamiento, se realizará internamente una operación de convolución que aplicará una serie de filtros a las imágenes de las hojas del limonero. Esto se lleva a cabo para identificar las características y patrones relevantes asociados con la detección de los defectos causados por la enfermedad Alternaria Alternata, permitiendo diferenciar sus características de otras posibles enfermedades de la planta. A medida que el kernel se desplaza, se crea una nueva imagen que ha sido filtrada por él. Posteriormente a la convolución con el kernel, se implementa la función de activación [22].

Para imágenes en color, la operación de convolución se realiza de manera análoga a llevar a cabo tres convoluciones 2D separadas. La primera se aplica a la capa roja para detectar los bordes de la hoja, la segunda se aplica a la capa verde para identificar la textura, y la tercera se aplica a la capa azul para analizar los píxeles. En este contexto, el filtro o núcleo se emplea para reconocer patrones y características específicas de la hoja, tales como sus bordes, textura y forma.

Figura 2. Convolución de imágenes [23]

Tal como se observa en la figura 2, la convolución es un procedimiento iterativo, en donde el kernel contendrá un número equivalente de planos que la imagen de entrada, siendo un plano por cada canal de la imagen inicial, en cada ciclo, se realiza una convolución entre cada plano del kernel y su respectivo plano en la imagen en color y los resultados se suman generando un único valor [23]. La convolución de imágenes en nuestro proyecto tiene como finalidad la identificación de las características distintivas de la hoja del limonero a través del uso de un kernel especializado. Este kernel está diseñado para reconocer patrones que distinguen entre una hoja con la enfermedad de la Alternaria Alternata y una hoja normal sin enfermedad o con otro tipo de enfermedad, incluyendo elementos como texturas, bordes y la forma morfológica de la hoja.

Para nuestro proyecto, se debe tener en cuenta que se trabajará en un ambiente no controlado, ya que se harán las muestras y pruebas en el mismo Fondo, en donde se tomarán distintos escenarios para la recolección de las imágenes en distintas horas del día.

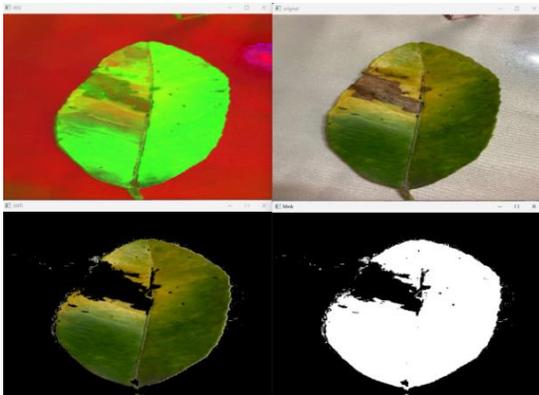


Figura 3. Convolución de imágenes de la planta de limón

Durante la fase de entrenamiento de la red neuronal, se realiza una convolución interna aplicando filtros a las imágenes de las hojas afectadas por la enfermedad Alternaria Alternata, como se ilustra en la figura 3. En el primer recuadro se presenta la imagen transformada al espacio de color HSV. La representación en HSV descompone la información de color en tono (hue), saturación (saturation) y valor (value). Esta representación visual contribuye a una identificación más precisa de las características del color en la imagen, facilitando así la definición de umbrales de color para el proceso de segmentación. En el segundo recuadro se muestra la imagen original se carga y ajusta de tamaño en cada repetición del bucle principal. Esto posibilita la visualización del objeto o escena antes de llevar a cabo cualquier procesamiento. En el tercer recuadro la pestaña "Mask" presenta la máscara binaria generada mediante la aplicación de umbrales en el espacio de

color HSV. Esta máscara resalta las áreas que satisfacen los criterios de color establecidos por los valores de las barras deslizantes. Los píxeles dentro de la máscara tienen un valor distinto de cero, mientras que los píxeles fuera de la máscara tienen un valor de cero. Finalmente, en el último recuadro se muestra la pestaña "AND" que exhibe el producto de aplicar la máscara a la imagen original. Esta sección de la imagen original corresponde a la región que cumple con los criterios de color definidos por la máscara. Los píxeles externos a la máscara se transforman en negro, mientras que los píxeles dentro de la máscara mantienen su color original. Este modo de visualización resalta la porción de la imagen que concuerda con el objeto o los colores de interés.

En Python se usaron una serie de códigos para procesar imágenes y videos en directo y obtener un resultado de que si la hoja tiene o no la enfermedad de la Alternaria Alternata. Los códigos más importantes empleados se muestran en la Tabla 1.

Tabla 1. Códigos usados en la aplicación Python para la detección de la enfermedad Alternaria Alternata en la planta del limón

CÓDIGO	DESCRIPCIÓN	DEL CÓDIGO
io.BytesIO	Para la importación de bibliotecas, esta biblioteca permite manejar datos binarios	
streamlit as st	Para crear la web interactiva	
tensorflow as tf	Para cargar y utilizar modelos previamente entrenados	
numpy as np	Para realizar operaciones matemáticas en matrices y tensores	
PIL.Image	Para importar la clase Image del módulo PIL (Python Imaging Library) para trabajar con imágenes.	
"st.set_option" ('deprecation.showfileUploaderEncoding', True)	Configura una opción para mostrar la codificación del cargador de archivos. Esta opción puede estar relacionada con problemas de carga de archivos.	
st.cache(allow_output_mutation=True)	Esta es una decoración de caché de Streamlit que permite cachear la función load_model1 para evitar cargar el modelo en cada ejecución de la aplicación. La función load_model1 carga un modelo previamente	

<pre>with st.spinner('Loading Model into Memory ')</pre>	<p>Para la carga del modelo de clasificación de hojas de cítricos se utilizó un bloque with st.spinner('Loading Model into Memory ') para mostrar un spinner mientras se carga el modelo en la memoria.</p>
<pre># Configurar las clases classes = ['planta sana', 'planta con alternaria alternata']</pre>	<p>Evento para la descripción del etiquetado e identificación de la planta con Alternaria Alternata y planta sana</p>
<pre># Inicializar la cámara cap = cv2.VideoCapture(0) while True: # Leer un fotograma de la cámara ret, frame = cap.read() # Realizar la detección de planta de limón results = model(frame)</pre>	<p>Evento para la configuración de la cámara</p>

En la definición de una lista de nombres de clases para las enfermedades de las hojas de cítricos se utilizó una función para predecir la clase de una imagen de hoja de cítrico: la función “predict\_class1” toma una imagen de hoja y un modelo como entrada, luego convierte la imagen en un tensor de punto flotante y la redimensiona a 224x224 píxeles después realiza la predicción utilizando el modelo cargado y devuelve la salida de la red neuronal, posteriormente carga de una imagen de ejemplo llamada “p2.jpg” y muestra la imagen.

En el Título de la aplicación web se procedió a la carga de una imagen de hoja del limón con la enfermedad a través del cargador de archivos y se verifica de si se ha cargado una imagen, si no se ha cargado, se muestra un mensaje de espera, si se ha cargado una imagen, se muestra un mensaje "Running the Inference..." y luego se muestra la imagen cargada. Se llama a la función “predict\_class1” para predecir la clase de la imagen y se muestra el resultado después se define otra función “load\_model2” y se carga un segundo modelo, que se utiliza para predecir enfermedades además se permite a los usuarios cargar una imagen de fruta cítrica a través del cargador de archivos y se verifica si se ha cargado una imagen. Si no se ha cargado, se muestra un mensaje de espera. Si se ha cargado una imagen, se muestra un mensaje "Running the Inference " y luego se muestra la imagen cargada, también se llama a la función “predict\_class2” para predecir la clase de la imagen y se muestra el resultado.

Desarrollamos un modelo secuencial con redes neuronales convolucionales (CNN) tomándose como referencia la Figura 4, con el propósito de categorizar los datos en grupos de entrenamiento y evaluación. Posteriormente, dividimos estos conjuntos en segmentos más pequeños para un análisis más detallado. Las capas de convolución tienen la función de identificar características, mientras que las capas de agrupación máxima se encargan de seleccionar esas características. Se recurre a las capas de agrupación máxima en situaciones en las que una imagen no requiere la totalidad de información en alta resolución o cuando se extrae la salida de una CNN con regiones más pequeñas tras el muestreo de los datos de entrada. La salida de las capas convolucionales y de agrupación se inserta en capas completamente conectadas con el propósito de llevar a cabo la clasificación. En la figura 4 se muestran 3 capas principales: Capa 1 (de entrada) también conocida como sensorial está formada por neuronas que captan información o señales provenientes del entorno. Por otro lado, una capa de salida (Capa 5) que consiste en neuronas que emiten la contestación de la red neuronal. En cuanto a una capa oculta, no establece una conexión directa con el entorno, es decir, no se vincula directamente con órganos sensores ni con efectores. Este tipo de capa oculta otorga flexibilidad a la red neuronal, permitiéndole representar de manera más precisa ciertas características del entorno que intenta modelar [24].

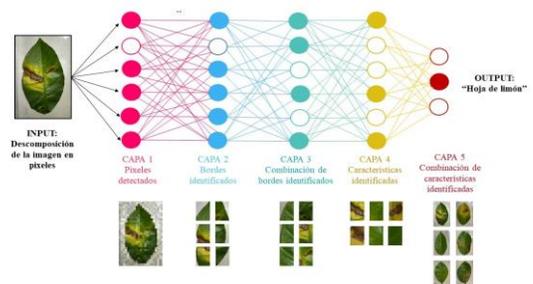


Figura 4. Red neuronal convolucional

Además, se utilizó un sistema de código abierto llamado YOLOv5 para la detección en tiempo real de objetos, el cual fue pre-entrenado con el conjunto de datos COCO. Este sistema utiliza una sola red neuronal convolucional (CNN) para detectar objetos en imágenes. En el enfoque YOLO, la detección de objetos se aborda como un problema de regresión única. La red neuronal convolucional realiza predicciones simultáneas para múltiples cuadros delimitadores que enmarcan los objetos en la imagen. Además, la red predice probabilidades condicionales para cada clase en relación con estos cuadros delimitadores [25].

El YOLOv5 utilizado en este proyecto fue previamente entrenado con un conjunto de datos diverso que abarcaba objetos de distintas categorías. Este preentrenamiento, realizado antes de adaptar el modelo para la detección de hojas de la planta del limón, permitió que el modelo adquiriera conocimientos sobre características generales de objetos y

patrones visuales complejos. Posteriormente, se llevó a cabo el ajuste del modelo utilizando un conjunto de datos específicamente diseñado para la detección de hojas de la planta de limón, clasificadas como "sanas" y "con Alternaria Alternata".

La arquitectura de YOLO se basa en una red neuronal convolucional (CNN) profunda, compuesta por varias capas convolucionales que extraen características jerárquicas de la imagen, como se muestra en la figura 5. Esta estructura divide la imagen en una cuadrícula y realiza predicciones en cada celda. Cada celda predice un conjunto de cuadros delimitadores, junto con las probabilidades asociadas a diversas clases. Este enfoque optimiza la eficiencia computacional al realizar predicciones de manera más específica y localizada.

En este proyecto, el modelo YOLO implementado tiene la capacidad de clasificar las hojas de la planta del limón en dos grupos principales: "Planta con Alternaria Alternata" y "Planta sana". Esta clasificación se logra asignando etiquetas a los cuadros delimitadores detectados, proporcionando información detallada sobre la presencia de enfermedades en las hojas.

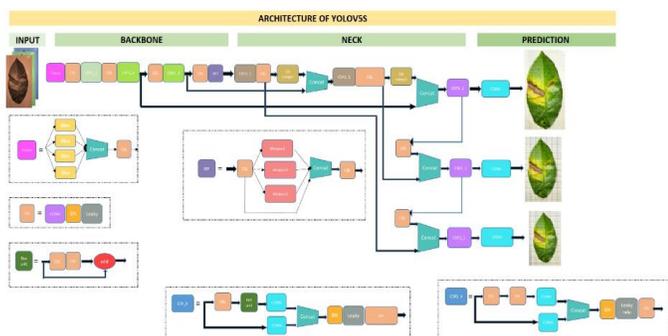


Figura 5. Arquitectura de YOLOv5

Como se puede observar en la fig. 6 se desarrolló el algoritmo para detectar a la hoja enferma mediante imágenes y videos en tiempo real.



Figura 6. Captura del programa Python

### III. RESULTADOS

Mediante el programa Python se utilizó la visión artificial para poder detectar la enfermedad de la Alternaria Alternata en la planta del limón. Por ello se creyó apropiado usar 30

tomas diferentes de las hojas de la planta del limón, para poder evaluar la eficiencia del algoritmo mediante la matriz de confusión. Dichas tomas fueron hechas a distintas hojas a luz natural, entre enfermas y sanas en distintas posiciones y en distintas cantidades.



Figura 7. Captura del programa Python. con hojas enfermas y sanas

En la figura 7 se puede observar como el programa detecta los bordes de las hojas y las clasifica entre hojas enfermas y hojas sanas. A su vez, el reconocimiento de cada hoja nos muestra un resultado probabilístico que nos indica el porcentaje de confiabilidad, tal como se muestra en la figura 8.



Figura 8. Captura del programa Python. con hojas enfermas y sanas

Además, lo resaltante de este proyecto es que el programa puede detectar cuando una hoja está enferma, aunque a simple vista pareciera que estuviera sana, tal como se muestra en la figura 9. De esta manera el agricultor puede observar cuando la hoja está a principios de incubación de la enfermedad y pueda tomar las medidas necesarias.



Figura 9. Hoja con Alternaria Alternata en su etapa inicial

En la tabla 2, se presentan de forma ordenada los resultados obtenidos de las 30 tomas realizadas a distintas hojas entre enfermas y sanas y en la figura 10 se puede observar un resumen de algunas de las pruebas realizadas. Para

ello, se colocaron distintas hojas y en diferentes cantidades para obtener la cantidad de errores por cada una de las 30 pruebas realizadas.



Figura 10. Resumen de algunas de las pruebas realizadas

Tabla 2. Resultados de la identificación de la hoja con la enfermedad Alternaria Alternata y una hoja sana

TOMAS REALIZADAS	RESULTADOS REALES	RESULTADOS OBTENIDOS	ERRORES
1 toma	1 enferma 1 sana	1 enferma 1 sana	0
2 toma	2 enfermas 1 sana	2 enfermas 1 sana	0
3 toma	2 enfermas 2 sanas	1 enfermas 2 sanas	1
4 toma	1 enferma 2 sanas	1 enferma 2 sanas	0
5 toma	2 enfermas 2 sanas	2 enfermas 2 sanas	0
6 toma	3 enfermas 1 sana	4 enfermas 0 sana	1
7 toma	1 enferma 2 sanas	1 enferma 2 sanas	0
8 toma	3 enfermas 1 sana	2 enfermas 1 sana	1
9 toma	1 enferma 2 sanas	1 enferma 2 sanas	0
10 toma	2 enfermas 3 sanas	2 enfermas 3 sanas	0
11 toma	2 enfermas 1 sanas	2 enfermas 1 sanas	0
12 toma	3 enferma 1 sanas	3 enferma 1 sanas	0
13 toma	2 enfermas 4 sanas	1 enfermas 4 sanas	1

14 toma	1 enferma 4 sanas	1 enferma 4 sanas	0
15 toma	3 enfermas 2 sanas	2 enfermas 3 sanas	1
16 toma	4 enfermas 1 sanas	4 enfermas 1 sanas	0
17 toma	1 enfermas 2 sana	1 enfermas 2 sana	0
18 toma	2 sanas 3 enfermas	2 sanas 3 enfermas	0
19 toma	1 enferma 3 sanas	1 enferma 3 sanas	0
20 toma	2 enfermas 3 sanas	2 enfermas 3 sanas	0
21 toma	4 enfermas 1 sana	4 enfermas 1 sana	0
22 toma	3 enfermas 2 sanas	3 enfermas 2 sanas	0
23 toma	2 enfermas 2 sanas	2 enfermas 2 sanas	0
24 toma	2 enfermas 1 sanas	2 enfermas 1 sanas	0
25 toma	1 enferma 2 sanas	1 enferma 2 sanas	0
26 toma	2 enfermas 2 sanas	2 enfermas 2 sanas	0
27 toma	3 enfermas 2 sanas	3 enfermas 2 sanas	0
28 toma	2 enfermas 3 sanas	2 enfermas 3 sanas	0
29 toma	1 enferma 1 sana	1 enferma 1 sana	0
30 toma	3 enfermas 1 sanas	3 enfermas 1 sanas	0
TOTAL	120 MUESTRAS		5

Los resultados encontrados en la tabla 2, nos muestran que, de las 120 muestras tomadas, solo hubo 5 errores, que por defecto el programa no las detectaba o las detectaba erróneamente. Con ello podemos confirmar que nuestros resultados tienen una eficiencia del 95.8 %. Lo que afirma que la visión artificial es de mucha utilidad en el sector agroindustrial, ya que detectará en tiempo real cuando la hoja presente la enfermedad de la Alternaria Alternata o se encuentre en su estado inicial de la enfermedad y el agricultor o encargado pueda tomar las medidas correspondientes para esta enfermedad que es la más peligrosa en la planta del limón.

También se hizo la matriz de confusión para evaluar el rendimiento del algoritmo que se realiza al momento de detectar la enfermedad Alternaria Alternata, obteniendo los siguientes resultados tal como se muestran en la tabla 3.

Tabla 3. Matriz de confusión

	POSITIVO (ENFERMAS)	NEGATIVO (SANAS)
POSITIVO (ENFERMAS)	VERDADERO POSITIVO	FALSO POSITIVO
	58	1
NEGATIVO (SANAS)	FALSO NEGATIVO	VERDADERO NEGATIVO
	4	57

En la tabla 3, se tienen verdaderos positivos con un total de 58 hojas enfermas que el programa detectó como enfermas, 4 falsos negativos que eran hojas enfermas pero el programa las detectó como sanas, 1 falso positivo, que el programa la detectó como enferma y era sana, tal como se observa en la figura 11 y 58 verdaderos negativos que son hojas realmente sanas detectadas como sanas.



Figura 11. Falso positivo

Tabla 4. Porcentaje de error y Nivel de confianza

Tomas	Muestra	Aciertos	Errores	% de Error	% Nivel de confianza
1 a 10	35	32	3	8.57%	91.43%
11 a 20	45	43	2	4.44%	95.56%
21 a 30	40	39	0	0	100%
					<b>95.66%</b>

En la Tabla 4, se ha calculado el porcentaje de error agrupando las tomas en tres grupos. En las tomas 1 a 10, se obtuvo un porcentaje de error del 8.57% con un nivel de confianza del 91.43%. Por otro lado, en las tomas 11 a 20, el porcentaje de error se redujo al 4.44%, alcanzando un nivel de confianza del 95.56%. Posteriormente, en las tomas 21 a 30, el porcentaje de error disminuyó a 0%, logrando un nivel de confianza del 100%. En promedio, esto deja un nivel de confianza del 95.66%.

Finalmente se realizaron algunas ecuaciones para determinar distintos indicadores:

$$Eficiencia = \frac{\text{Predicciones correctas}}{\text{Total de predicciones}}$$

$$Eficiencia = \frac{115}{120}$$

$$Eficiencia = 0.958 \dots Ec(1)$$

$$Precisión = \frac{\text{Verdaderos positivos}}{\text{verdadero positivo} + \text{falsos positivos}}$$

$$Precisión = \frac{58}{58 + 1}$$

$$Precisión = 0.983 \dots Ec(2)$$

$$Efectividad$$

$$= \frac{\text{Verdaderos positivos}}{\text{Verdaderos positivos} + \text{Falsos negativos}}$$

$$Efectividad = \frac{58}{58 + 4}$$

$$Efectividad = 0.935 \dots Ec(3)$$

#### IV. DISCUSIÓN

Comparado con el estudio previo sobre la detección de hongos en una planta medicinal mediante redes neuronales, donde la precisión alcanzada fue del 75% [13], nuestro proyecto logró un 98.3% de precisión. Esto puede atribuirse al vertiginoso avance científico actual. Asimismo, en nuestro trabajo, empleamos el lenguaje de programación YOLOv5, mientras que el estudio anterior utilizó el modelo YOLOv3. La elección de una arquitectura más avanzada y la aplicación de técnicas innovadoras pueden haber contribuido significativamente a nuestro éxito en la detección de hongos en plantas medicinales.

En contraste, en el ámbito de la visión artificial aplicada a la detección de defectos externos en mangos, se obtuvo una efectividad del 87.79% mediante técnicas previas [14]. Sin embargo, en nuestro trabajo logramos alcanzar una efectividad del 93.5%. Este resultado se debe a la implementación de redes neuronales específicas para detectar la enfermedad de la Alternaria Alternata. La utilización de estas redes neuronales mejoró significativamente la precisión durante las pruebas. Por otro lado, en el enfoque basado exclusivamente en algoritmos de procesamiento de imágenes, como K-Means y Otsu, la efectividad fue menor.

La visita al “Fundo Amada” puso de manifiesto la presencia de enfermedades que afectan negativamente la producción de limones, lo que proporciona una sólida justificación para el desarrollo de nuestro proyecto. La implementación de un sistema de visión artificial específicamente diseñado para identificar la Alternaria Alternata en las plantas de limón emerge como una solución crucial. Este sistema no solo facilita a los agricultores la detección precisa de la enfermedad, sino que también les ayuda a determinar cuándo una hoja está afectada por la enfermedad, incluso cuando no es visible a simple vista.

Además, sienta las bases para futuras investigaciones en el ámbito de la agricultura y el control biológico de plagas.

## V. CONCLUSIONES

Se logró el desarrollo de un algoritmo de visión artificial para la detección de la enfermedad de *Alternaria Alternata* en las plantas de limón en el Fundo Amada, que es una respuesta oportuna a la crisis en la cosecha de limones en el Perú. La implementación de este sistema ofrece una solución tecnológica avanzada y práctica para los agricultores, permitiéndoles identificar de manera rápida y precisa las hojas afectadas por esta enfermedad. Los antecedentes de investigaciones similares en otras regiones respaldan la efectividad de este enfoque, mientras que los resultados obtenidos en el Fundo Amada demuestran una eficiencia de 95.8%, una precisión de 98.3% y una efectividad de 93.5% en el algoritmo.

Se concluye afirmando que al trabajar en un ambiente controlado o no controlado como en el Fundo Amada y en el laboratorio de la universidad, el desarrollo del algoritmo funciona perfectamente y ayuda al agricultor en la detección de la enfermedad de la *Alternaria Alternata*.

La combinación de herramientas tecnológicas como Python, Tensorflow y YOLOv5, junto con el uso de una red neuronal convolucional, ha demostrado ser exitosa en la detección de la *Alternaria Alternata*. Los resultados obtenidos, con una tasa de error del 4%, indican que el algoritmo es confiable y puede proporcionar a los agricultores la información necesaria para gestionar eficazmente la enfermedad en sus cultivos.

Este proyecto no solo aborda una problemática específica en la producción de limones, sino que también sienta las bases para futuras investigaciones y aplicaciones en el campo de la detección de enfermedades en la agricultura. La adaptabilidad del algoritmo a entornos controlados y no controlados y su capacidad para trabajar con diversas condiciones de iluminación y posicionamiento lo hacen valioso y aplicable en diversas situaciones. En última instancia, este trabajo contribuye al avance de la tecnología en la agricultura, ofreciendo soluciones innovadoras para mejorar la productividad y la gestión de enfermedades en los cultivos.

## REFERENCIAS

- [1] Lucena, P. (2022). Inteligencia Artificial. Obtenido de <https://www.cesuma.mx/blog/que-es-la-vision-artificial.html>
- [2] Ruseell, S. (2022). Inteligencia Artificial-Un enfoque moderno. Obtenido de [https://luismejias21.files.wordpress.com/2017/09/inteligencia-artificial-un-enfoque-moderno-stuart-j-ru\\_ssell.pdf](https://luismejias21.files.wordpress.com/2017/09/inteligencia-artificial-un-enfoque-moderno-stuart-j-ru_ssell.pdf)
- [3] Zarai, R. M. (2020). Redes neuronales recurrentes y redes neuronales profundas basadas en un sistema de detección de intrusiones. Obtenido de [https://www.scirp.org/%28S%28351jmbntvnsjt1aadkpozsjz%29%29/journal/paperinformation.aspx?p\\_aperid=99105](https://www.scirp.org/%28S%28351jmbntvnsjt1aadkpozsjz%29%29/journal/paperinformation.aspx?p_aperid=99105)
- [4] Challenger, I. (2014). El lenguaje de programación Python. Obtenido de <https://www.redalyc.org/pdf/1815/181531232001.pdf>
- [5] Sanchez, J. & Soler, J. (2014). Herramienta de control biológico de *Alternaria alternata* en cítricos. Obtenido de [https://www.phytoma.com/images/pdf/258\\_ID\\_IAB\\_Alternaria.pdf](https://www.phytoma.com/images/pdf/258_ID_IAB_Alternaria.pdf)
- [6] Alayon, P., & L., G. (2022). Combinación de tratamientos con fungicidas y nitrato de calcio para el control de la mancha marrón (*Alternaria alternata*). Obtenido de <https://www.redalyc.org/pdf/612/61220112.pdf>
- [7] Camarena J., (2013). Sistema nacional de vigilancia y monitoreo de plagas. Obtenido de <https://www.sinavimo.gob.ar/>
- [8] Rouhiainen, L. (2018). Inteligencia artificial. Obtenido de [https://planetadelibrosec0.cdnstatics.com/libros\\_contenido\\_extra/40/393\\_08\\_Inteligencia\\_artificial.pdf](https://planetadelibrosec0.cdnstatics.com/libros_contenido_extra/40/393_08_Inteligencia_artificial.pdf)
- [9] García, I. & Caranqui, V. (2015). La visión artificial y los campos de aplicación. Obtenido de <https://revistasdigitales.upec.edu.ec/index.php/tierrainfinita/article/view/76/2992>
- [10] Rodriguez, L. (2020). Gestión de un sistema de visión artificial para la detección de los. Obtenido de <file:///C:/Users/JHOLY/Downloads/3151-Texto%20del%20art%C3%ADculo-11544-1-10-20201117.pdf>
- [11] Alvear & Rosero (2017). Internet de las Cosas y Visión Artificial, Funcionamiento y Aplicaciones. Obtenido de <https://ingenieria.ute.edu.ec/enfoqueute/index.php/revista/article/view/121/127>
- [12] Sanchez, C. (2020). Detección de enfermedades en plantas de crisantemo, por medio de visión artificial aplicada a imágenes multispectrales. Obtenido de [https://repositorio.itm.edu.co/bitstream/handle/20.500.12622/4531/CarlosAndres\\_SanchezRios2021.pdf?sequence=1&isAllowed=y](https://repositorio.itm.edu.co/bitstream/handle/20.500.12622/4531/CarlosAndres_SanchezRios2021.pdf?sequence=1&isAllowed=y)
- [13] Álvarez, O. (2020). Desarrollo de un sistema de visión artificial para la detección de hongos en plantas de cannabis medicinal mediante redes neuronales en ambientes controlados. <http://repositoriodspace.unipamplona.edu.co/jspui/handle/20.500.12744/5316>
- [14] Carrillo & Saldaña (2016). Utilización de técnicas de visión artificial para la detección automática de defectos externos del mango. Obtenido de <https://repositorio.uss.edu.pe/bitstream/handle/20.500.12802/162/10%20TESIS.pdf?sequence=1&isAllowed=y>
- [15] Mota . Juárez. Olguin, J(2018) Clasificación de manzanas utilizando visión artificial y redes neuronales artificiales. Obtenido de: <https://journalusco.edu.co/index.php/region/article/view/1917>
- [16] Muñoz L. (2021). Viabilidad y rendimiento de YOLOv5 en Raspberry Pi 4 modelo B. Obtenido de <https://idus.us.es/bitstream/handle/11441/126961/TFG-3731-MU%c3%91IZ%20GARCIA.pdf?sequence=1&isAllowed=y>
- [17] Ártola A. (2019). Clasificación de imágenes usando redes neuronales convolucionales en Python. Obtenido de <https://idus.us.es/bitstream/handle/11441/89506/TFG-2402-ARTOLA.pdf?sequence=1&isAllowed=y>
- [18] Calvo D. (2017) Red Neuronal Convolucional. Obtenido de <http://www.diegocalvo.es/redneuronal-convolucional/>. Último acceso: 04/2019
- [19] Mínguez, T. D. (2021). Visión artificial: aplicaciones prácticas con OpenCV-Python. Marcombo.
- [20] Peinado, R. (2022). Estudio de la calidad en las detecciones de la red YOLOv5 con transformación de imágenes. Obtenido de <https://riuma.uma.es/xmlui/handle/10630/26026>
- [21] Severance C. (2019). Python para todos. Obtenido de <https://www.cartagena99.com/recursos/alumnos/temarios/211001163348-pythonlearn.pdf>
- [22] Hilera G. (2019). Conceptos básicos sobre redes neuronales. Obtenido de <http://grupo.us.es/gtocoma/pid/pid10/RedesNeuronales.htm#arquitectura-redes>.
- [23] Sotaquirá, M. (2019). La Convolución en las Redes Convolucionales. Obtenido de <https://www.codificandobits.com/blog/convolucion-redes-convolucionales>
- [24] Larrañaga P. & Iñaki I. Redes Neuronales (2017). Obtenido de <http://www.sc.ehu.es/ccwbayes/docencia/mmcc/docs/t8neuronales.pdf>
- [25] Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp.779–788).