

# Development of an artificial vision algorithm to detect the Huanglongbing (HLB) disease in the citrus lemon plant of the “Fundo Amada”

Cesar Enrique Santos Gonzales<sup>1</sup>, Blas Varas Stefany<sup>2</sup>, Delgado Rodriguez Jholy<sup>3</sup>  
<sup>1</sup>Universidad Privada del Norte, Perú, cesar.gonzales@upn.edu.pe

*Abstract- In Peru, between August and October 2023, lemon production faced a crisis due to exceptional weather conditions associated with the El Niño Phenomenon. This situation led to the proliferation of pests and diseases, generating a 500% increase in the price of lemon, and reducing its availability, which led to a decrease in its consumption. The Amada Farm was also affected by pests such as penicillium, exocortis and cottony mealybug. The Huanglongbing (HLB) disease, known as "yellow dragon", stood out as the most destructive and represented a serious threat to the farm. Currently, the control of this disease is carried out mainly through the use of chemicals, but there is growing interest in solutions based on biological control to reduce dependence on chemical substances. Given the difficulty of controlling the disease in susceptible varieties and in areas with years of presence of the pathogen, it was proposed to develop an artificial vision algorithm. This algorithm aims to detect the disease in lemon plants, identifying both diseased leaves and those that, at first glance, appear healthy, but already have the disease in its initial stage. To achieve this, convolutional neural networks and the Python programming language were used. 119 images of leaves were captured in various conditions, including diseased and healthy, with variations in lighting, position, and quantity. The purpose of this set of images was to evaluate the effectiveness of the algorithm using a confusion matrix. The results showed that, of the 119 samples taken, only 4 errors were recorded, confirming that the algorithm achieved an efficiency of 96.64%.*

*Keywords: computer vision, python, Huanglongbing, 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 Huanglongbing (HLB) en la planta citrus limón del “Fundo Amada”

Cesar Santos Gonzales<sup>1</sup>, Blas Varas Stefany<sup>2</sup>, Delgado Rodriguez Jholy<sup>3</sup>

<sup>1</sup>Universidad Privada del Norte, Perú, cesar.gonzales@upn.edu.pe

**Resumen-** En el Perú, entre agosto y octubre de 2023, la producción de limones enfrentó una crisis debido a condiciones climáticas excepcionales asociadas al Fenómeno del Niño. Esta situación propició la proliferación de plagas y enfermedades, generando un aumento del 500% en el precio del limón y reduciendo su disponibilidad, lo que llevó a una disminución en su consumo. El Fundo Amada también se vio afectado por plagas como el penicillium, el exocortis y la cochinilla algodonosa. La enfermedad del Huanglongbing (HLB), conocida como "dragón amarillo", se destacó como la más destructiva y representó una seria amenaza para el fundo.

Actualmente, el control de esta enfermedad se realiza principalmente mediante el uso de productos químicos, pero existe un interés creciente en soluciones basadas en el control biológico para reducir la dependencia de sustancias químicas. Dada la dificultad de controlar la enfermedad en variedades susceptibles y en áreas con años de presencia del patógeno, se propuso desarrollar un algoritmo de visión artificial. Este algoritmo tiene como objetivo detectar la enfermedad en las plantas de limón, identificando tanto hojas enfermas como aquellas que, a simple vista, parecen sanas, pero ya presentan la enfermedad en su etapa inicial.

Para lograr esto, se emplearon redes neuronales convolucionales y el lenguaje de programación Python. Se capturaron 119 imágenes de hojas en diversas condiciones, incluyendo enfermas y sanas, con variaciones en la iluminación, posición y cantidad. El propósito de este conjunto de imágenes era evaluar la eficacia del algoritmo mediante una matriz de confusión. Los resultados mostraron que, de las 119 muestras tomadas, solo se registraron 4 errores, lo que confirma que el algoritmo logró una eficiencia del 96.64%.

Palabras claves: visión artificial, python, Huanglongbing, redes neuronales

## I. INTRODUCCIÓN

En el Perú, la producción de limones se mantiene constante a lo largo del año, pero es durante los meses de enero a junio cuando se alcanza el 60% de la producción nacional. En los últimos meses del año 2023 el país enfrentó una crisis en la cosecha de limones, resultando en un aumento del 500% en su precio y obligando a muchas personas a reducir su consumo debido a la escasez. Esta situación contribuyó en el aumento de la inflación del país en dichos meses.

La crisis en la cosecha se atribuyó a las lluvias y condiciones climáticas inusuales causadas por el Fenómeno del Niño en los meses de abril del año 2023. Estos eventos han propiciado la proliferación de diversas plagas y enfermedades en las plantas de limón, afectando la disponibilidad del fruto. El fundo Amada no ha sido una excepción, ya que sus plantas

de limón están infestadas con plagas y enfermedades como penicillium, exocortis, alternaria alternata y el huanglongbing (HLB), todo debido al Fenómeno del Niño.

Entre todas las plagas y enfermedades, el huanglongbing (HLB) también conocida como el "dragón amarillo" es una enfermedad altamente destructiva y representa una seria amenaza para la industria de los cítricos en todo el mundo. El control de la enfermedad a menudo implica medidas preventivas para reducir la propagación de los insectos vectores, así como la eliminación de árboles infectados para evitar la diseminación del patógeno.

Ante este escenario, se busca desarrollar un algoritmo de visión artificial que permita detectar la enfermedad del Huanglongbing (HLB) en las plantas de limón, ya que a simple vista no parece que la hoja esté enferma. Esto facilita la diferenciación de esta enfermedad respecto a otras, brindando a los agricultores la información necesaria para aplicar los métodos y tratamientos precisos. Por ende, en este trabajo se aprovechará la visión e inteligencia artificial. La visión artificial permite que las máquinas "vean" y procesen 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, como el aprendizaje, la percepción, el razonamiento y la toma de decisiones [2]. Además, se utilizarán las redes neuronales convolucionales, un tipo de red neuronal profunda altamente efectiva en tareas de visión artificial como la clasificación de imágenes y la detección de objetos [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].

En este trabajo, se emplea la visión artificial para identificar la presencia de la enfermedad del HLB o también llamado “dragón amarillo” en la planta del limón, distinguiéndose de otras enfermedades. Esta enfermedad se clasifica como una de las más destructivas para los cítricos a nivel global debido a su rápida propagación y devastadoras consecuencias. Esta patología reduce significativamente los rendimientos de los cultivos y puede resultar en la muerte de los árboles afectados [5].

La enfermedad conocida como HLB está vinculada a la bacteria *Candidatus Liberibacter*, que se encuentra en material vegetal infectado y en insectos como *Trioza erytreae* y *Diaphorina citri*. Se considera que este último es el principal portador del agente causal de la enfermedad. Estudios filogenéticos basados en la región 16S rRNA han identificado a *Ca. Liberibacter* como perteneciente a  $\alpha$ -2 proteobacteria y posee una gran negatividad. Además, la bacteria tiene un diámetro que oscila entre 0.2 y 0.3  $\mu\text{m}$  y presenta una membrana que contiene una capa de peptidoglicano. [6].

La enfermedad en los árboles se manifiesta mediante una protuberancia en la región central de las hojas, y en etapas más avanzadas, se producen colapsos en las células del floema. Como resultado, el tejido vascular sufre necrosis, obstruyendo el flujo y la translocación de nutrientes. Este proceso conlleva a cambios anatómicos en las hojas, tales como el amarillamiento de las nervaduras y la aparición de manchas irregulares que varían desde tonalidades amarillas hasta verde oscuro [7].

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 un gran interés. Estos 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 una investigación previa en Chao, se hizo uso de un sistema de visión artificial para la identificación de *Heliothis virescens* en plantas de arándano en una empresa agroindustrial. Los resultados obtenidos al identificar plagas revelaron un nivel de efectividad del 70%, acompañado de una reducción de 30 minutos en el tiempo de ejecución. A partir de estos hallazgos, se puede inferir que un sistema de visión computacional ejerce un impacto notable en la identificación de plagas. Esta conclusión se respalda con la prueba Z, donde  $p < 0.05$  con un nivel de confianza del 95% [11].

Por otro lado, en Colombia se desarrolló un sistema de visión artificial para el reconocimiento de enfermedades y plagas en las hojas de yuca por medio de redes neuronales

convolucionales. El modelo presentado en este estudio, fundamentado en este tipo específico de redes, fue capacitado utilizando un conjunto de datos creado a partir de la combinación de información proveniente de dos competiciones alojadas en la plataforma Kaggle. Entre los tres modelos escogidos por su destacado desempeño en la clasificación de enfermedades en plantas, según la información consultada, el más sobresaliente resultó ser Xception. Fue entrenado a lo largo de 35 épocas utilizando 6120 imágenes de hojas de yuca, alcanzando una precisión del 94,56%. Este modelo se presenta como una alternativa para la detección temprana, confiable y económica de enfermedades en las hojas de yuca en el lugar donde se encuentran. [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.

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 enfermedad de Huanglongbing (HLB) causada por la bacteria *Candidatus Liberibacter*, que causa como principal característica el color amarillo en exceso en las hojas, lo que a simple vista podría pasar como una hoja sana. 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 detección de objetos 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, ya que nos pudimos dar cuenta que es 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 de Huanglongbing (HLB) o dragón amarillo 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 Huanglongbing (HLB) en la planta citrus limón en el “Fundo Amada”, para lo cual se establecieron los siguientes objetivos específicos: trabajar en ambientes controlados y no controlados y utilizar la red neuronal del YOLOv5.

## II. MATERIALES Y MÉTODOS

Inicialmente, se llevó a cabo una evaluación del estado de las plantas de limón, durante la cual se capturaron fotografías con el propósito de visualizar la presencia de la enfermedad Huanglongbing (HLB). El objetivo consistía en examinar las características como la apariencia y color de las hojas, identificando sus defectos. Se procuró que estas fotografías tuvieran la iluminación y enfoque adecuados, siendo tomadas en diversas horas del día para garantizar una mayor diversidad en el conjunto de datos a emplear en el programa.

En total, se recolectaron 130 imágenes en distintas condiciones de luz, posiciones y ángulos, como se muestra en la Figura 1. Sin embargo, se descartaron 30 imágenes que no cumplían con los requisitos para el procesamiento. Posteriormente, las fotografías fueron recortadas y redimensionadas con el objetivo de simplificar el proceso de entrenamiento. A continuación, se procedió al etiquetado de las imágenes, utilizando la herramienta LabelMe para realizar la identificación gráfica de la enfermedad Huanglongbing (HLB) en las hojas de la planta de limón. Este etiquetado tenía como finalidad reconocer las características distintivas entre las hojas en buen estado y las enfermas, destacando aspectos como el color, la forma y la textura. Se prestaron especial atención a los rasgos clave para identificar las hojas afectadas por la enfermedad Huanglongbing (HLB), tales como manchas de color bastante amarillas, lo cual a simple vista podría pasar por desapercibido, pero está es una característica principal de esta enfermedad, de ahí que también es conocida como el “Dragón amarillo”.



Fig.1  
 Enfermedad del HLB a las 8:00 pm  
 Enfermedad del HLB a las 12:00 pm  
 Enfermedad del HLB a las 4:00 pm  
 Enfermedad del HLB a las 6:00 pm

Se emplearán redes neuronales convolucionales (CNN) para el proceso, las cuales procesan sus capas de manera que emule 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 jerárquicamente. En este contexto, las primeras capas detectan propiedades o formas elementales y a medida que avanzamos en las capas, la red se especializa cada vez más, llegando a capas más profundas capaces de reconocer formas complejas como rostros o siluetas [17]. La red neuronal requiere procesar un conjunto extenso de imágenes para identificar las características distintivas de cada objeto y, al mismo tiempo, lograr generalizar. Cada imagen se representa como una matriz 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 integrará el modelo YOLOv5 con la biblioteca OpenCV para posibilitar la visualización en tiempo real de los resultados de la detección [19]. YOLOv5 utiliza una variante de la arquitectura Darknet llamada CSPDarknet53 como espinazo (backbone) de la red. Esta arquitectura se caracteriza por bloques de conexión y separación (CSP) que mejoran el flujo de información 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, proporcionando una herramienta eficaz para la evaluación constante de las hojas sanas y enfermas.

Para el proceso de entrenamiento de las redes neuronales, se utilizará 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 implica un análisis detallado de todas las imágenes con etiquetas adecuadas para resumir las representaciones de las características presentes en ellas. Durante el proceso de entrenamiento, se aplicará internamente una operación de convolución que utilizará filtros para identificar características y patrones relevantes asociados con la detección de los defectos causados por la enfermedad Huanglongbing (HLB). Esto permitirá diferenciar sus características de otras posibles enfermedades de la planta. La operación de convolución se realiza de manera análoga para imágenes en color, aplicando convoluciones 2D separadas a cada capa (roja, verde y azul) para detectar bordes, identificar textura y analizar píxeles, respectivamente. El filtro o núcleo se utiliza para reconocer patrones y características específicas de la hoja, como bordes, textura y forma.

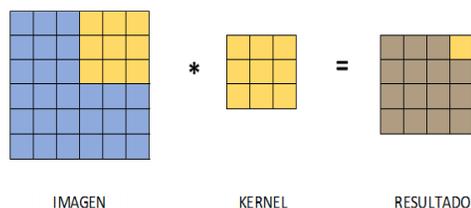


Fig. 2 Convolución de imágenes [23]

Como se evidencia en la Figura 2, el proceso de convolución es un método iterativo en el que el kernel posee un número de planos equivalente al de la imagen de entrada, con un plano por cada canal de la imagen inicial. En cada ciclo, se lleva a cabo una convolución entre cada plano del kernel y su respectivo plano en la imagen en color, sumando los resultados para generar un único valor [23]. En el contexto de nuestro proyecto, la convolución de imágenes tiene como objetivo identificar las características distintivas de las hojas de la planta del limón mediante el uso de un kernel especializado. Este kernel está diseñado para reconocer patrones que distingan entre una hoja afectada por la enfermedad del Huanglongbing (HLB) en una hoja normal o con otro tipo de enfermedad, incluyendo aspectos como texturas, bordes y la forma morfológica de la hoja.

Es importante tener en cuenta que nuestro proyecto se llevará a cabo en un entorno no controlado, realizando muestras y pruebas en el mismo Fondo, donde se abordarán diferentes escenarios para la captura de imágenes en diversas horas del día.

Durante el proceso de entrenamiento de la red neuronal, se ejecuta una convolución interna aplicando filtros a las imágenes de las hojas afectadas por la enfermedad del Huanglongbing (HLB), como se ilustra en la Figura 3. En el primer cuadro (a), se presenta la imagen transformada al espacio de color HSV, que descompone la información de color en tono, saturación y valor para facilitar la identificación precisa de las características del color en la imagen. En el segundo cuadro (b), se muestra la imagen original ajustada de tamaño en cada repetición del bucle principal. Esto permite visualizar el objeto o escena antes de cualquier procesamiento. El tercer cuadro (c) presenta la máscara binaria generada mediante la aplicación de umbrales en el espacio de color HSV, resaltando las áreas que cumplen con los criterios de color establecidos. Finalmente, en el último cuadro (d) se exhibe el resultado de aplicar la máscara a la imagen original, destacando la región que concuerda con los criterios de color definidos, resaltando así la porción de la imagen de interés.

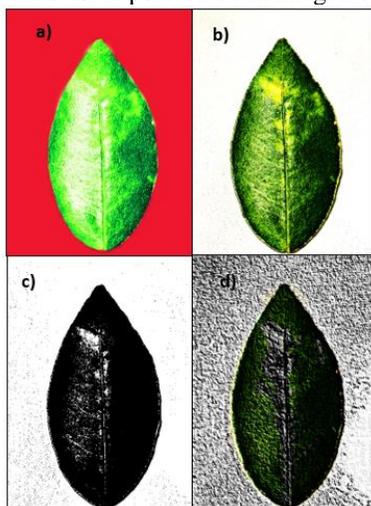


Fig. 3 Convolución de imágenes de la planta de limón

En el entorno de programación Python, se implementaron varios conjuntos de códigos para analizar imágenes y videos en tiempo real, determinando la presencia o ausencia de la enfermedad de Huanglongbing (HLB) en las hojas. Los códigos más significativos utilizados se detallan en la Tabla 1.

TABLA I  
CÓDIGOS USADOS EN LA APLICACIÓN PYTHON PARA LA DETECCIÓN DE LA ENFERMEDAD HUANGLONGBING (HLB) EN LA PLANTA DEL LIMÓN

CÓDIGO	DESCRIPCIÓN DEL CÓDIGO
io.BytesIO	En cuanto a la incorporación de bibliotecas, esta librería posibilita la manipulación de datos en formato binario.
streamlit as st	Con el fin de desarrollar la plataforma web interactiva
tensorflow as tf	Con el propósito de cargar y emplear modelos que han sido entrenados previamente
numpy as np	Con el objetivo de llevar a cabo operaciones matemáticas en matrices y tensores.
PIL.Image	Para incorporar la clase Image del módulo PIL (Python Imaging Library) y así trabajar con imágenes
“st.set_option” (‘deprecation.showfileUploaderEncoding’, True)	Establece una configuración que permita visualizar la codificación del cargador de archivos, ya que esta opción podría estar vinculada a inconvenientes durante la carga de archivos.
st.cache(allow_output_mutation=True)	Esta es una decoración de caché de Streamlit que permite almacenar en caché la función load_model para evitar la carga repetida del modelo en cada ejecución de la aplicación. La función load_model se encarga de cargar un modelo previamente.

<pre>with st.spinner('Loading Model into Memory')</pre>	<p>Para cargar el modelo de clasificación de hojas de cítricos, se empleó un bloque con <code>st.spinner('Cargando modelo en memoria')</code> con el objetivo de mostrar un indicador de carga mientras el modelo se carga en la memoria.</p>
<pre># Configurar las clases classes = ['planta sana', 'planta con HLB']</pre>	<p>Evento para la descripción del etiquetado e identificación de la PLANTA CON HLB 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 creación de una lista de nombres de clases para las enfermedades de las hojas de cítricos, se empleó la función "predict\_class1" para predecir la clase de una imagen de hoja de cítrico. Esta función toma una imagen de hoja y un modelo como entrada, convierte la imagen en un tensor de punto flotante, la redimensiona a 224x224 píxeles y realiza la predicción utilizando el modelo cargado, devolviendo la salida de la red neuronal. Luego, se carga una imagen de ejemplo llamada "p2.jpg" y se muestra la imagen.

En el título de la aplicación web, se lleva a cabo la carga de una imagen de hoja de limón con la enfermedad a través del cargador de archivos. Se verifica si se ha cargado una imagen y, si no se ha cargado, se muestra un mensaje de espera. Si se ha cargado una imagen, se presenta un mensaje de "Running the Inference..." y luego se muestra la imagen cargada. Se utiliza la función "predict\_class1" para predecir la clase de la imagen, y se muestra el resultado.

Además, se define otra función llamada "load\_model2" que carga un segundo modelo utilizado para predecir enfermedades. Los usuarios pueden 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 presenta un mensaje de "Running the Inference" y luego se muestra la imagen cargada. Se llama a la función "predict\_class2" para predecir la clase de la imagen y se muestra el resultado.

En el desarrollo del modelo secuencial con redes neuronales convolucionales (CNN), nos basamos en la Figura 4 para clasificar los datos en conjuntos de entrenamiento y prueba. Luego, dividimos estos conjuntos en segmentos más pequeños para un análisis más detallado. Las capas de convolución identifican características, mientras que las capas de agrupación máxima seleccionan esas características. Las capas de agrupación máxima son útiles cuando no se requiere la totalidad de información en alta resolución o cuando se extrae la salida de una CNN con regiones más pequeñas después del muestreo de los datos de entrada. La salida de estas capas se introduce en capas completamente conectadas para la clasificación. La Figura 4 muestra tres capas principales: la Capa 1 (de entrada), también conocida como sensorial, formada por neuronas que reciben datos del entorno; una capa de salida (Capa 5) que emite la respuesta de la red neuronal; y una capa oculta que no establece una conexión directa con el entorno, brindando flexibilidad a la red para representar características específicas del entorno que intenta modelar [24]

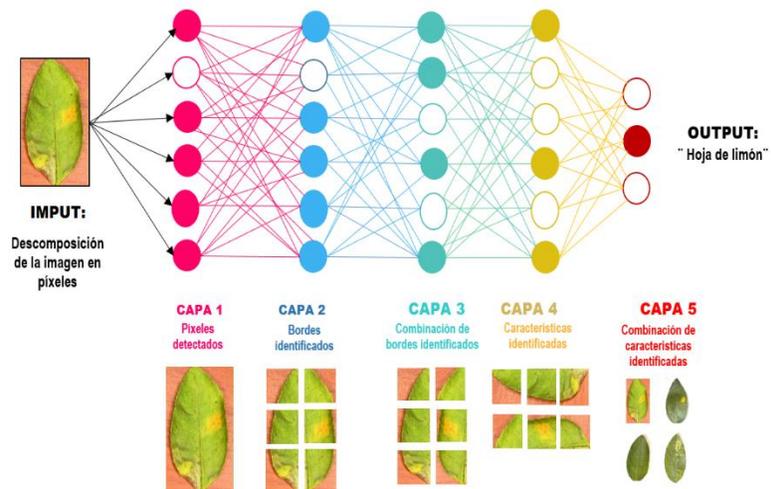


Fig. 4 Red neuronal convolucional

Además, se empleó un sistema de código abierto denominado YOLOv5 para la detección en tiempo real de objetos, el cual fue preentrenado utilizando el conjunto de datos COCO. Este sistema se basa en una única red neuronal convolucional (CNN) para la detección de objetos en imágenes. En el enfoque YOLO, la detección de objetos se trata como un problema de regresión única, donde 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 preentrenado con un conjunto de datos diverso que incluía objetos de diversas categorías. Este preentrenamiento, llevado a cabo 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 realizó 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 HLB".

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 ilustra 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 Huanglongbing (HLB)" 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.

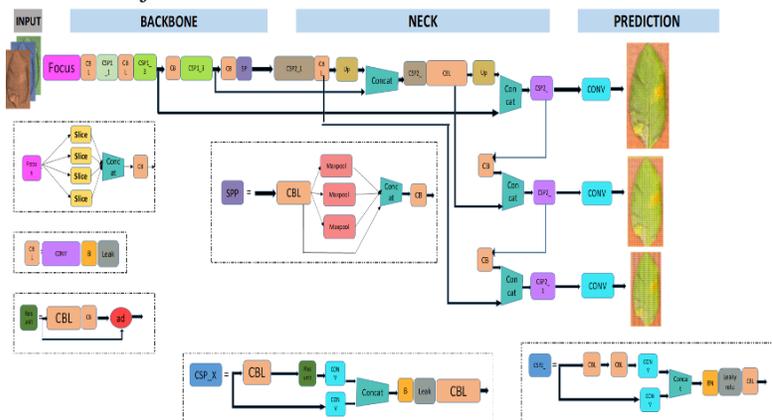


Fig. 5 Arquitectura de YOLOv5

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.



Fig. 6 Captura del programa Python

### III. RESULTADOS

A través del uso de Python, se aplicó la visión artificial con el objetivo de identificar la presencia de la enfermedad Huanglongbing (HLB) en la planta de limón. Para evaluar la eficacia del algoritmo, se seleccionaron 30 imágenes diferentes de hojas de limón, capturadas en diversas condiciones de luz natural, abarcando hojas enfermas y sanas, en variadas posiciones y cantidades. Estas imágenes se utilizaron para analizar el desempeño del algoritmo mediante la construcción de una matriz de confusión.

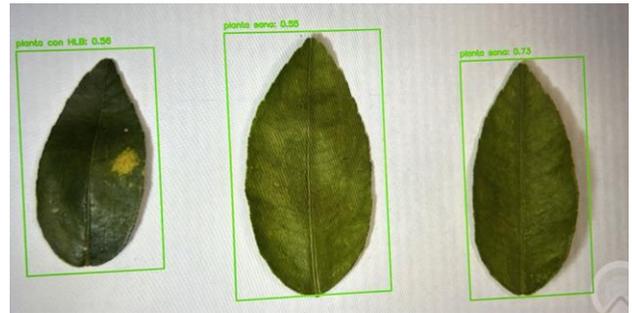


Fig.7 Captura del programa python. con hojas enfermas y sanas

En la figura 7 se evidencia cómo el software identifica los contornos de las hojas y las categoriza en hojas afectadas y hojas saludables. Además, el reconocimiento individual de cada hoja proporciona un resultado probabilístico que refleja el porcentaje de confiabilidad, tal como se ilustra en la figura 8.



Fig. 8 Captura del programa python. con hojas enfermas y sanas

Un aspecto destacado de este proyecto es la capacidad del programa para identificar una hoja enferma, incluso cuando a simple vista pueda parecer saludable, como se representa en la figura 9. Esto permite al agricultor detectar la etapa inicial de la enfermedad en la hoja y tomar las medidas necesarias.



Figura 9. Hoja con Huanglongbing (HLB) en su etapa inicial

La tabla 2 presenta de manera organizada los resultados derivados de las 30 capturas efectuadas en varias hojas, incluyendo tanto las afectadas como las saludables. En la figura 10, se proporciona un resumen de algunas de las pruebas realizadas. Para ello, se dispusieron diversas hojas en distintas cantidades, con el propósito de determinar la cantidad de errores en cada una de las 30 pruebas ejecutadas.



Fig. 10 Resumen de algunas de las pruebas realizadas

TABLA II  
RESULTADOS DE LA IDENTIFICACIÓN DE LA HOJA CON LA ENFERMEDAD DE HUANGLONBING (HLB) 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	2 enfermas 2 sanas	0
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 2 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 3 sanas	2 enfermas 3 sanas	0
14 toma	1 enferma 4 sanas	1 enferma 4 sanas	0

15 toma	3 enfermas 2 sanas	2 enfermas 3 sanas	0
16 toma	4 enfermas 1 sanas	3 enfermas 2 sanas	1
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	3 enfermas 2 sana	1
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	119 MUESTRAS		4
EFICIENCIA	96.64 %		

Los resultados detallados en la tabla 2 indican que, de las 119 muestras recopiladas, solo se observaron 4 errores, donde el programa no las detectaba o las identificaba de manera incorrecta. Este hallazgo confirma que nuestros resultados poseen una eficacia del 96.64 %. Esto respalda la afirmación de que la visión artificial resulta altamente beneficiosa en el ámbito agroindustrial, ya que permite detectar en tiempo real la presencia de la enfermedad de Huanglongbing (HLB) o identificar su fase inicial. Esto, a su vez, posibilita que el agricultor o el responsable tome las medidas adecuadas ante esta enfermedad, que representa un riesgo significativo para la planta de limón.

También se hizo la matriz de confusión para ordenar los verdaderos positivos, falso negativo, falso positivo y verdadero negativo, obteniendo los siguientes resultados tal como se muestran en la tabla 3.

TABLA III  
MATRIZ DE CONFUSIÓN

	POSITIVO (ENFERMAS)	NEGATIVO (SANAS)
POSITIVO (ENFERMAS)	VERDADERO POSITIVO 59	FALSO POSITIVO 3
NEGATIVO (SANAS)	FALSO NEGATIVO 1	VERDADERO NEGATIVO 60

En la tabla 3, se tienen verdaderos positivos con un total de 59 hojas enfermas que el programa detectó como enfermas, 1 falsos negativos que eran hojas enfermas pero el programa las detectó como sanas, 3 falso positivo, que el programa la detectó como enferma y era sana, tal como se observa en la figura 11 y 60 verdaderos negativos que son hojas realmente sanas detectadas como sanas.



Fig. 11 Falso positivo

Finalmente se realizaron algunas ecuaciones para determinar distintos indicadores:

$$\begin{aligned} \text{Exactitud} &= \text{Predicciones correctas} / \text{total de} \\ & \text{predicciones.... Ecuación (1)} \\ \text{Exactitud} &= 115 / 119 \\ \text{Exactitud} &= 0.97 \end{aligned}$$

$$\begin{aligned} \text{Precisión} &= \text{Verdaderos positivos} / \text{verdaderos} \\ & \text{positivos} + \text{falsos positivos... Ecuación (2)} \\ \text{Precisión} &= 59 / (59 + 3) \\ \text{Precisión} &= 0.95 \end{aligned}$$

$$\begin{aligned} \text{Recall} &= \text{Verdaderos positivos} / \text{verdaderos} \\ & \text{positivos} + \text{falsos negativos} \\ \text{Recall} &= 59 / (59 + 1) \\ \text{Recall} &= 0.98 \end{aligned}$$

#### IV. DISCUSIÓN

En contraste con el estudio enfocado en la detección de hongos en una planta medicinal utilizando redes neuronales,

que logró una precisión del 75% [13], nuestro proyecto alcanzó una precisión del 95%. Este resultado podría atribuirse a los notables avances en la ciencia contemporánea, además de que en nuestra investigación empleamos el lenguaje de programación YOLOv5, mientras que ellos utilizaron el modelo YOLOv3.

En cuanto a la aplicación de técnicas de visión artificial para identificar defectos externos en mangos, se logró una efectividad del 87.79% [14]. En contraste, nuestro proyecto alcanzó una efectividad del 96.64%. Este logro se atribuye al uso de redes neuronales específicamente diseñadas para detectar la enfermedad de Huanglongbing (HLB) en nuestro trabajo, lo cual resultó en una mayor precisión y exactitud durante las pruebas. En el caso de la detección de defectos externos en mangos mediante técnicas de visión artificial, se utilizaron exclusivamente algoritmos de procesamiento de imágenes como K-Means y Otsu, lo que resultó en una menor efectividad.

La visita al "Fundo Amada" reveló la existencia de enfermedades que afectan negativamente la producción de limones, ofreciendo así una sólida justificación para la implementación del proyecto. La creación de un sistema de visión artificial específicamente diseñado para identificar principalmente la enfermedad de Huanglongbing (HLB) o "dragón amarillo" en las plantas de limón surge como una solución esencial. Este sistema no solo simplifica la detección precisa de la enfermedad para los agricultores, sino que también les proporciona la capacidad de identificar la presencia de la enfermedad incluso cuando no es visible a simple vista. Además, establece una base para futuras investigaciones en el ámbito de la agricultura y el control biológico de plagas.

#### V. CONCLUSIONES

Se ha desarrollado un algoritmo de visión artificial destinado a la detección de la enfermedad de Huanglongbing (HLB) en las plantas de limón en el Fundo Amada, como respuesta oportuna a la crisis en la cosecha de limones que ha afectado al Perú. La implementación de este sistema proporciona una solución tecnológica avanzada y práctica para los agricultores, permitiéndoles identificar de manera rápida y precisa las hojas afectadas por esta enfermedad. La efectividad de este enfoque está respaldada por antecedentes de investigaciones similares en otras regiones, y los resultados obtenidos en el Fundo Amada demuestran una alta eficiencia del algoritmo.

Se llega a la conclusión de que, al operar en un entorno no controlado, como es el caso del Fundo Amada, la implementación del algoritmo demuestra un rendimiento óptimo y brinda asistencia efectiva al agricultor en la detección de la enfermedad del HLB o dragón amarillo.

La integración de herramientas tecnológicas como Python, Tensorflow y YOLOv5, respaldada por el empleo de redes neuronales convolucionales, ha mostrado ser eficaz en la

identificación de la enfermedad HLB, a comparación del algoritmo YOLOv3, ya que este último es de menor precisión y velocidad de detección. Además, es más pesado en tamaño, lo que dificulta su implementación en dispositivos con recursos limitados. Por ende, los resultados alcanzados con el algoritmo YOLOv5 nos generó una tasa mínima de error del 3.36%, señalando que el algoritmo es fiable y capaz de suministrar a los agricultores la información esencial para gestionar de manera efectiva la enfermedad en sus cultivos.

Este proyecto no solo aborda un problema específico en la producción de limones, sino que también sienta las bases para futuras investigaciones y aplicaciones en el ámbito de la detección de enfermedades en la agricultura. La capacidad del algoritmo para adaptarse a entornos no controlados y trabajar eficazmente en diversas condiciones de iluminación y posicionamiento lo hace valioso y aplicable en distintas situaciones. En última instancia, esta labor contribuye al progreso de la tecnología en la agricultura, proporcionando 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] Rusell, S. (2022). Inteligencia Artificial-Un enfoque moderno. Obtenido de <https://luismejias21.files.wordpress.com/2017/09/inteligencia-artificial-un-enfoque-moderno-stuart-j-ru-swell.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%28351jmbntvnsjt1aadkposzje%29%29/journal/paperinformation.aspx?p\\_aperid=99105](https://www.scirp.org/%28S%28351jmbntvnsjt1aadkposzje%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] Hall, R. Salcedo (2018). Principales enfermedades en cítricos Obtenido de [https://www.scielo.org.mx/scielo.php?script=sci\\_arttext&pid=2007-09342019000701653#:~:text=Las%20principales%20enfermedades%20son%3A%20Phytophthora,%2C%20tallos%2C%20ra%C3%ADces%20o%20frutosS](https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=2007-09342019000701653#:~:text=Las%20principales%20enfermedades%20son%3A%20Phytophthora,%2C%20tallos%2C%20ra%C3%ADces%20o%20frutosS)
- [6] Alayon, P., & L., G. (2022). Combinación de tratamientos con fungicidas y nitrato de calcio para el control de la mancha marrón. 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/40/39308\\_Inteligencia\\_artificial.pdf](https://planetadelibrosec0.cdnstatics.com/libros_contenido_extra/40/39308_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] Gonzales & Lifonso (2020). SISTEMA DE VISIÓN COMPUTACIONAL PARA LA IDENTIFICACIÓN DE HELIOTHIS VIRESCENS EN PLANTAS DE ARÁNDANO EN UNA EMPRESA AGROINDUSTRIAL. Obtenido de <https://repositorio.upn.edu.pe/bitstream/handle/11537/23979/Gonz%20%20A1les%20Rafael%20Marianely%20Yoselin%20%20Lifonso%20Zavaleta%20Marisol.pdf?sequence=10>
- [12] Gomez (2021). Sistema de visión artificial para el reconocimiento de enfermedades y plagas en hojas de yuca. Obtenido de <https://repositorio.utb.edu.co/handle/20.500.12585/11805>
- [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] Muñiz 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%91Z%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 Convolutacional. Obtenido de <http://www.diegocalvo.es/redneuronal-convolutacional/>. 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] Hilerá G. (2019). Conceptos básicos sobre redes neuronales. Obtenido de <http://grupo.us.es/gtocom/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/ccwbytes/docencia/mmc/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).