

**Detección de las enfermedades Torque y Podredumbre Morena que afectan a los cultivos
de durazno a partir del uso de la visión por computadora e inteligencia artificial**

Daniel Felipe Silva Gaona

Leyber Orlando Villa Pinto

Luisa Paola Zúñiga Castro

Asesores

Ing. Paola Andrea Mateus Abaunza

Ing. Sandra Milena García Ávila

Universidad Nacional Abierta y a Distancia UNAD

Escuela de Ciencias Básicas, Tecnología e Ingeniería ECBTI

Ingeniería de Telecomunicaciones

2024

Agradecimientos

Agradecemos primeramente a Dios por habernos brindado mucha sabiduría y salud para llevar a cabo este proyecto. Seguidamente no siendo menos importante a la Universidad por brindarnos espacios y aulas altamente calificadas para el desarrollo de actividades que satisficieron nuestros conocimientos durante el proceso de formación, del mismo modo a los tutores que se hicieron partícipes a lo largo de la carrera profesional.

Finalmente agradecemos a nuestra directora Ing. Paola Andrea Mateus Abaunza y codirectora Ing. Sandra Milena García Ávila quienes brindaron sus conocimientos, crearon espacios para asesorarnos y nos guiaron en el proceso del desarrollo del proyecto.

Dedicatorias

Dedico de manera muy especial este proyecto a mi madre, mi padre, mi esposa y hermanos, quienes siempre estuvieron en mi proceso profesional, ellos quienes siempre me motivaron e hicieron que nunca me diera por vencido, que también creyeron en mi desde el inicio y hasta el final, los cuales establecieron en mis bases de responsabilidad y compromiso por mis objetivos, siendo este proyecto uno de mis grandes sueños profesionales.

De igual forma dedico este proyecto a los tutores y tutoras que siempre estuvieron brindando sus conocimientos y nunca negaron una gota de sabiduría para formar una gran persona profesionalmente.

Daniel Felipe Silva Gaona

Este proyecto de grado está dedicado a todas las personas que han sido mi fuente de inspiración y apoyo a lo largo de este camino.

A mi madre, por su amor incondicional, sus sacrificios y su constante aliento. Sin su apoyo, esto no habría sido posible, a mis profesores, por compartir su conocimiento y guiarnos con paciencia y sabiduría. Su dedicación y compromiso son la base de nuestro aprendizaje, mi esposa, por su amor, comprensión y por estar siempre a mi lado en los momentos difíciles y en los momentos de alegría. Su apoyo ha sido fundamental para lograr este objetivo, mis amigos, por su compañerismo y por hacer de esta experiencia algo inolvidable. Sus palabras de ánimo y su compañía han sido fundamentales.

Finalmente, dedico este trabajo a mí mismo, por la perseverancia y el esfuerzo que he puesto en cada paso de este recorrido.

Leyiber Orlando Villa Pinto.

A Dios, por concederme la sabiduría y perseverancia necesarias para superar cada desafío tanto en el desarrollo de mi formación profesional como en la ejecución del proyecto; a mi madre y esposo, por su constante motivación y apoyo, por creer en mis capacidades y alentarme cada día; a mis hermanos, mi total gratitud, especialmente a Lizeth, cuya luz siempre brillará en mi corazón, te dedico este logro hasta el cielo.

Luisa Paola Zuñiga Castro.

Resumen

La presencia de plagas y enfermedades en los cultivos ha sido una constante amenaza para la agricultura, causando una notable disminución en la producción, afectando negativamente la economía de nuestros campesinos. Por lo tanto, se propone el diseño de un sistema para la detección temprana de las enfermedades Torque (*Taphrina deformans*) y Podredumbre Morena (*Monilinia spp*) en los cultivos de durazno ubicados en Cómbita, Boyacá, utilizando visión por computadora e inteligencia artificial.

El sistema integra varias tecnologías y técnicas, principalmente el procesamiento digital de imágenes e inteligencia artificial (IA), con el objetivo de proporcionar a los productores una herramienta que permita la pronta identificación de estas enfermedades, y así, facilitar la toma de decisiones oportunas para mitigar los efectos negativos en los cultivos.

El proyecto se divide en varias etapas. En primer lugar, se recopilan imágenes de frutos y hojas de durazno, tanto sanas como afectadas por Podredumbre Morena y Torque, con el fin de estructurar una base de datos para la aplicación, dicha labor se realiza en un cultivo ubicado en Combita Boyacá, el cual se ha visto afectado de manera constante por estas enfermedades. Posteriormente, se aplican técnicas de procesamiento de imágenes con el fin de resaltar las características relevantes para la detección de enfermedades.

Una vez procesadas las imágenes, se procede al desarrollo del modelo de IA. Se utilizan redes neuronales convolucionales (CNN) debido a su efectividad en tareas de clasificación de imágenes. Estas redes se entrenan a partir del conjunto de imágenes contenidas en la base de datos anteriormente estructurada, ajustando los parámetros del modelo para maximizar la precisión en la identificación de las enfermedades.

Una vez entrenado el modelo, se integra en la aplicación web, la cual fue desarrollada utilizando una plataforma de desarrollo Low Code, para asegurar una experiencia de usuario amigable y eficiente. La aplicación permite a los agricultores cargar imágenes de sus hojas y frutos de durazno a través de una interfaz sencilla desde su equipo móvil. Las imágenes son procesadas por el modelo de IA, el cual genera una predicción indicando si el fruto está sano o si presenta signos de alguna enfermedad, especificando si se trata de Podredumbre Morena en el caso del fruto, o Torque en el caso de la hoja.

Los resultados obtenidos durante las pruebas de la aplicación son excelentes, resaltando altos niveles de precisión en la detección de las enfermedades. Alcanzando un porcentaje de 94.6% de exactitud y 96.4% de precisión en la hoja, y un 91.6% de exactitud y 100% de precisión para el fruto, la aplicación demuestra ser una herramienta confiable para los agricultores, permitiéndoles verificar el estado de sus cultivos y reduciendo el riesgo de pérdidas por enfermedades no detectadas a tiempo.

La realización de este proyecto representa un avance significativo en el uso de tecnología para la agricultura. La combinación de visión por computadora e inteligencia artificial ha permitido desarrollar una solución práctica y efectiva para la detección temprana de enfermedades en el cultivo de durazno, beneficiando a los agricultores, tanto de Combita Boyacá, como del país, potenciando la producción sostenible de esta importante fruta.

Palabras clave: CNN, Inteligencia artificial, Podredumbre Morena, Torque, Visión por computadora.

Abstract

The presence of pests and diseases in crops has been a constant threat to agriculture, causing a notable decrease in production, negatively affecting the economy of our farmers. Therefore, the design of a system for the early detection of Torque (*Taphrina deformans*) and Brown Rot (*Monilinia* spp) diseases in peach crops located in C6mbita, Boyac6, using computer vision and artificial intelligence, is proposed.

The system integrates several technologies and techniques, mainly digital image processing and artificial intelligence (AI), with the aim of providing producers with a tool that allows the early identification of these diseases, and thus, facilitate timely decision-making to mitigate the negative effects on crops.

The project is divided into several stages. First, images of peach fruits and leaves, both healthy and affected by Brown Rot and Torque, are collected in order to structure a database for the application. This work is carried out in a crop located in C6mbita Boyac6, which has been constantly affected by these diseases. Subsequently, image processing techniques are applied in order to highlight the relevant characteristics for the detection of diseases.

Once the images are processed, the AI model is developed. Convolutional neural networks (CNN) are used due to their effectiveness in image classification tasks. These networks are trained from the set of images contained in the previously structured database, adjusting the model parameters to maximize the accuracy in the identification of diseases.

Once the model is trained, it is integrated into the web application, which was developed using a Low Code development platform, to ensure a friendly and efficient user experience. The application allows farmers to upload images of their peach leaves and fruits through a simple interface from their mobile device. The images are processed by the AI model, which generates a

prediction indicating whether the fruit is healthy or shows signs of disease, specifying whether it is Brown Rot in the case of the fruit, or Torque in the case of the leaf.

The results obtained during the application tests are excellent, highlighting high levels of precision in the detection of diseases. Achieving a percentage of 94.6% accuracy and 96.4% precision in the leaf, and 91.6% accuracy and 100% precision for the fruit, the application proves to be a reliable tool for farmers, allowing them to check the status of their crops and reducing the risk of losses due to diseases not detected in time.

The implementation of this project represents a significant advance in the use of technology for agriculture. The combination of computer vision and artificial intelligence has allowed the development of a practical and effective solution for the early detection of diseases in peach crops, benefiting farmers, both in Cómbita, Boyacá, and in the country, promoting the sustainable production of this important fruit.

Keyword: CNN, Artificial intelligence, Brown rot, Torque, Computer vision.

Tabla de Contenido

Introducción	14
Planteamiento del Problema	20
Estado del Arte.....	23
Objetivos	39
Objetivo General.....	39
Objetivos Específicos.....	39
Justificación	40
Marco Teórico y Conceptual	42
Marco Conceptual.....	42
Cultivo.....	42
Durazno.....	42
Plagas y Enfermedades	42
Inteligencia Artificial	43
Procesamiento Digital de Imágenes.....	43
Visión por Computadora.....	43
Marco Teórico.....	44
Torque de Duraznero	44
Podredumbre Morena.....	46
Metodología	47
Etapas del Proyecto.....	48
Etapa 1. Estructuración de la Base de Datos Preprocesamiento de Imágenes.....	48
Etapa 2. Procesamiento de Imágenes.....	50

Etapa 3. Estructuración de la Base de Datos para el Entrenamiento de la Red Neuronal.....	58
Etapa 4. Aplicación de Técnicas de Validación Cruzada	59
Etapa 5. Aplicación de Técnicas de Inteligencia Artificial.....	64
Etapa 6. Aplicación Web	70
Resultados	75
Conclusiones	89
Referencias Bibliográficas	92

Lista de Tablas

Tabla 1 <i>Resumen de los Resultados Obtenidos en los Proyectos Citados en el Estado del Arte</i>	35
Tabla 2 <i>Estructura de la Base de Datos Inicial</i>	59
Tabla 3 <i>Cantidad de Imágenes de Prueba para el Modelo de Entrenamiento del Modelo del Fruto</i>	61
Tabla 4 <i>Cantidad de Imágenes de Prueba para el Modelo de Entrenamiento del Modelo de la Hoja</i>	63
Tabla 5 <i>Imágenes Obtenidas en la Validación Cruzada para el Entrenamiento del Modelo del Fruto.</i>	66
Tabla 6 <i>Imágenes Obtenidas en la Validación Cruzada para el Entrenamiento del Modelo de la Hoja</i>	67
Tabla 7 <i>Registro de Resultados Obtenidos en la Evaluación del Modelo Entrenado para el Fruto.</i>	82
Tabla 8 <i>Registro de Resultados Obtenidos en la Evaluación del Modelo Entrenado para la Hoja</i>	84

Lista de Figuras

Figura 1	<i>Enfermedad de Torque (Taphrina Deformans) en la Hoja de Durazno.</i>	16
Figura 2	<i>Enfermedad de Podredumbre Morena (Monilinia Spp) en el Fruto del Durazno.</i>	17
Figura 3	<i>Resultado del Análisis de Irregularidades en Plantas.</i>	24
Figura 4	<i>Presencia de la Plaga Monalonia en el Aguate Hass.</i>	29
Figura 5	<i>Enfermedad del Torque en el Durazno.</i>	45
Figura 6	<i>Fruto del Durazno Afectado por la Enfermedad Podredumbre Morena.</i>	46
Figura 7	<i>Fotografía Satelital, que Permite Localizar los Cultivos de Duraznos de la Región.</i>	48
Figura 8	<i>Estado de los Frutos y Hojas del Durazno a Procesar.</i>	50
Figura 9	<i>Técnica de Remoción del Fondo en el Fruto de Durazno.</i>	52
Figura 10	<i>Técnica de Remoción del Fondo Aplicada a la Hoja de Durazno.</i>	53
Figura 11	<i>Técnica de Conversión de Colores BGR a RGB</i>	54
Figura 12	<i>Conversión del Espacio de Color a las Imágenes del Fruto</i>	55
Figura 13	<i>Redimensionamiento de las Imágenes al 150 x 150 Píxeles</i>	56
Figura 14	<i>Aplicación de Contornos a los Objetos de Interés en las Imágenes</i>	57
Figura 15	<i>Ejemplo de Uso de la Técnica de Validación Cruzada en Conjunto de Datos</i>	60
Figura 16	<i>Resultado de la Validación Cruzada, Realizada a la Base de Datos Inicial del Fruto de Durazno</i>	62
Figura 17	<i>Resultado de la Validación Cruzada, Realizada a la Base de Datos Inicial de la Hoja de Durazno</i>	64
Figura 18	<i>Resultado del Entrenamiento del Modelo para el Fruto de Durazno.</i>	66
Figura 19	<i>Resultado del Entrenamiento del Modelo para la Hoja de Durazno.</i>	68
Figura 20	<i>Estructura de Matriz de Confusión.</i>	70

Figura 21 <i>Diagrama de Bloques de la Metodología Empleada para el Proyecto.</i>	74
Figura 22 <i>Ejemplo Visual de la Estructura de la Base de Datos Inicial del Proyecto.</i>	76
Figura 23 <i>Aplicación de la Técnica de Remoción de Fondo para la Obtención de la Región de Interés en la Imagen.</i>	77
Figura 24 <i>Resultado de la Validación Cruzada Aplicada para el Fruto, Alcanzando un Accuracy del 90.28%.</i>	78
Figura 25 <i>Resultado de la Validación Cruzada Aplicada para la Hoja, Alcanzando un Accuracy del 96.43%.</i>	79
Figura 26 <i>Proceso de Entrenamiento del Modelo para el Fruto de Durazno.</i>	79
Figura 27 <i>Proceso de Entrenamiento del Modelo para la Hoja de Durazno.</i>	81
Figura 28 <i>Resultado de la Matriz de Confusión de la Evaluación Realizada a el Modelo IA del Fruto.</i>	83
Figura 29 <i>Resultado de la Matriz de Confusión de la Evaluación Realizada a el Modelo Ia de la Hoja.</i>	85
Figura 30 <i>Interfaz de la Aplicación Web, donde se Muestra el Resultado Arrojado sobre el Estado del Fruto de Durazno.</i>	86
Figura 31 <i>Interfaz de la Aplicación Web, donde se Muestra el Resultado Arrojado sobre el Estado de la Hoja de Durazno.</i>	87
Figura 32 <i>Logo de la Aplicación Web.</i>	88

Introducción

La adecuada identificación de problemáticas da lugar a diferentes ideas de soluciones que contribuyen en la construcción de nuevas herramientas tecnológicas, las cuales se pueden implementar en múltiples campos o áreas de aplicación, entre ellas, los cultivos.

El fruto durazno (*Prunus Pérsica*) es originario de china y mediante el comercio de frutos se fue esparciendo y ahora es cultivado a lo largo del mundo, este árbol frutal forma parte de la familia de Rosaceae. Se cultiva en climas templados, donde para Colombia de acuerdo con las condiciones agroecológicas se ubica en un rango de 1800 (msnm) hasta 2600 (msnm) siendo el adecuado para alcanzar excelentes cosechas según (TvAgro, 2019). Este árbol es de tamaño pequeño alcanzando máximo 6 (Mts) de altura, siendo caducifolio, de tallo y copa mediana además de corteza lisa. En lo que corresponde a las hojas son simples, lanceoladas que pueden alcanzar los 15 centímetros de longitud, un ancho hasta de 3,5 cm, un peciolo que puede lograr los 1,5 cm presenta margen aserrado y haz de un verde brillante («SIPSA», 2020). En cuanto al fruto es una drupa de forma oblonga, ovalada o redonda de 4 a 10 cm, la epidermis (piel) es delgada, de colores amarillentos, rojizo o purpura; el mesocarpio (pulpa) es carnoso de colores blanco, amarillo o rojo y el endocarpio (hueso) contiene la semilla que es una almendra (Baugher, 2003).

En la actualidad se conoce que Colombia cuenta con aproximadamente 40 variedades del fruto, donde se encuentran fresa morado, Pezón de Venus, Fresa blanco, Elberta gigante, Rubidoux, Frank, Ventura, Diamante, Riograndense, Dorado, Conservero amarillo y Zapallo tal como lo indica (Ordoñez, 2007). El durazno (*Prunus pérsica*) puede ser consumido de múltiples maneras, tales como fruto fresco, jugo, jalea, almíbar, pure, mermeladas, entre otros.

Por otra parte, el durazno (*Prunus Pérsica*) en el departamento de Boyacá cuenta con una extensión sembrada de 813,69 hectáreas, donde su producción para el año 2022 fue de 11830,05 toneladas siendo el 37,79% de la producción nacional, donde se le concede el segundo puesto entre 7 departamentos productores de durazno para el país de Colombia, (*Agronet Inicio*, n.d.).

Según el documento "*Plantación y Sosténimiento de Una Hectárea de Cultivo de Durazno (Prunus Pérsica) En La Vereda Las Jarras Municipio de Isnos*" (n.d.), el proceso de siembra de una hectárea de durazno requiere una inversión de \$20.085.200, que incluye costos de trabajo, equipos, fertilizantes y otros insumos. Este contexto subraya el riesgo de pérdidas económicas debido a la disminución en la calidad de la producción de los cultivos de durazno, asociado a la presencia de enfermedades. De esta manera, surge el interrogante: ¿Cómo puede la inteligencia artificial y la visión por computadora aportar a la detección de enfermedades como "Torque" y "Podredumbre Morena" en cultivos de durazno?, ya que se hace evidente la necesidad de detectar e identificar dichas enfermedades de manera temprana, permitiendo al productor aplicar tratamientos oportunos en su cultivo para evitar pérdidas económicas y preservar los empleos.

Teniendo en cuenta la problemática, se lleva a cabo desde el área de la ingeniería, la creación de una herramienta que con tan solo una imagen capturada desde su equipo móvil, le brinde al productor de duraznos la información sobre el estado de su cultivo.

Por consiguiente, se desarrolla y pone en marcha una aplicación web, fundamentada en la visión por computadora y la inteligencia artificial. Esta herramienta facilita el proceso de inspección visual realizado por personal especializado, reduciendo el tiempo de detección de enfermedades tales como: Torque (*Taphrina deformans*) y Podredumbre Moreno (*Monilinia spp*) en el cultivo de durazno, identificadas como las principales enfermedades que afectan dicho

cultivo. Según Ávila et al., (2013), el Torque (*Taphrina deformans*) es una de las enfermedades más predominantes en el departamento de Boyacá dañando un 30% de los cultivos, causada por un parásito que afecta la hoja del durazno (*Prunus pérsica*), las ramas y los frutos, esto desfavoreciendo el rendimiento considerablemente y la longevidad de las plantaciones, como se muestra en la Figura 1. **¡Error! No se encuentra el origen de la referencia.** Las condiciones favorables para la proliferación de la enfermedad en cuanto a su temperatura son mayores a 2,5°C y menor a 22°C que sería el rango ideal para la producción de esporas y con una humedad superior al 50% (Rossi y Languasco, 2007).

Figura 1

Enfermedad de Torque (Taphrina Deformans) en la Hoja de Durazno.



Fuente. Autoría propia, se evidencia la afectación que causa la enfermedad sobre toda la rama.

La Podredumbre Morena (*Monilinia spp*) es otra enfermedad que ataca inicialmente a la flor, evidenciándose en pequeñas manchas marrones que se extienden a través de los pétalos, marchitándolos y dejándolos adheridos a la rama, luego el hongo avanza sobre

ella produciendo una lesión llamada cancro, estos cancos pueden anillar la rama produciendo su muerte. Esta enfermedad también ataca a los frutos maduros, desarrollando el síntoma de Podredumbre Morena (*Monilinia spp*), la cual es de color marrón y avanza rápidamente atacando el fruto, generando su caída y posterior descomposición, en algunos casos el fruto afectado se queda en la rama hasta momificarse, logrando que la rama pueda secarse completamente, indicando un caso severo de la enfermedad. (Mondino, P., Alaniz, S., & Leoni, C. (2010)). En la Figura 2. se muestra el efecto de la enfermedad sobre un fruto maduro.

Figura 2

Enfermedad de Podredumbre Morena (Monilinia Spp) en el Fruto del Durazno.



Fuente. Autoría propia, se evidencia como la enfermedad de Podredumbre Morena se va extendiendo por el fruto de durazno.

El aplicativo web propuesto utiliza técnicas avanzadas de reconocimiento y tratamiento de imágenes para determinar el estado del fruto y/o hoja a partir de características específicas.

Así, se convierte en un aliado para el productor, permitiéndole definir la mejor opción para la prevención y/o restauración de su cultivo. Técnicamente, el sistema emplea visión por computadora e inteligencia artificial, donde el usuario ingresa una imagen desde su dispositivo y el aplicativo web retorna un resultado sobre el estado del fruto u hoja.

El proceso se divide en dos etapas:

Procesamiento de imagen.

Análisis del modelo entrenado bajo redes neuronales convolucionales (*RCNN2*).

En la etapa de procesamiento de imagen, se aplican diversas técnicas necesarias para optimizar la imagen, haciéndola legible, comprensible y fácil de procesar por el sistema de inteligencia artificial. Estas técnicas incluyen la remoción de fondo, el ajuste del espacio de colores RGB y el redimensionamiento de la imagen. Además, se utilizan algoritmos para la detección de contornos y la superposición, lo que permite resaltar características específicas relevantes para el análisis, asegurando así que el sistema de inteligencia artificial pueda interpretar y procesar la imagen de manera eficiente y precisa.

En la etapa de análisis del modelo entrenado bajo redes neuronales convolucionales (*RCNN2*), se realiza la detección de la clase de enfermedad que padece el cultivo, en tiempo real y de forma precisa, según sea la enfermedad, ya sea "Torque" o "Podredumbre Morena". Esto se logra gracias a una base de datos previamente preparada mediante técnicas de validación cruzada, lo que garantiza la robustez y fiabilidad del modelo. Además, se emplean técnicas avanzadas de preprocesamiento y optimización para mejorar la exactitud de las predicciones y reducir los falsos positivos y negativos, permitiendo una intervención temprana y eficaz en el manejo de las enfermedades del cultivo.

El proyecto se encuentra ligado a línea de investigación de Ingeniería de Software y Automatización de Herramientas Lógicas para la carrera profesional de ingeniería de telecomunicaciones, además está asociado al proyecto de investigación sobre “*Identificación de enfermedades en el durazno (prunus persica) mediante el uso de técnicas de visión por computadora e inteligencia artificial*” por convocatoria interna 12 del año 2023. Proyecto presentado por la universidad Nacional Abierta y a Distancia (UNAD) en alianza institucional con la universidad ECCI, de tal manera, el presente proyecto está aportando a través del uso de herramientas tecnológicas, la detección temprana de las enfermedades, Torque (*Taphrina deformans*) y Podredumbre Morena (*Monilinia spp*), buscando la conservación y buenas prácticas de sanidad en los cultivos de durazno (*Prunus Pérsica*).

Planteamiento del Problema

En diferentes tipos de cultivos, se logra evidenciar que existen múltiples factores que influyen en la aparición de enfermedades y en la proliferación de plagas. La mayoría de estos factores se deben a que no se realizan los procedimientos correctos, tanto para definir el terreno apto para la siembra, como para la fertilización y la aplicación de productos, con el fin de minimizar el impacto de hongos, plagas y demás.

Aparte de esto, se conoce que muchas de las prácticas utilizadas en el cultivo se basan en experiencias del cultivador, que, si bien alguna vez fueron exitosas, pueden no funcionar en la totalidad de los casos, ya que carecen de estudios técnicos que las refuercen. Esto influye fundamentalmente en el problema, según TvAgro (2019), ya que, al hablar específicamente del cultivo de durazno, la aparición de enfermedades está ligada a no llevar a cabo un reconocimiento de los factores de humedad relativa, ubicación del terreno, intensidad solar en horarios de mayor nivel, entre otros, donde la afectación es directamente a la planta y, posteriormente, a la producción, generando grandes pérdidas económicas y daños en el terreno.

Las pérdidas económicas para el proceso de siembra del cultivo de durazno, para un terreno de 1 hectárea, según Gómez (2018), aproximadamente ascienden a \$20.085.200, considerando los costos de trabajo, equipos, fertilizantes y demás. Esto afecta grandemente la economía del agricultor, quien labra la tierra para su sustento diario, y de la misma forma, se afecta la comercialización y oferta del producto para la región.

La enfermedad del Torque (*Taphrina deformans*) es la más presente en los cultivos de durazno, según Ávila et al. (2013). Esta es una de las enfermedades más predominantes en el departamento de Boyacá, dañando un 30% de los cultivos. Se presenta mediante un parásito que afecta la hoja del durazno, las ramas y los frutos, desfavoreciendo considerablemente el rendimiento y la longevidad de las plantaciones. Las condiciones favorables para la proliferación de la enfermedad incluyen una temperatura mayor a 2.5 °C y menor a 22 °C, que es el rango ideal para la producción de esporas, y una humedad superior al 50% (Rossi y Languasco, 2007).

La Podredumbre Morena (*Monilinia spp*), es otra enfermedad que ataca inicialmente a la flor, evidenciándose en pequeñas manchas marrones que se extienden por toda la flor, marchitándola y dejándola adherida a la rama. Posteriormente, el hongo avanza sobre ella, produciendo una lesión llamada cancro. Estos canchros se invaden por encima y debajo de la flor, siendo de color marrón, y también pueden anillar la rama, produciendo su muerte. Esta enfermedad también ataca a los frutos maduros, desarrollando el síntoma de Podredumbre Morena, que es de color marrón y avanza rápidamente, atacando todo el fruto, el cual puede caerse y descomponerse o quedarse en la rama, momificándose.

Cuando el ataque es muy severo, la rama puede secarse completamente (Mondino, P., Alaniz, S., & Leoni, C. (2010)).

La enfermedad de Podredumbre Morena (*Monilinia spp*) puede causar bastantes pérdidas directas en la producción debido a la infección en las flores (tizón de flores y brotes) y la podredumbre de frutos en pre y postcosecha (dos Santos et al., 2012, como se citó en Leone, 2017). Además, se presentan pérdidas indirectas por el alto costo en la aplicación de fungicidas durante el proceso de floración y el desarrollo del fruto hasta la postcosecha (Emery et al., 2000; Mitidieri, 2012, como se citó en Leone, 2017). Sin un manejo adecuado, las pérdidas de

producción y cosecha pueden superar el 80% (Venancio et al., 2012, como se citó en Leone, 2017), afectando gran parte de la totalidad de la cosecha que se pretende comercializar para el beneficio económico del agricultor.

De acuerdo con lo anterior, surge la siguiente pregunta de investigación ¿Cómo puede la inteligencia artificial y la visión por computadora aportar para la identificación de enfermedades como Torque y Podredumbre Morena en cultivos de durazno?

Estado del Arte

La adopción de la inteligencia artificial para la detección de enfermedades en hojas y frutos en distintos cultivos ha contribuido significativamente en la agricultura moderna. Esta tecnología permite identificar de manera temprana plagas y enfermedades en las plantaciones, optimizando así el uso de recursos como pesticidas y fertilizantes, lo que resulta en una disminución de costos y un menor impacto ambiental.

Estos resultados han sido posibles gracias a estudios enfocados en problemas específicos que afectan al sector agrícola y a sus inversores. Por lo tanto, es fundamental conocer las técnicas empleadas y los casos de éxito recientes, donde se han combinado los conocimientos de los profesionales con las tecnologías de procesamiento de imágenes y redes neuronales.

Para garantizar altos niveles de precisión en el desarrollo del proyecto, se han consultado diversos artículos que aportan información significativa. Estos artículos se centran en técnicas y procesos utilizados en investigaciones que abordan problemáticas similares.

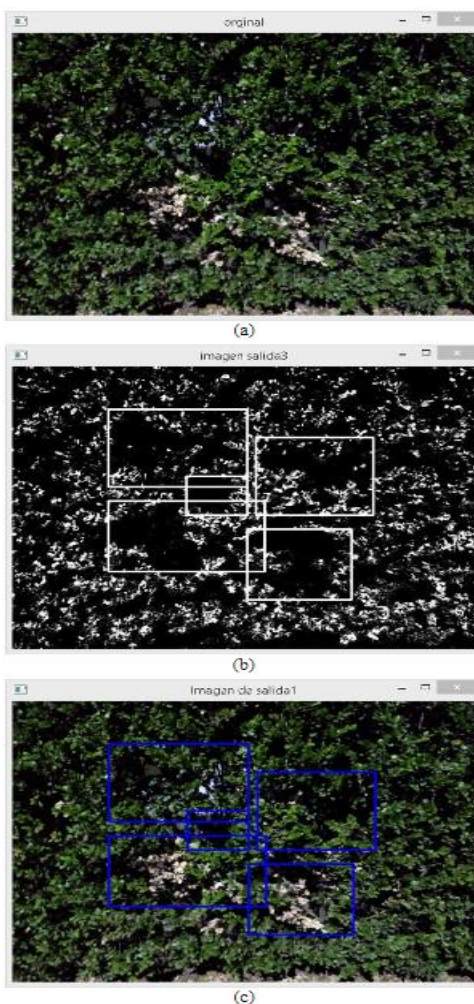
A continuación, se citan algunos artículos científicos que describen las herramientas tecnológicas que han aportado significativamente en la identificación de enfermedades en los cultivos.

Villasana-Montes et al. (2023), propone un proyecto para la detección de irregularidades en las hojas de los cultivos mediante la adquisición y procesamiento digital de imágenes, tal como se muestra en la Figura 3, lo cual se lleva a cabo utilizando una tarjeta de procesamiento con el sistema operativo Raspberry Pi y programación desarrollada en Python, implementando

un algoritmo que funciona como clasificador de colores, segmentando las imágenes en tiempo real utilizando la función `cv2`, ajustando dinámicamente los umbrales basados en tonos verdes predominantes en el follaje, la detección de irregularidades se da empleando un clasificador que analiza y clasifica los píxeles según su valor RGB, seleccionando automáticamente los umbrales más adecuados.

Figura 3

Resultado del Análisis de Irregularidades en Plantas.



Fuente. Villasana-Montes et al., 2023, zona de interés obtenida en el proceso de inspección, en la figura, (a) representa la imagen original, (b) es la visualización del resultado de segmentación y

el enmarcado de las irregularidades, y (c) una mezcla de la imagen original con la sobreposición de los marcos.

Gope y Fukai (2022). Desarrollaron un sistema de clasificación de granos de café verdes implementado en una Raspberry Pi3. El sistema alcanzó una frecuencia de muestreo de 13.77 imágenes por segundo y una exactitud superior (98.19%) utilizando redes neuronales convolucionales. Las imágenes a color utilizadas para la clasificación tenían una resolución de 64x64 píxeles.

De esta manera se tienen en cuenta las principales herramientas que sugieren los autores, las cuales pueden contribuir a la identificación de irregularidades tanto en el fruto como en la hoja del cultivo del durazno, teniendo en cuenta las evidentes variaciones de colores que producen las diferentes enfermedades en el cultivo, más sin embargo, se busca que la adquisición de la imagen la realice directamente el agricultor por medio de la cámara de su equipo móvil, dicha imagen será procesada en tiempo real por la programación realizada, la cual esta propuesta para ser alojada en la web, evitando el uso de tarjetas de procesamiento.

El proyecto de Azadnia et al. (2023b). Desarrolló un sistema automatizado para clasificar frutos de espino según su maduración utilizando visión artificial y técnicas de aprendizaje profundo (DL). Las imágenes de los frutos se capturaron con un teléfono inteligente y se preprocesaron para separar el fruto del fondo. Se utilizó una red neuronal convolucional (CNN) modificada, combinando capas convolucionales, de agrupación máxima, activación ReLU y normalización por lotes para extraer características de las imágenes y clasificar los frutos en tres etapas de madurez: inmaduro, maduro y demasiado maduro.

Los resultados demostraron que los modelos DL, específicamente Inception-V3, ResNet-50 y la CNN propuesta, superaron a los algoritmos tradicionales de aprendizaje automático (ML)

en precisión, alcanzando valores del 100%, 99.63% y 99.63%, respectivamente. El sistema de clasificación automatizado se mostró eficaz y rentable, utilizando imágenes de teléfonos inteligentes en lugar de equipos sofisticados. Las métricas de evaluación indicaron una alta eficiencia de las redes DL, haciendo viable su aplicación en la industria alimentaria para la clasificación automatizada de fruta.

De acuerdo con el proyecto anteriormente mencionado se pueden extraer conclusiones muy valiosas para la detección de enfermedades en el cultivo del durazno, ya que se encuentra ajustado a varios de los requerimientos, entre los que se encuentran la adquisición de la imagen por medio de un equipo móvil, extracción de las características del fruto por medio de clasificadores y una alta precisión de análisis.

El trabajo de L et al. (2024). Consiste en crear un modelo para detectar enfermedades en tomates usando redes neuronales convolucionales (CNN). Este diseño incluye tres capas de filtros y de agrupación, cada una con muchos filtros. Se usaron datos de hojas de tomate del conjunto de datos “Plant Village” para la investigación. La información se divide en nueve grupos de enfermedades y una clase de imágenes saludables. Como no todas las clases de imágenes tienen el mismo número de ejemplos, se usó un proceso llamado aumento de datos para equilibrarlas. Los experimentos mostraron que la precisión del modelo varía entre el 76% y el 100% para las diferentes clases. Además, el modelo tiene una precisión general del 91,2%. El espacio necesario para almacenar el modelo es de unos 1.5 MB, mientras que el modelo original necesita alrededor de 100 MB, lo que muestra las ventajas de este modelo.

Por otra parte, Y. R. Ricardo et al. (2023). Se centra en la detección de malezas en cultivos de albahaca utilizando el algoritmo YOLO (You Only Look Once) para la identificación y clasificación de objetos. El proceso incluye la adquisición de imágenes en campo abierto con

una cámara de celular, la preparación de datos mediante el etiquetado manual de las malezas en las imágenes, y el entrenamiento del modelo YOLO V4 utilizando Google Colab. Se mencionan herramientas de procesamiento de imágenes como OpenCV y Matlab, y se detalla cómo se validó el modelo para identificar malezas eficientemente, mostrando las malezas con cuadros delimitadores de color fucsia.

La elección de YOLO V4 se basa en su eficacia y capacidad de funcionar en diferentes sistemas operativos. El proyecto también implica una revisión de la literatura para identificar las técnicas más adecuadas, y la plataforma Google Colab se utilizó para el entrenamiento y despliegue del modelo. Los resultados muestran una eficiencia del 69.70% después de tres horas de entrenamiento. Se concluye recomendando el uso de más imágenes y la exploración de otros algoritmos como EfficientDet o RetinaNet para futuras mejoras.

El proyecto aporta información relevante acerca de la estructuración del mismo, más, sin embargo, en la práctica se logra evidenciar que la plataforma Google Colab no satisface totalmente las necesidades del proyecto, ya que no permite la ejecución del programa de manera automática al momento de cargar una imagen para analizar, además de requerir un mayor porcentaje de eficiencia.

Helal Sheikh et al. (2019). Describe una revisión de investigaciones y técnicas para detectar enfermedades en plantas como maíz y durazno, resaltando el uso de modelos predictivos, procesamiento de imágenes y redes neuronales convolucionales (CNN) para mejorar la precisión y eficiencia en la detección. Se enfatiza el uso de tecnologías avanzadas como el procesamiento de imágenes y CNN para la detección en tiempo real, facilitando herramientas accesibles incluso para personas con pocos conocimientos técnicos.

Se recopilaron más de 8000 imágenes de hojas de maíz y durazno, las cuales se preprocesaron y dividieron en conjuntos de entrenamiento y prueba. El modelo CNN multicapa utilizado mostró una precisión inicial de entrenamiento del 78.99% y una precisión de validación del 39.17%, aumentando a una precisión de validación del 99.28% después de múltiples ejecuciones.

El proyecto de Ricardo (2023). Se enfoca en desarrollar una aplicación móvil para dispositivos Android que utiliza tecnologías de Visión Artificial y Deep Learning para identificar la plaga *Monalonion* en aguacates Hass. Esto responde a la necesidad de los agricultores de la región de San Agustín, Huila, de combatir esta plaga que afecta sus cultivos. La introducción del proyecto destaca la importancia de estas tecnologías en la agricultura, especialmente en la detección de enfermedades en cultivos, mencionando la plaga *Monalonion* como una preocupación principal de los agricultores locales.

El diseño metodológico incluye el uso de herramientas como TensorFlow Lite para el Machine Learning y la recopilación de datos a través de imágenes etiquetadas de aguacates afectados por la plaga, aguacates sanos y otros con enfermedades, para entrenar el modelo de detección. La aplicación móvil desarrollada integra este modelo para proporcionar a los usuarios resultados de detección en tiempo real, con una precisión promedio del 90% en la detección de la plaga, así como se muestra en la Figura 4, además se destaca su capacidad para funcionar sin conexión a internet, siendo una herramienta práctica y accesible para los agricultores.

Figura 4

Presencia de la Plaga Monalonion en el Aguate Hass.



Fuente. Ricardo, 2023, se observa como la aplicación móvil detecta la plaga de Monalonion y el porcentaje de exactitud.

De acuerdo con Robles y Cesar (2020), los modelos neuronales creados mediante la librería TensorFlow pueden ser exportados en una versión más liviana y utilizados en aplicaciones para Android o iOS. En su trabajo de maestría, Casa Robles desarrolla un modelo para la clasificación de imágenes basado en una red neuronal utilizando TensorFlow Lite con Python. Durante el proyecto, se probaron diferentes tipos y configuraciones de redes neuronales. Los modelos evaluados y seleccionados se implementaron en una aplicación para Android, desarrollada en Android Studio y Bazel.

Dichos proyectos abren las puertas al uso de librerías especializadas en análisis de datos e imágenes, así como la implementación de aplicaciones adaptables a los diferentes dispositivos o responsivas, Los sitios web responsivos ajustan su diseño y contenido automáticamente para ofrecer una experiencia de usuario óptima, sin importar el dispositivo desde el cual se acceda.

Sullca et al. (2018). Propone un modelo de reconocimiento de enfermedades y plagas en hojas de arándano para abordar problemas en los cultivos, permitiendo un análisis instantáneo a través de capturas de imagen o vídeos. Este sistema, una vez desarrollado, podrá ser implementado en dispositivos móviles o aparatos mecánicos para monitorear continuamente los cultivos y detectar anomalías.

La metodología incluyó la recopilación de imágenes de hojas de arándano, su preprocesamiento y segmentación mediante conversiones de color y aplicaciones de filtros como Gaussiano y Mediana para mejorar la calidad de las imágenes. Se utilizaron algoritmos de extracción de características y aprendizaje como HOG y LBP, entrenando el modelo con SVM y evaluándolo con diferentes algoritmos, resultando en una precisión del 85.6%, lo que indica la eficacia del modelo para predecir el estado de las plantas de arándano.

La investigación culmina con la validación del modelo mediante la separación de datos de prueba y test, evaluando su precisión en la clasificación de hojas enfermas y sanas. Los resultados muestran que el modelo entrenado con redes neuronales y características extraídas con LBP tuvo el mejor rendimiento, destacando la posibilidad de mejorar aún más el sistema mediante la expansión de la base de datos de entrenamiento.

Este enfoque sistemático, desde la recolección de datos hasta la evaluación del modelo, demuestra la viabilidad de aplicar técnicas de aprendizaje automático en la detección temprana

de enfermedades y plagas en cultivos de arándano, ofreciendo una herramienta efectiva para la gestión y protección de estos cultivos agrícolas.

Esta investigación concluye que se obtienen mejores resultados y mayor precisión mediante la expansión de la base de datos, lo cual es un punto clave en la detección de enfermedades en el cultivo de durazno ya que se requiere una precisión alta.

El artículo de Gautam et al. (2023). Se enfoca en el desarrollo de un método avanzado para detectar y clasificar enfermedades en las hojas de mango mediante técnicas de aprendizaje automático y profundo. Comienza describiendo un conjunto de datos detallado que abarca ocho clases de enfermedades comunes en hojas de mango, junto con imágenes de hojas sanas, totalizando unas 2000 imágenes. Entre las enfermedades incluidas se encuentran el mildiú polvoriento, antracnosis, muerte regresiva, tizón bacteriano, roya roja, fumagina y malformación del mango.

La metodología propuesta abarca tres niveles clave. En el primer nivel, se realiza un riguroso preprocesamiento y aumento de datos para mejorar la calidad y diversidad del conjunto de imágenes, incluyendo operaciones como voltear, rotar y desplazar, junto con técnicas de mejora de color y eliminación de ruido. En el segundo nivel, se desarrolla un modelo de aprendizaje profundo estructurado en redes neuronales apiladas para extraer características significativas de las imágenes segmentadas, permitiendo la identificación precisa de enfermedades. En el tercer nivel, se utiliza un modelo de aprendizaje automático que combina la información de las redes neuronales profundas para realizar la clasificación final de las enfermedades de las hojas de mango.

El estudio también incluye una evaluación comparativa exhaustiva, contrastando el rendimiento del modelo propuesto con otros modelos de aprendizaje profundo de última

generación. Los resultados muestran una superioridad significativa en términos de precisión de clasificación, destacando la eficacia y robustez del enfoque propuesto para la detección y clasificación de enfermedades vegetales, lo que tiene implicaciones importantes en la agricultura de precisión y la gestión de cultivos.

Geetharamani y Arun Pandian (2019). Proporciona una visión detallada de la identificación de enfermedades en hojas de plantas utilizando una red neuronal convolucional profunda de nueve capas.

El proceso comienza con la adquisición y preprocesamiento de datos utilizando imágenes de hojas sanas y enfermas descargadas de PlantVillage, con un total de 54,305 imágenes de 13 tipos de plantas. Se aplican transformaciones de imágenes para aumentar el conjunto de datos y reducir el sobreajuste. La configuración experimental se realiza utilizando bibliotecas en Python como scikit-learn, Keras, Pillow y OpenCV, ejecutando el entrenamiento en una NVIDIA DGX-1 V100.

El entrenamiento de la red Deep CNN se lleva a cabo en dos conjuntos de datos: uno con imágenes aumentadas y otro sin aumentar. La arquitectura de la red incluye capas convolucionales, de agrupación, de deserción y densas, optimizadas con descenso de gradiente y mini lotes para mejorar la eficiencia y reducir el sobreajuste.

El modelo se entrena y valida con 3000 épocas en el conjunto de datos aumentado, logrando una precisión de validación del 97,87%. Se comparó con otros modelos de aprendizaje automático y de transferencia, mostrando un rendimiento superior en la precisión de predicción del 96,46% en el conjunto de pruebas.

En conclusión, el modelo Deep CNN propuesto demuestra una capacidad eficaz para clasificar 38 clases diferentes de hojas de plantas sanas y enfermas, con mejoras significativas

mediante el aumento de datos y una arquitectura optimizada de la red neuronal convolucional profunda.

Respecto al proyecto mencionado cabe recalcar que Plant Village cuenta con imágenes tomadas en entornos controlados, donde no se consideran situaciones reales, principalmente de las imágenes, resolución de las cámaras, iluminación, la variedad en el tamaño y formas de los síntomas, entre otras.

Sajitha et al. (2023). Se centra en la descripción del conjunto de datos utilizado para el estudio, la configuración de implementación, los resultados de la simulación y el rendimiento general de un sistema desarrollado para la detección de calidad del banano mediante aprendizaje automático. El conjunto de datos consta de 1164 fotografías de plátanos, con seis imágenes por cada plátano que muestran diferentes vistas laterales. Se utilizó el modelo KEGCNN para la detección de calidad, tomando solo las imágenes de vista frontal y utilizando características como los valores RGB y las dimensiones de tamaño para cada imagen. Se realizaron experimentos comparativos con modelos como ResNet 50, Inception ResNet V2 y GCNN.

El modelo KEGCNN se entrenó utilizando el 80% de las imágenes del conjunto de datos y se evaluó utilizando validación cruzada f-fold. Se utilizaron hiper parámetros optimizados con el optimizador Adam y una tasa de aprendizaje de 0,0001. Los resultados mostraron que el modelo KEGCNN logró una precisión promedio del 98% en la detección de calidad de los plátanos, superando a los modelos comparativos. La matriz de confusión mostró una identificación precisa de las diferentes clases de calidad de los plátanos, destacando la capacidad del modelo para distinguir y eliminar plátanos de calidad inferior.

Además, se discutió la regularización del modelo para mejorar su generalización y se presentaron las curvas de precisión del entrenamiento y las pruebas, así como las curvas de

pérdida. Estos resultados indicaron una convergencia efectiva y una alta capacidad del modelo para categorizar y generalizar imágenes de diferentes clases de calidad de plátanos, lo que sugiere su potencial para mejorar la gestión de la calidad de la fruta en la agricultura y las industrias procesadoras de frutas.

En el artículo Borrmann et al. (2020). Utiliza Deep Learning para identificar tomates en condiciones de cultivo, abordando la complejidad derivada de la redundancia del color verde, ya que los tomates en su madurez permanecen verdes. Para obtener grandes cantidades de imágenes, se emplearon técnicas de aumento de datos como rotación vertical y horizontal, transformaciones y rotaciones de las imágenes originales. Se utilizaron redes neuronales pre-entrenadas, incluyendo AlexNet, ResNet18, ResNet50, ResNet152, VGG16, VGG19, entre otras. los mejores resultados se obtuvieron con la red ResNet18.

Tabla 1*Resumen de los Resultados Obtenidos en los Proyectos Citados en el Estado del Arte*

Autores	Proyecto	Técnica	Rendimiento
Villasana-Montes et al. (2023)	Diseño de sistema de monitoreo para detección temprana de enfermedades y plagas superficiales en plantas mediante visión artificial.	Clasificador de colores (segmentación de imágenes).	Se logra segmentar las irregularidades en el follaje del cultivo.
Gope y Fukai (2022)	Clasificación de granos de café normal y Peaberry mediante CNN, SVM y KNN: Su implementación y limitaciones de Raspberry Pi 3.	Redes neuronales convolucionales (CNN), máquinas de vectores de soporte (SVM), y k-vecinos más cercanos (KNN).	El sistema alcanzó una frecuencia de muestreo de 13.77 imágenes por segundo y una exactitud superior (98.19%) utilizando redes neuronales convolucionales.
Azadnia et al. (2023b).	Detección inteligente y control de residuos de frutos de espino en función del nivel de maduración mediante un sistema de visión artificial y técnicas de aprendizaje profundo.	Visión artificial y técnicas de aprendizaje profundo (DL) y utilizó una red neuronal convolucional (CNN) modificada.	Se obtuvo una precisión en Inception-V3 del 100%, ResNet-50 del 99.92% y la CNN propuesta del 99.63%
L et al. (2024).	Detección de enfermedades de la hoja del tomate mediante CNN.	Uso de redes neuronales convolucionales (CNN), AlexNet y SVM.	El modelo obtuvo una precisión general del 91,2%.
Y. R. Ricardo et al. (2023).	Técnica de identificación de	Utilizando el algoritmo YOLO	Los resultados muestran una eficiencia del 69.70%

Autores	Proyecto	Técnica	Rendimiento
	malezas en cultivos de albahaca mediante visión por computadora.	V4(You Only Look Once) para la identificación y clasificación de objetos complementado con procesamiento de imágenes (Deep Learning).	después de tres horas de entrenamiento.
Helal Sheikh et al. (2019).	Detección de enfermedades de la hoja del maíz y del durazno mediante Procesamiento de imágenes.	Usan modelos predictivos, procesamiento de imágenes y redes neuronales convolucionales (CNN).	El modelo CNN multicapa utilizado mostró una precisión inicial de entrenamiento del 78.99% y una precisión de validación del 39.17%, aumentando a una precisión de validación del 99.28% después de múltiples ejecuciones.
Ricardo (2023).	Desarrollo de aplicación Android móvil utilizando Visión Artificial y Deep Learning para la identificación de aguacates Hass con la plaga Monalonion, en la finca “Las Palmas”, ubicada en el municipio de San Agustín, Huila.	Utiliza tecnologías de Visión Artificial y Deep Learning.	Se obtuvo una precisión promedio del 90% en la detección de la plaga.
Robles y Cesar (2020).	Desarrollo de aplicaciones móviles de clasificación y detección de objetos a partir de redes convolucionales ligeras.	Se utiliza Machine Learning (ML) con la biblioteca: Tensor Flow lite y utilizando redes neuronales pre	MobileNet como el modelo eficiente que manifiesta una buena relación entre el rendimiento de las métricas y los tiempos de inferencia en ambas tareas,

Autores	Proyecto	Técnica	Rendimiento
Sullca et al. (2018).	Detección de enfermedades y plagas en las hojas de arándanos utilizando técnicas de visión artificial	entrenadas como (MobileNetV2, MNasNet, ResNet50, VGG16). Se utilizo algoritmo de aprendizaje SVM (Suport Vector Machine), Random Forest y Redes neuronales.	concretamente MobileNetV2 en clasificación y MobileNetV1 con una profundidad de 0.75 para detección y ambos con niveles de cuantificación de enteros de 8 bits. Obteniendo una precisión del 85.6%, lo que indica la eficacia del modelo para predecir el estado de las plantas de arándano.
Gautam et al. (2023).	ESDNN: una nueva red neuronal profunda de pila ensamblada para la clasificación y detección de enfermedades de la hoja del mango.	Se utiliza red neuronal profunda apilada con modelo matemático (CNN) (ECNN).	El modelo propuesto tiene un 98.57% de precisión de aprendizaje.
Geetharamani y Arun Pandian (2019).	Identificación de enfermedades de las hojas de las plantas mediante una red neuronal convolucional profunda de nueve capas.	Se utiliza red neuronal Deep CNN, algoritmo de aprendizaje SVM (Suport Vector Machine) y el algoritmo de clasificación simple basado en memoria(K-NN).	Se logra una precisión de validación del 97,87%. Se comparó con otros modelos de aprendizaje automático y de transferencia, mostrando un rendimiento superior en la precisión de predicción del 96,46% en el conjunto de pruebas.
Sajitha et al. (2023).	Aplicación de agricultura inteligente que utiliza una red neuronal convolucional	Utiliza redes neuronales convolucionales (KEGCNN) y el	Logró una precisión promedio del 98% en la detección de calidad de los plátanos.

Autores	Proyecto	Técnica	Rendimiento
Borrmann et al. (2020).	de gráficos integrados (KEGCNN) para la detección de la calidad del banano. Identificación de tomates maduros e inmaduros en un invernadero con aprendizaje profundo.	modelo AlexNet, utiliza técnicas de modelo de mezcla gaussiana (GMM). Se utilizaron redes neuronales pre entrenadas, incluyendo AlexNet, ResNet18, ResNet50, ResNet152, VGG16, VGG19,	El mejor modelo tiene una puntuación F1 de 0,9527, utilizando ResNet152.

Nota. Autoría propia, resumen detallado de los resultados obtenidos en los proyectos analizados y citados en el estado del arte.

Objetivos

Objetivo General

Implementar un sistema que integre las tecnologías de inteligencia artificial y visión por computadora para la identificación temprana de enfermedades de “Torque y Podredumbre Morena” en cultivos de duraznos.

Objetivos Específicos

Estructurar la base de datos necesaria para el funcionamiento del sistema a partir de la toma de imágenes donde se evidencien las enfermedades de “Torque y Podredumbre Morena” en las hojas y frutos del durazno.

Implementar técnicas de visión por computadora para procesar las imágenes de la base de datos con el fin de eliminar ruido e identificar el objeto de interés.

Aplicar técnicas de IA para la detección de las enfermedades “Torque y Podredumbre Morena”.

Validar el sistema propuesto mediante análisis cualitativo y cuantitativo en la detección de las enfermedades “Torque y Podredumbre Morena” en los cultivos de duraznos.

Justificación

Las enfermedades fúngicas representan una amenaza significativa para la producción agrícola a nivel mundial, afectando diversos cultivos y generando pérdidas económicas considerables. En el departamento de Boyacá, Colombia, los cultivos de durazno son especialmente vulnerables a enfermedades como la Podredumbre Morena (*Monilinia spp*) y el Torque (*Taphrina deformans*). Estas enfermedades no solo disminuyen la productividad y la calidad del fruto, sino que también incrementan los costos de producción debido a la necesidad de tratamientos fitosanitarios y la pérdida de cosechas afectadas. Según Guarín Torres et al. (2019), la presencia de diferentes patógenos en el cultivo puede resultar en una pérdida de hasta el 80% en calidad y cosecha. La prevalencia de estas enfermedades pone en riesgo la sostenibilidad de la agricultura local, afectando a pequeños y medianos agricultores que dependen de esta actividad como su principal fuente de ingresos.

Por lo tanto, es sumamente necesaria una herramienta de detección temprana de enfermedades en el cultivo, lo cual posibilitaría la identificación rápida de los primeros signos de infección, permitiendo a los agricultores aplicar medidas preventivas y de control de manera más efectiva. Esto reduciría la dependencia de fungicidas, mitigaría el impacto ambiental y garantizaría cosechas más saludables, mejorando la rentabilidad y sostenibilidad de la producción de duraznos en la región.

Teniendo en cuenta la problemática mencionada y su impacto, se propone desde el ámbito de la ingeniería la creación de una herramienta basada en visión por computadora e inteligencia artificial, con el fin de lograr la detección temprana de enfermedades en los cultivos de durazno. Utilizando simplemente la cámara de un equipo móvil y algoritmos de aprendizaje automático, esta tecnología puede identificar síntomas iniciales de la Podredumbre Morena y el

Torque con precisión y rapidez. Los agricultores pueden recibir en tiempo real el resultado del proceso, permitiéndoles tomar medidas inmediatas para controlar las infecciones. Esta herramienta no solo mejora la eficiencia y efectividad de las labores del agro, sino que también reduce el uso de fungicidas, protege el medio ambiente y optimiza la producción, asegurando cosechas más saludables y rentables.

De acuerdo con González (2024), la integración de la inteligencia artificial en la agricultura representa un cambio de paradigma que promete un futuro más sostenible y resiliente para la producción de alimentos a nivel global. Por lo tanto, la adopción de tecnologías innovadoras posiciona a los agricultores de Boyacá como líderes en prácticas agrícolas modernas y sostenibles, lo que puede atraer inversiones y apoyo de instituciones gubernamentales y privadas. En un mercado cada vez más competitivo y globalizado, el uso de herramientas tecnológicas avanzadas es una estrategia clave para mejorar la rentabilidad, sostenibilidad y competitividad de los agricultores locales (Párr. 6).

Marco Teórico y Conceptual

Marco Conceptual

Cultivo

Son los procesos ejecutados para trabajar la tierra en plantaciones con función de que en ella crezcan especies vegetales, frutales, medicinales, cereales y otros. Estos procesos pueden ser llevados a cabo por acciones de los agricultores pero también se pueden dar de manera natural, considerándose la actividad más importante si se trata de preservar el sustento y crecimiento económico se trata, adicionalmente se conoce que los cultivos requieren de condiciones específicas que garanticen su producción y calidad de la cosecha, por lo tanto en cuanto al ejercicio de la agricultura se deben cumplir con unos análisis y ejecución de estudios técnicos con el fin de no perjudicar la tierra (Bembibre, 2022).

Durazno

El durazno es de origen chino y según su historia es considerado como símbolo de longevidad e inmortalidad. Esta fruta es envuelta en una cascara lisa o aterciopelada fina de color amarillo o rojizo, en donde en su interior se encuentra la pulpa jugosa amarillenta y finalmente su semilla o denominada hueso, (Nestlé, 2022).

Plagas y Enfermedades

Las plagas o enfermedades son condiciones que afectan los cultivos del sector agrícola, donde el cual afecta el proceso tanto de producción, como de crecimientos de las plantas. Estas plagas y enfermedades son causadas por seres vivos como lo son: insectos, hongos y bacterias. Cada uno de ellos puede afectar desde el tallo, las hojas, el fruto y hasta la raíz de la planta, (FAO, 2000).

Inteligencia Artificial

Es una disciplina que conlleva una serie de algoritmos de códigos que se crean para la interpretación de acciones y comportamientos humanos, creando así un espacio más tecnológico y de fácil acceso. Para (IBM, s. f.) es una forma teórica de IA en la que una máquina tendría una inteligencia igual a la de los humanos; sería autoconsciente y tendría la capacidad de resolver problemas, aprender y planificar para el futuro. La superinteligencia artificial (SIA), también conocida como superinteligencia, superaría la inteligencia y la capacidad del cerebro humano.

Procesamiento Digital de Imágenes

Este proceso se efectúa a partir de la división de la imagen en un arreglo rectangular de elementos, donde cada elemento dividido de la imagen se le nombra como pixel, luego de ello se asigna un valor numérico de luminosidad, todos estos datos se almacenan desde una computadora, finalmente se aplican filtros u operaciones morfológicas para alteran algunos detalles que sean convenientes para ser vistos desde el ojo humano, el procesamiento de imágenes tiene muchas aplicaciones como por ejemplo en la medicina, agricultura, movilidad entre otras, (Rubio, 2020).

Visión por Computadora

La visión por computadora se comprende como el grupo de tecnologías o herramientas computacionales, que permiten a los equipos captar imágenes del mundo real para procesarlas y generar información mediante el análisis de estas. Principalmente la visión por computadora abarca muchas funcionalidades u operaciones, pero destacando algunas de ellas, se puede aplicar en la detección de objetos, el análisis de imágenes o videos y la comparación estadística, (EDS Robotics, 2022).

Marco Teórico

El durazno es proveniente de China, donde se produce desde el año 1000 a.c, en el siglo XVI fue llevado a América por los colonos españoles. Donde hoy en día los mayores productores en el hemisferio norte se encuentran Estados Unidos y regiones limítrofes de Canadá. Dentro del hemisferio sur se encuentran Argentina, Chile, Uruguay, Sudáfrica y Nueva Zelanda. Para zonas templadas o tropicales se puede dar con el manejo forzado de defoliación artificial (manual o química) para poder simular el otoño, como puede ocurrir en países como Colombia o Venezuela, (Agrotendencia, 2023).

Dentro de las características físicas que comprende el cultivo de durazno, se puede apreciar la raíz, el tallo, las hojas, la flor y floración, y el fruto. El durazno tiene la gran capacidad de adaptarse a suelos sueltos, con buen drenaje de agua, profundidad efectiva de 1 o 1.5 metros, suelos francos arenosos o arcillosos y un pH de 6,5, donde las condiciones climáticas se requieren como el frío moderado, altura de 1600-2200 m.s.n.m, humedad relativa del 75% y un brillo solar de 1500 horas/año, (Gómez, 2018).

El proyecto en estudio se sitúa en el municipio de Cómbita Boyacá, donde se encuentra un cultivo de durazno, cultivado a 2700 m.s.n.m. Las enfermedades y plagas más comunes que se presentan en los cultivos de durazno son:

Torque de Duraznero

Esta es una de las enfermedades más importantes de los cultivos frutales de carozo, esta enfermedad ha llegado a producir un 80% de pérdidas. Las lesiones que presentan en las hojas, flores y frutos, pero en el mayor de los casos se presenta en las hojas, como se muestra en la Figura 5. Durante la brotación, en las hojas se presenta en las hojas una yema foliar, donde se crean áreas amarillentas a rojizas donde estas manchas se van engrosando, haciéndose más

carnosa y se enrollan con los bordes hacia adentro. Esto radica en la infección localizada en el parénquima en empalizada mientras que las nervaduras permanecen sanas, (Fauba, 2022).

Este se desarrolla de forma subcuticular e intracelularmente, esto hace que se ocasionen el amarillento de la zona afectada. La hiperplasia e hipertrofia se produce a la formación de una sustancia cuya actividad es particular al ácido indol acético (Auxina). De tal forma el tejido foliar desciende haciendo que haya un aumento en la concentración de pigmentos antociánicos (Metaplasia), por ello la enfermedad se da a conocer mediante el color vinoso, (Fauba, 2022).

Figura 5

Enfermedad del Torque en el Durazno.



Fuente. Herbario Virtual Fitopatología, s. f, se visualiza la afectación causada por la enfermedad de Torque en las hojas del durazno.

Podredumbre Morena

Esta enfermedad empieza atacando las flores y ramas, las cuales presentan manchas húmedas, así como se muestra en la Figura 6. Las partes afectadas se tornan marrones, las hojas marchitas se cubren de una masa gomosa y pueden caerse. En los frutos, la enfermedad los afecta desde la maduración, tornándose en una podredumbre marrón, que sería el daño más común de la enfermedad. Esta se inicia en el fruto por un color pardo en una lesión circular que avanza rápidamente, ablandando los tejidos y pudiendo abarcar parcial o totalmente la fruta en pocos días. Pudre los frutos, arrugando la piel y deshidratando la fruta. Finalmente, en el interior de las frutas se desarrolla el micelio del hongo (Fauba, 2022).

Figura 6

Fruto del Durazno Afectado por la Enfermedad Podredumbre Morena



Fuente. Fauba, 2023, la enfermedad de Podredumbre Morena se va extendiendo por el fruto de durazno hasta momificarlo.

Metodología

El presente proyecto tiene como objetivo desarrollar un sistema que integre las tecnologías de inteligencia artificial y visión por computadora para la identificación temprana de enfermedades en el durazno. A través de una herramienta web, diseñada específicamente para asistir a los agricultores productores de durazno en la detección temprana de las enfermedades de Podredumbre Morena (*Monilinia spp*) y Torque (*Taphrina deformans*). Estas enfermedades representan un desafío significativo para la producción de durazno en el departamento de Boyacá, Colombia, afectando tanto la calidad como la cantidad de las cosechas.

La herramienta web desarrollada no solo ofrece una plataforma accesible y fácil de usar, sino que también incorpora tecnologías avanzadas de análisis de imágenes y aprendizaje automático para identificar los primeros signos de estas enfermedades. Esto permite a los agricultores tomar medidas preventivas y correctivas oportunas, reduciendo así las pérdidas económicas y daños al medio ambiente.

La metodología empleada en este proyecto combina enfoques cuantitativos y cualitativos para asegurar que la solución desarrollada sea tanto efectiva como práctica. El enfoque cuantitativo se basa en la recolección y análisis de imágenes de los cultivos de durazno afectados, utilizando técnicas de visión por computadora para entrenar el algoritmo de detección. Estas imágenes fueron recolectadas directamente en los campos de cultivo, abarcando diferentes etapas de crecimiento y condiciones de las plantas.

Paralelamente, se recopilan datos agronómicos históricos y actuales sobre la incidencia de las enfermedades en las diferentes zonas de cultivo de Boyacá. Esta información permite contextualizar y enriquecer los análisis, proporcionando una base sólida para el desarrollo de modelos predictivos y de detección temprana.

La integración de estos enfoques metodológicos brinda una comprensión integral del problema y la creación de una herramienta que no solo sea técnicamente robusta, sino que también esté alineada con las realidades y desafíos cotidianos de los agricultores. En última instancia, este proyecto busca empoderar a los productores de durazno de Boyacá con una herramienta de alta tecnología que promueva prácticas agrícolas más sostenibles y rentables.

El proyecto se lleva cabo en 6 etapas, las cuales se describen a continuación:


Etapas del Proyecto

Etapa 1. Estructuración de la Base de Datos Preprocesamiento de Imágenes

Se fundamenta principalmente en la recolección de imágenes en cultivos de durazno, esta tarea se lleva a cabo mediante visitas de campo a un área de cultivos de aproximadamente 3 hectáreas de siembra ubicada en Combita, Boyacá. A continuación, se presenta la Figura 7 que ilustra las áreas de ubicación de estos cultivos de durazno en la región.

Figura 7

Fotografía Satelital, que Permite Localizar los Cultivos de Duraznos de la Región



Fuente. Google, 2024, se detallan los cultivos de durazno de los cuales se recopilaron las imágenes de la base de datos inicial.

Durante estas visitas, se realiza un estudio riguroso y detallado de las enfermedades para identificar las características clave que permitan su detección.

Las imágenes se capturan directamente en los cultivos, garantizando así que la base de datos refleje fielmente las condiciones reales en las que se presentan las enfermedades. Este proceso incluye la toma de muestras aleatorias de cultivos enfermos y sanos, asegurando una representación equilibrada y precisa de las diferentes etapas y manifestaciones de las enfermedades en los duraznos.

De esta manera, se recolecta un total de 640 imágenes que incluyen hojas y frutos de durazno, tanto sanos como enfermos. En la Figura 8, se detallan algunas de estas imágenes.

Imagen A. Muestra un durazno afectado por Podredumbre Morena.

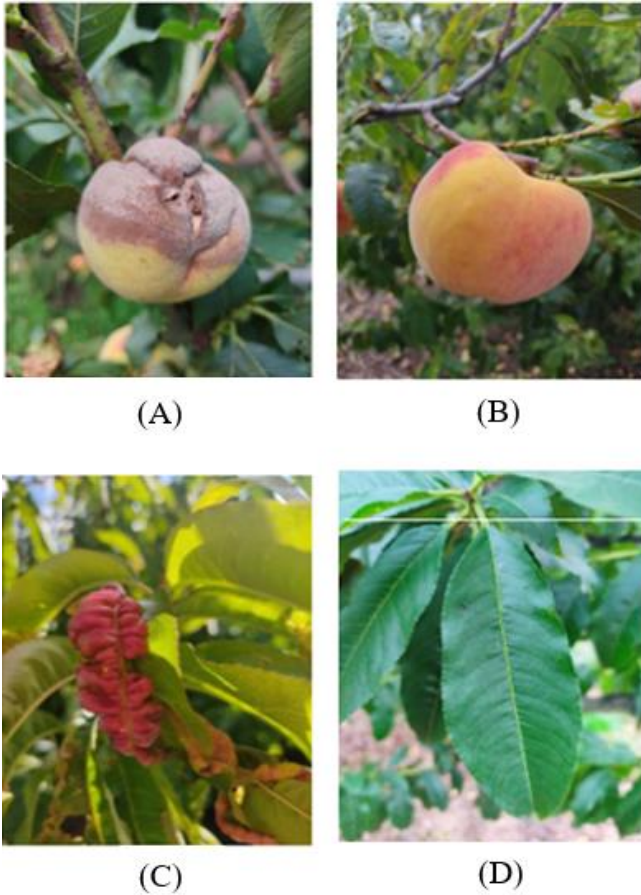
Imagen B. Detalla un durazno sano.

Imagen C. Presenta una hoja con signos de la enfermedad de Torque.

Imagen D. Muestra una hoja sana.

Figura 8

Estado de los Frutos y Hojas del Durazno a Procesar.



Fuente. Autoría propia, se muestra la diferencia entre hojas y frutos, tanto sanos y enfermos en las plantaciones del durazno.

Etapas 2. Procesamiento de Imágenes

El objetivo principal de esta etapa es obtener una visualización detallada y precisa de las áreas afectadas en las hojas y frutos, Para lograr esto, se implementan avanzadas técnicas de visión por computadora, con el fin de resaltar las irregularidades encontradas en la imagen.

Asimismo, se llevan a cabo pruebas y validaciones para asegurar que los algoritmos de procesamiento de imágenes funcionen de manera correcta en diversas condiciones de

iluminación y variaciones en la apariencia de los cultivos. Esto asegura que la herramienta web sea robusta y aplicable en diferentes escenarios agrícolas.

Las técnicas de visión por computadora utilizadas son:

Remoción de Fondo. Esta técnica permite centrar la atención exclusivamente en las hojas y frutos, eliminando elementos distractores y asegurando que las características relevantes de las enfermedades sean claramente visibles. La eliminación del fondo se logra mediante el uso de algoritmos de segmentación de imágenes que distinguen entre el objeto de interés (hoja o fruto) y el fondo. Esto mejora la precisión de los análisis posteriores y la efectividad de los algoritmos de detección. Tal como se detalla en la Figura 9.

En la imagen A1, se encuentra la imagen original de un fruto de durazno afectado con la enfermedad Podredumbre Morena.

En la imagen A2, se visualiza la imagen con remoción de fondo del fruto de durazno afectado con la enfermedad de Podredumbre Morena.

En la imagen B1, se muestra una imagen original de un fruto de durazno sano.

En la imagen B2, se visualiza la imagen con remoción de fondo del fruto sano.

Figura 9

Técnica de Remoción del Fondo en el Fruto de Durazno.



(A1)



(A2)



(B1)



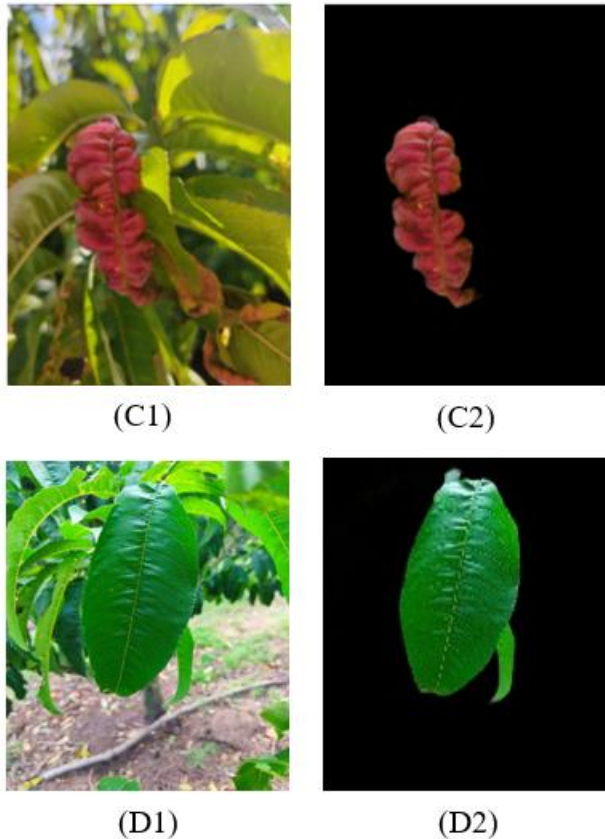
(B2)

Fuente. Autoría propia, la técnica de remoción de fondo ofrece la facilidad del procesamiento de la imagen en sus puntos de interés.

El mismo proceso es aplicado en la hoja, tanto sana como afectada con la enfermedad de Torque. Así como se presenta en la Figura 10.

Figura 10

Técnica de Remoción del Fondo Aplicada a la Hoja de Durazno.



Fuente. Autoría propia, proceso de remoción de fondo aplicada a la hoja de durazno.

Conversión al Espacio de Color RGB. La conversión del espacio de color de BGR a RGB es un paso importante en el procesamiento de imágenes. Las imágenes capturadas suelen estar en formato BGR (Blue, Green, Red), utilizado por algunas cámaras. Sin embargo, para asegurar una correcta visualización y compatibilidad con otras herramientas y sistemas, se requiere convertir estas imágenes al formato RGB (Red, Green, Blue).

Este proceso reordena los componentes de color en cada píxel, pasando de (B, G, R) a (R, G, B). La conversión se realiza utilizando la biblioteca PIL (Python Imaging Library), asegurando que las imágenes procesadas sean adecuadamente interpretadas y visualizadas.

En la Figura 11, se puede observar.

Imagen C3, hoja enferma en el espacio de color BGR.


Imagen C4, hoja enferma en el espacio de color RGB.

Imagen D3, hoja sana en el espacio de color BGR.

Imagen D4, hoja enferma en el espacio de color RGB.

Figura 11

Técnica de Conversión de Colores BGR a RGB



Fuente. Autoría propia, aplicación de conversión de espacio de colores en la hoja.

Para el fruto, también se aplica el proceso de conversión de espacio de color BGR a RGB, como se muestra en la Figura 12.

Imagen A3, fruto enfermo en espacio de color BGR.


Imagen A4, fruto enfermo en espacio de color RGB.

Imagen B3, fruto sano en espacio de color BGR.

Imagen B4, fruto sano en espacio de color RGB.

Figura 12

Conversión del Espacio de Color a las Imágenes del Fruto



Fuente. Autoría propia, aplicación de conversión de espacio de colores en el fruto.

Redimensionamiento de Imágenes. Este paso se realiza para adaptar las imágenes a las dimensiones requeridas por los algoritmos de procesamiento y análisis. Las imágenes recolectadas pueden tener diferentes tamaños y resoluciones, lo que puede afectar la consistencia y precisión de los análisis posteriores.

Redimensionar las imágenes a un tamaño uniforme asegura que todos los datos sean tratados de manera consistente.


Para el redimensionamiento, se utilizan técnicas que ajustan la resolución de las imágenes a 150 x 150 píxeles, manteniendo la proporción de aspecto, tal cual se puede observar en la Figura 13.

Imagen A5, fruto enfermo de Podredumbre Morena imagen redimensionada.

Imagen C5, hoja enferma de Torque imagen redimensionada.

Figura 13

Redimensionamiento de las Imágenes al 150 x 150 Píxeles



Fuente. Autoría propia, redimensionamiento de las imágenes.

Aplicación de Contornos. La aplicación de contornos es una técnica clave para identificar y analizar las formas y los límites de los objetos en las imágenes. Los contornos ayudan a resaltar los bordes y las fronteras de los objetos de interés, facilitando la visualización y el análisis de las áreas afectadas por enfermedades.

En la Figura 14, se puede apreciar la aplicación de contornos al área afectada en un fruto y hoja de durazno.

Figura 14

Aplicación de Contornos a los Objetos de Interés en las Imágenes



(A6)



(A7)



(C6)



(C7)

Fuente. Autoría propia, se contornea las partes de interés.

Etapa 3. Estructuración de la Base de Datos para el Entrenamiento de la Red Neuronal

Se estructura una base de datos que incluye 4 clases:

1. Frutos sanos
2. Hojas sanas
3. Frutos enfermos de Podredumbre Morena (*Monilinia spp*).
4. Hojas enfermas de Torque (*Taphrina deformans*).

Este proceso es crucial para entrenar correctamente el algoritmo. La recopilación de datos se realiza con un total de 640 imágenes previamente redimensionadas a 150 x 150 píxeles, y sometidas a remoción de fondo, posteriormente las imágenes se organizan en carpetas separadas, una para las hojas y otra para los frutos.

En la siguiente tabla se verifica la cantidad de imágenes en cada una de las clases:

Tabla 2*Estructura de la Base de Datos Inicial*

Distribución de las imágenes de la base de datos			
Tipo	Sano	Enfermo Patología	Cantidad
Fruto	x		141
Hoja	x		120
Fruto		Podredumbre Morena (<i>Monilinia Spp</i>)	219
Hoja		Torque (<i>Taphrina deformans</i>)	160
Total			640

Nota. Autoría propia, se detallan las cantidades de imágenes para cada clase.

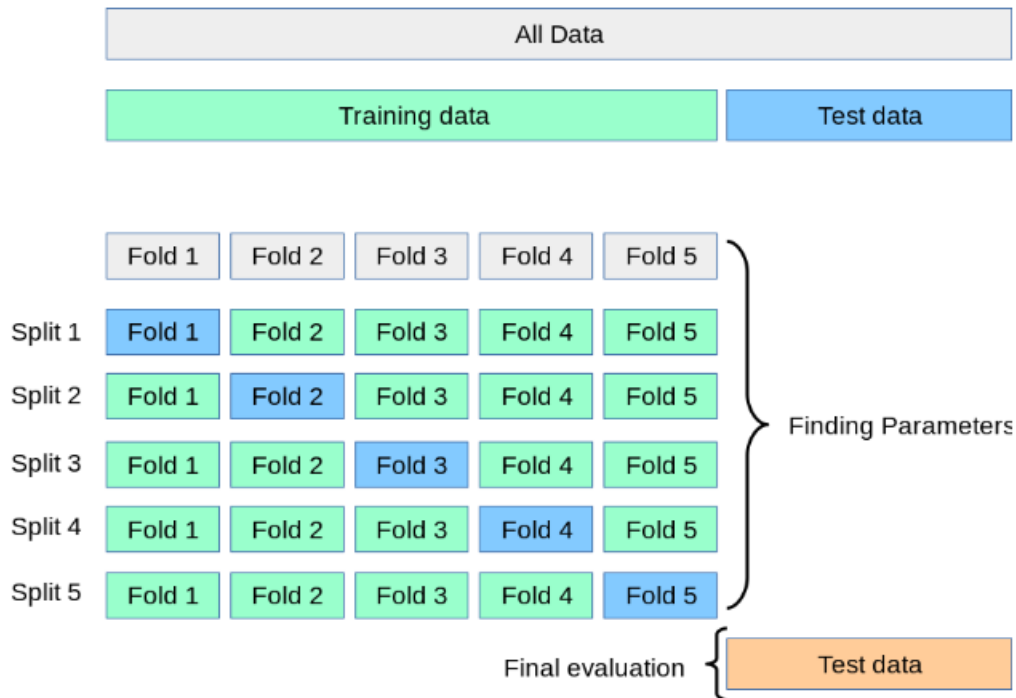
Etapas 4. Aplicación de Técnicas de Validación Cruzada

La validación cruzada es esencial para asegurar que el modelo desarrollado no solo sea preciso en el conjunto de datos de entrenamiento, sino que también generalice bien a datos nuevos y no vistos. Esto es particularmente importante en aplicaciones agrícolas donde la variabilidad de las condiciones del cultivo puede ser alta.

Esta técnica realiza la división de un conjunto de datos, arrojando un conjunto de datos para entrenamiento y otro conjunto de datos para prueba. Esto se lleva a cabo mediante particiones (Folds), tal como se muestra en la Figura 15.

Figura 15

Ejemplo de Uso de la Técnica de Validación Cruzada en Conjunto de Datos



Fuente. us.numerica.mx, 2020, se detalla claramente el proceso de la validación cruzada a un conjunto de datos.

Para el proyecto, se aplica la técnica de validación cruzada a la base de datos del fruto, que consta de 360 imágenes. Esta técnica divide la base de datos aleatoriamente en 5 particiones o folds, cada una con 72 imágenes. El proceso realiza iteraciones para cada partición y determina cuál alcanza el mayor porcentaje de validación. En este caso, la técnica indica que el fold número 4 contiene las imágenes del fruto con el mayor porcentaje de validación (90.28%), como se muestra en la Figura 16. De este modo, el sistema reserva las imágenes del fold número 4 para la prueba, tal como se distribuye en la Tabla 3 y las demás imágenes se utilizan para el

entrenamiento, asegurando que el modelo no conozca las imágenes de prueba y evaluando así su rendimiento con datos no vistos.

Tabla 3

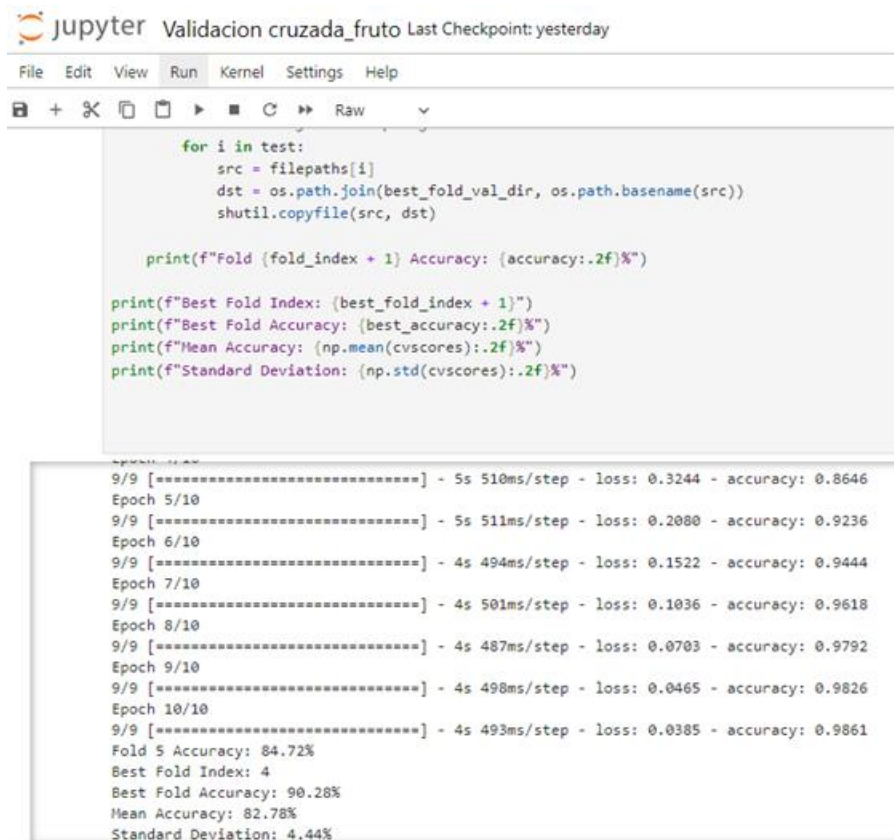
Cantidad de Imágenes de Prueba para el Modelo de Entrenamiento del Modelo del Fruto

Imágenes de prueba para el modelo de entrenamiento del fruto	
Clases	Cantidades
Fruto enfermo	41
Fruto sano	31
Total	72

Nota. Autoría propia, distribución de las imágenes de prueba obtenidas en la técnica de validación cruzada para el entrenamiento del modelo del fruto.

Figura 16

Resultado de la Validación Cruzada, Realizada a la Base de Datos Inicial del Fruto de Durazno



```

for i in test:
    src = filepaths[i]
    dst = os.path.join(best_fold_val_dir, os.path.basename(src))
    shutil.copyfile(src, dst)

print(f"Fold {fold_index + 1} Accuracy: {accuracy:.2f}%")

print(f"Best Fold Index: {best_fold_index + 1}")
print(f"Best Fold Accuracy: {best_accuracy:.2f}%")
print(f"Mean Accuracy: {np.mean(cvscores):.2f}%")
print(f"Standard Deviation: {np.std(cvscores):.2f}%")

```

```

9/9 [=====] - 5s 510ms/step - loss: 0.3244 - accuracy: 0.8646
Epoch 5/10
9/9 [=====] - 5s 511ms/step - loss: 0.2080 - accuracy: 0.9236
Epoch 6/10
9/9 [=====] - 4s 494ms/step - loss: 0.1522 - accuracy: 0.9444
Epoch 7/10
9/9 [=====] - 4s 501ms/step - loss: 0.1036 - accuracy: 0.9618
Epoch 8/10
9/9 [=====] - 4s 487ms/step - loss: 0.0703 - accuracy: 0.9792
Epoch 9/10
9/9 [=====] - 4s 498ms/step - loss: 0.0465 - accuracy: 0.9826
Epoch 10/10
9/9 [=====] - 4s 493ms/step - loss: 0.0385 - accuracy: 0.9861
Fold 5 Accuracy: 84.72%
Best Fold Index: 4
Best Fold Accuracy: 90.28%
Mean Accuracy: 82.78%
Standard Deviation: 4.44%

```

Fuente. Autoría propia, se obtiene el resultados de la validación cruzada de la base de datos inicial del fruto que consta de 360 imágenes entre frutos sanos y enfermos.

El mismo proceso se lleva a cabo para la base de datos de la hoja, que consta de 280 imágenes, estas se dividen aleatoriamente en 5 folds, cada uno con 56 imágenes. Las iteraciones correspondientes se realizan para cada partición, determinando que el fold número 2 contiene las imágenes con el mayor porcentaje de validación (96.43%). Estas imágenes se reservan para la prueba y las demás se utilizan para el entrenamiento del modelo. Estos datos son soportados en la Figura 17 y su distribución está dada en la Tabla 4.

Tabla 4

Cantidad de Imágenes de Prueba para el Modelo de Entrenamiento del Modelo de la Hoja

Imágenes de prueba para el modelo de entrenamiento de la hoja	
Clases	Cantidades
Hoja enferma	29
Hoja sana	27
Total	56

Nota. Autoría propia, distribución de las imágenes de prueba obtenidas en la técnica de validación cruzada para el entrenamiento del modelo de la hoja.

Figura 17

Resultado de la Validación Cruzada, Realizada a la Base de Datos Inicial de la Hoja de Durazno



```

print(f"Fold {fold_index + 1} Accuracy: {accuracy:.2f}%")

print(f"Best Fold Index: {best_fold_index + 1}")
print(f"Best Fold Accuracy: {best_accuracy:.2f}%")
print(f"Mean Accuracy: {np.mean(cv_scores):.2f}%")
print(f"Standard Deviation: {np.std(cv_scores):.2f}%")

```

```

Epoch 2/10
7/7 [=====] - 3s 492ms/step - loss: 0.3929 - accuracy: 0.8438
Epoch 3/10
7/7 [=====] - 4s 509ms/step - loss: 0.2335 - accuracy: 0.8973
Epoch 4/10
7/7 [=====] - 3s 492ms/step - loss: 0.1494 - accuracy: 0.9554
Epoch 5/10
7/7 [=====] - 3s 489ms/step - loss: 0.1050 - accuracy: 0.9598
Epoch 6/10
7/7 [=====] - 3s 492ms/step - loss: 0.0440 - accuracy: 0.9955
Epoch 7/10
7/7 [=====] - 3s 487ms/step - loss: 0.0265 - accuracy: 0.9955
Epoch 8/10
7/7 [=====] - 3s 495ms/step - loss: 0.0142 - accuracy: 0.9955
Epoch 9/10
7/7 [=====] - 4s 508ms/step - loss: 0.0051 - accuracy: 1.0000
Epoch 10/10
7/7 [=====] - 4s 535ms/step - loss: 0.0139 - accuracy: 0.9955
Fold 5 Accuracy: 91.07%
Best Fold Index: 2
Best Fold Accuracy: 96.43%
Mean Accuracy: 92.86%
Standard Deviation: 1.96%

```

Fuente. Autoría propia, se obtiene el resultados de la validación cruzada de la base de datos inicial de la hoja que consta de 280 imágenes entre hojas sanas y enfermas.

Etapas 5. Aplicación de Técnicas de Inteligencia Artificial

En esta etapa se implementan técnicas de inteligencia artificial para el entrenamiento de un modelo de predicción, con el fin de contribuir al análisis y la detección temprana de enfermedades como la Podredumbre Morena y Torque en los cultivos de durazno. Estas técnicas permiten desarrollar modelos precisos y eficaces que pueden identificar las características de las enfermedades a partir de imágenes recolectadas.

Entrenamiento del Modelo de Predicción. Se implementa el uso de Redes Neuronales Convolucionales (CNN). Las CNN son particularmente efectivas para el análisis de imágenes debido a su capacidad para capturar características espaciales y patrones locales.

Las capas de convolución son el componente principal de las CNN. Aplican filtros (kernel) a las imágenes de entrada para detectar características locales como bordes, texturas y formas. Cada filtro produce un mapa de características que resalta las regiones de la imagen donde se detecta una característica específica.

De acuerdo con la Etapa 4. Aplicación de Técnicas de Validación Cruzada Se realiza la construcción de los modelos utilizando la red neuronal convolucional, que consiste en la implementación de tres capas convolucionales. La primera integra 16 neuronas, la segunda 32 neuronas y la tercera 64 neuronas, con una función de activación ReLU (*Rectified Linear Units*).

Esta función de activación le permite al modelo aprender de acuerdo con la mayor cantidad de características de las imágenes de la base de datos, sin aumentar significativamente la carga computacional. Por otra parte, para el entrenamiento del modelo se asigna el 80% de las imágenes resultado de la validación cruzada, y el 20% de las imágenes para validación.

En este caso, para el fruto se entrenó el modelo con 288 imágenes entre sanas y enfermas de Podredumbre Morena en 10 épocas, tal como se muestra en la Tabla 5. Además, se puede verificar que el modelo construido alcanza un accuracy de 88.63% según se muestra en la Figura 18.

Tabla 5

Imágenes Obtenidas en la Validación Cruzada para el Entrenamiento del Modelo del Fruto.

Imágenes de entrenamiento del modelo para el fruto	
Clases	Cantidades
Fruto enfermo	178
Fruto sano	110
Total	288

Nota. Autoría propia, cantidad y distribución de imágenes obtenidas en la validación cruzada para el entrenamiento del modelo del fruto de durazno.

Figura 18

Resultado del Entrenamiento del Modelo para el Fruto de Durazno

```
[63]: print("Comenzando entrenamiento")
epochs=10
history = model.fit(
    train_ds,
    validation_data=val_ds,
    epochs=epochs
)
print("Modelo entrenado")
```

Comenzando entrenamiento

Epoch 1/10
58/58 ————— 8s 110ms/step - accuracy: 0.6809 - loss: 0.5888 - val_accuracy: 0.8304 - val_loss: 0.4425

Epoch 2/10
58/58 ————— 7s 118ms/step - accuracy: 0.8239 - loss: 0.4112 - val_accuracy: 0.8435 - val_loss: 0.3649

Epoch 3/10
58/58 ————— 8s 130ms/step - accuracy: 0.8515 - loss: 0.3461 - val_accuracy: 0.8696 - val_loss: 0.3283

Epoch 4/10
58/58 ————— 7s 122ms/step - accuracy: 0.8729 - loss: 0.3109 - val_accuracy: 0.8522 - val_loss: 0.3276

Epoch 5/10
58/58 ————— 7s 120ms/step - accuracy: 0.8988 - loss: 0.2581 - val_accuracy: 0.8848 - val_loss: 0.2662

Epoch 6/10
58/58 ————— 7s 128ms/step - accuracy: 0.9306 - loss: 0.1957 - val_accuracy: 0.8957 - val_loss: 0.2493

Epoch 7/10
58/58 ————— 7s 122ms/step - accuracy: 0.9471 - loss: 0.1524 - val_accuracy: 0.9109 - val_loss: 0.2449

Epoch 8/10
58/58 ————— 7s 127ms/step - accuracy: 0.9458 - loss: 0.1444 - val_accuracy: 0.9261 - val_loss: 0.2080

Epoch 9/10
58/58 ————— 8s 128ms/step - accuracy: 0.9658 - loss: 0.1018 - val_accuracy: 0.9152 - val_loss: 0.2187

Epoch 10/10
58/58 ————— 8s 129ms/step - accuracy: 0.9387 - loss: 0.1529 - val_accuracy: 0.9348 - val_loss: 0.1954

Modelo entrenado

Fuente. Autoría propia, datos del entrenamiento del modelo del fruto.

Para la hoja, se entrenó el modelo con 224 imágenes entre sanas y enfermas de Torque en 10 épocas, como se muestra en la Tabla 6. Alcanzando un accuracy de 90.9%, tal como se evidencia en la Figura 19.

Tabla 6

Imágenes Obtenidas en la Validación Cruzada para el Entrenamiento del Modelo de la Hoja.

Imágenes de entrenamiento del modelo para la hoja	
Clases	Cantidades
Hoja enferma	131
Hoja sana	93
Total	224

Nota. Autoría propia, cantidad y distribución de imágenes obtenidas en la validación cruzada para el entrenamiento del modelo de la hoja de durazno.

Figura 19

Resultado del Entrenamiento del Modelo para la Hoja de Durazno

```

Entrenamos el modelo

[13]: print("Comenzando entrenamiento")
epochs=10
history = model.fit(
    train_ds,
    validation_data=val_ds,
    epochs=epochs
)
print("Modelo entrenado")

Comenzando entrenamiento
Epoch 1/10
6/6 ----- 4s 221ms/step - accuracy: 0.5972 - loss: 0.6202 - val_accuracy: 0.8636 - val_loss: 0.3730
Epoch 2/10
6/6 ----- 1s 139ms/step - accuracy: 0.9096 - loss: 0.2584 - val_accuracy: 0.8409 - val_loss: 0.4399
Epoch 3/10
6/6 ----- 1s 141ms/step - accuracy: 0.9461 - loss: 0.1480 - val_accuracy: 0.9091 - val_loss: 0.2765
Epoch 4/10
6/6 ----- 1s 151ms/step - accuracy: 0.9697 - loss: 0.1088 - val_accuracy: 0.8864 - val_loss: 0.2554
Epoch 5/10
6/6 ----- 1s 144ms/step - accuracy: 0.9730 - loss: 0.0648 - val_accuracy: 0.9545 - val_loss: 0.2000
Epoch 6/10
6/6 ----- 1s 142ms/step - accuracy: 0.9821 - loss: 0.0634 - val_accuracy: 0.9318 - val_loss: 0.1963
Epoch 7/10
6/6 ----- 1s 141ms/step - accuracy: 0.9964 - loss: 0.0267 - val_accuracy: 0.9318 - val_loss: 0.2075
Epoch 8/10
6/6 ----- 1s 140ms/step - accuracy: 1.0000 - loss: 0.0116 - val_accuracy: 0.9318 - val_loss: 0.2413
Epoch 9/10
6/6 ----- 1s 186ms/step - accuracy: 1.0000 - loss: 0.0062 - val_accuracy: 0.9318 - val_loss: 0.2623
Epoch 10/10
6/6 ----- 1s 142ms/step - accuracy: 1.0000 - loss: 0.0049 - val_accuracy: 0.9091 - val_loss: 0.2693
Modelo entrenado

```

Fuente. Autoría propia, datos del entrenamiento del modelo de la hoja.

Estos resultados demuestran que el modelo tiene un alto nivel de exactitud en la clasificación de las imágenes, lo cual sugiere que es una herramienta confiable para la detección de enfermedades en cultivos. La alta precisión en ambos casos indica que el modelo es robusto y puede ser aplicado de manera efectiva en entornos reales.

Matriz de Confusión. Para valorar la calidad del modelo de clasificación basado en aprendizaje automático, se utiliza la matriz de confusión. Esta herramienta es fundamental en la evaluación de modelos de clasificación, ya que permite desglosar y visualizar el rendimiento del modelo en términos de verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos. En la Figura 20 se muestra la distribución de resultados.

Con estos datos, es posible calcular métricas clave como la precisión, la sensibilidad (recall), la especificidad y el valor predictivo positivo, entre otras. Al analizar la matriz de confusión, se identifican áreas específicas donde el modelo funciona correctamente y otras donde necesita ajustes.

Esto permite ajustar los parámetros del modelo, como la tasa de aprendizaje, el número de capas, nodos en la red neuronal, las técnicas de regularización aplicadas, entre otros. Gracias a estos ajustes y a la retroalimentación proporcionada por la matriz de confusión, se logra mejorar significativamente la precisión del modelo, alcanzando niveles óptimos de desempeño. Este proceso no solo asegura que el modelo tenga un alto rendimiento en términos de exactitud, sino que también garantiza su robustez y capacidad para generalizar a nuevos datos, lo cual es crucial para su aplicación en escenarios reales.

Figura 20

Estructura de Matriz de Confusión

The diagram illustrates a Confusion Matrix. The vertical axis is labeled 'Realidad' (Reality) and has two categories: '1' (Positivo) and '0' (Negativo). The horizontal axis is labeled 'Predicción' (Prediction) and has two categories: '1' (Positivo) and '0' (Negativo). The matrix is divided into four quadrants: Top-Left (Actual 1, Predicted 1) is 'Verdadero positivo' (True Positive); Top-Right (Actual 1, Predicted 0) is 'Falso negativo' (False Negative); Bottom-Left (Actual 0, Predicted 1) is 'Falso positivo' (False Positive); Bottom-Right (Actual 0, Predicted 0) is 'Verdadero negativo' (True Negative).

		Predicción	
		"1" (Positivo)	"0" (Negativo)
Realidad	"1" (Positivo)	Verdadero positivo	Falso negativo
	"0" (Negativo)	Falso positivo	Verdadero negativo

Fuente. Diaz & Diaz, 2022, distribución de los resultados obtenidos en la evaluación del modelo entrenado.

Etapas 6. Aplicación Web

Para asegurar que los agricultores puedan utilizar fácilmente la herramienta desarrollada para la detección temprana de enfermedades en cultivos de durazno, se implementa un front-end intuitivo y accesible.

Desarrollo de un Front-end con Anvil.work. El front-end se desarrolla utilizando Anvil, una plataforma de desarrollo web que permite construir aplicaciones web completas de manera sencilla y rápida. Utilizando el editor visual de Anvil, se diseña una interfaz de usuario amigable que permite a los agricultores cargar imágenes de las hojas y/o frutos de su cultivo, visualizar los resultados del análisis y acceder a información relevante sobre las enfermedades detectadas.

Integración del Front-end y el Back-end. Para realizar el análisis de las imágenes, el front-end debe comunicarse con el back-end, donde se ejecuta el modelo de IA entrenado. Anvil facilita esta comunicación a través de llamados a funciones del servidor, logrando una correcta comunicación con el back-end alojado en Jupyter.

El diseño intuitivo de la aplicación web desarrollada con Anvil permite a los agricultores utilizar la herramienta sin necesidad de conocimientos técnicos avanzados. Simplemente deben seguir unos pasos sencillos para cargar una imagen de un fruto o una hoja de durazno y obtener un diagnóstico preciso sobre la salud de sus cultivos.

1. Ejecución de la Aplicación. El proceso comienza con la ejecución de la aplicación web. Esta interfaz amigable guía al usuario a través de cada paso necesario para realizar la detección de enfermedades.

2. Carga de Imágenes. Los agricultores cargan fácilmente una imagen de un fruto o una hoja de durazno utilizando el formulario de carga de imágenes en la aplicación. Esta imagen puede ser tomada directamente desde un dispositivo móvil o una cámara y cargada en el sistema con solo unos clics.

4. Envío de la Imagen. Una vez cargada la imagen, el usuario puede enviarla para su análisis. Este proceso es rápido y directo, diseñado para minimizar el tiempo y esfuerzo requeridos por el agricultor.

5. Procesamiento y Análisis con Jupyter. La imagen enviada es procesada por el código alojado en un entorno Jupyter. Este código se encarga de realizar varias tareas:

Preprocesamiento de la Imagen. Incluye operaciones como la conversión del espacio de color, la eliminación de fondos irrelevantes y el redimensionamiento de la imagen para asegurar que esta se encuentre en el formato adecuado para el análisis.

Análisis mediante IA. Utilizando un modelo de inteligencia artificial, la imagen es analizada para detectar signos de Podredumbre Morena o Torque.

Predicción. El modelo de IA genera una predicción basada en las características detectadas en la imagen.

6. Visualización de Resultados en Anvil. Los resultados del análisis, incluyendo la imagen procesada y el diagnóstico, son devueltos a la interfaz de Anvil. Esta información es presentada de manera clara y comprensible para el usuario, permitiendo que el agricultor vea el estado de salud del fruto o la hoja cargada inicialmente.

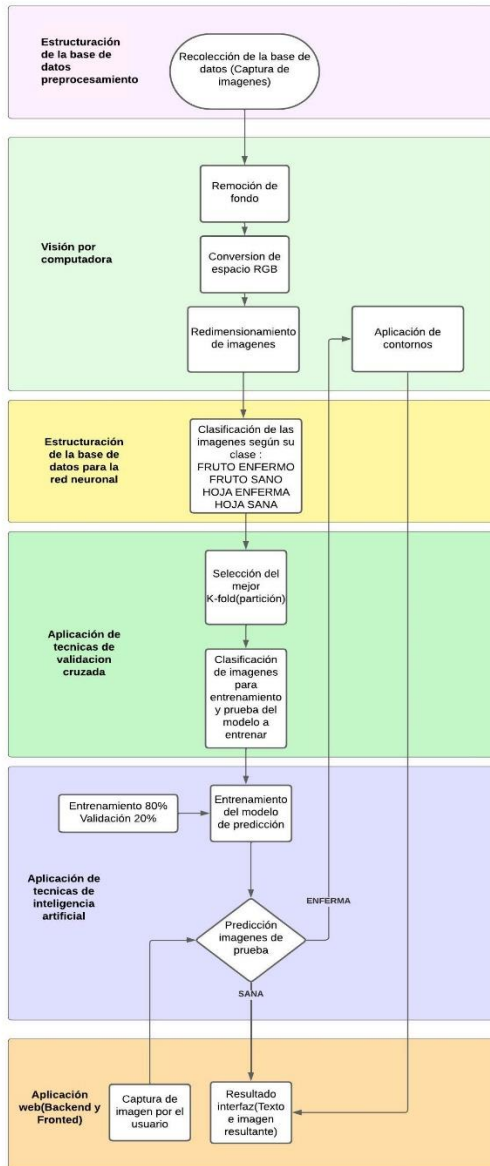
7. Diagnóstico. El diagnóstico proporcionado indica si la imagen muestra signos de Podredumbre Morena o Torque, información que ayuda al agricultor a tomar decisiones oportunas sobre el manejo de sus cultivos.

Los pasos anteriormente mencionados aseguran que los agricultores obtengan rápidamente un diagnóstico preciso y confiable, utilizando una herramienta accesible y fácil de manejar. La integración de Jupyter y Anvil hace posible que complejas técnicas de inteligencia artificial sean aplicadas de manera práctica y útil en el campo agrícola.

Para una mejor comprensión de la estructura de la metodología, se ilustra en la Figura 21 el diagrama de bloques.

Figura 21

Diagrama de Bloques de la Metodología Empleada para el Proyecto



Fuente. Autoría propia.

Resultados


El objetivo principal de este proyecto consiste en implementar un sistema que integre tecnologías de inteligencia artificial y visión por computadora, con el fin de identificar de manera temprana las enfermedades de Podredumbre Morena (*Monilinia spp*) y Torque (*Taphrina deformans*) en los cultivos de durazno. Los resultados que se presenta a continuación proporcionan un análisis detallado de los datos recolectados y los hallazgos obtenidos a lo largo de la implementación y evaluación del sistema propuesto.

Para alcanzar este objetivo, se llevan a cabo varias etapas de desarrollo y pruebas, a continuación, se detallan aquellas etapas que son cruciales y requieren buenos resultados para dar paso a las siguientes.

En primer lugar, se recolectan imágenes de alta calidad de frutos y hojas de durazno, tanto sanas como afectadas por Podredumbre Morena (*Monilinia spp*) y Torque (*Taphrina deformans*), en la Figura 22 se muestra cómo se organizó la base de datos de imágenes iniciales.

Figura 22

Ejemplo Visual de la Estructura de la Base de Datos Inicial del Proyecto.



Fuente. Autoría propia.

Posteriormente, se aplican técnicas de visión por computadora con el fin de preparar las imágenes para los procesos de entrenamiento del modelo de IA, tal cual se observa en la Figura 23.

Figura 23

Aplicación de la Técnica de Remoción de Fondo para la Obtención de la Región de Interés en la Imagen.



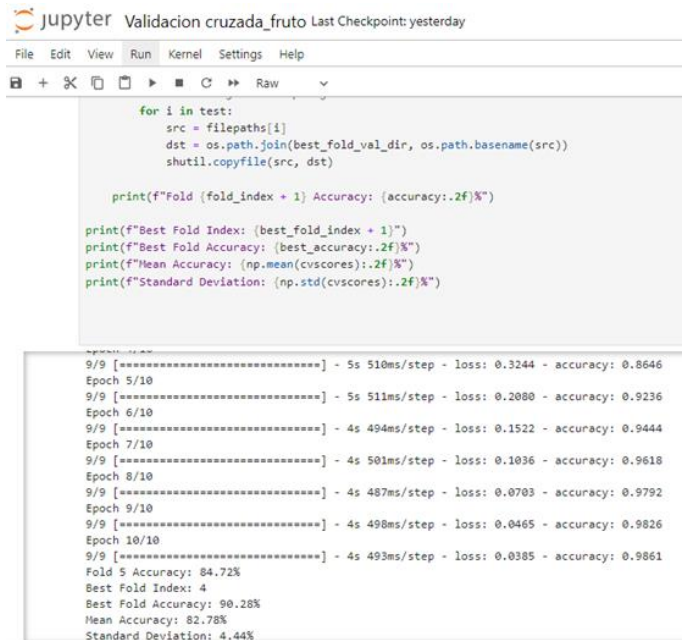
Fuente. Autoría propia.

A continuación, se desarrolla e implementa el modelo de inteligencia artificial para analizar las imágenes y detectar signos de las enfermedades mencionadas, en esta etapa se aplican diferentes técnicas para evaluar el rendimiento del modelo en términos de precisión y exactitud, de esta manera se llevan a cabo los siguientes pasos:

Determinar por medio de la técnica de validación cruzada las imágenes que serán utilizadas para entrenamiento y para prueba del modelo de inteligencia artificial. En las Figura 24 y Figura 25 se logra verificar el resultado de la aplicación de dicha técnica tanto para fruto como para hoja.

Figura 24

Resultado de la Validación Cruzada Aplicada para el Fruto, Alcanzando un Accuracy del 90.28%



The image shows a Jupyter Notebook interface with the title "Validation cruzada_fruto Last Checkpoint: yesterday". The code in the cell is as follows:

```

for i in test:
    src = filepaths[i]
    dst = os.path.join(best_fold_val_dir, os.path.basename(src))
    shutil.copyfile(src, dst)

print(f'Fold {fold_index + 1} Accuracy: {accuracy:.2f}%')

print(f'Best Fold Index: {best_fold_index + 1}')
print(f'Best Fold Accuracy: {best_accuracy:.2f}%')
print(f'Mean Accuracy: {np.mean(cv_scores):.2f}%')
print(f'Standard Deviation: {np.std(cv_scores):.2f}%')

```

The output of the code is:

```

9/9 [=====] - 5s 510ms/step - loss: 0.3244 - accuracy: 0.8646
Epoch 5/10
9/9 [=====] - 5s 511ms/step - loss: 0.2080 - accuracy: 0.9236
Epoch 6/10
9/9 [=====] - 4s 494ms/step - loss: 0.1522 - accuracy: 0.9444
Epoch 7/10
9/9 [=====] - 4s 501ms/step - loss: 0.1036 - accuracy: 0.9618
Epoch 8/10
9/9 [=====] - 4s 487ms/step - loss: 0.0703 - accuracy: 0.9792
Epoch 9/10
9/9 [=====] - 4s 498ms/step - loss: 0.0465 - accuracy: 0.9826
Epoch 10/10
9/9 [=====] - 4s 493ms/step - loss: 0.0385 - accuracy: 0.9861
Fold 5 Accuracy: 84.72%
Best Fold Index: 4
Best Fold Accuracy: 90.28%
Mean Accuracy: 82.78%
Standard Deviation: 4.44%

```

Fuente. Autoría propia.

Figura 25

Resultado de la Validación Cruzada Aplicada para la Hoja, Alcanzando un Accuracy del 96.43%

```

jupyter Validacion cruzada_hoja Last Checkpoint: last month
File Edit View Run Kernel Settings Help
+ X Copy Paste Run Stop Refresh Code
print(f"Fold {fold_index + 1} Accuracy: {accuracy:.2f}%")

print(f"Best Fold Index: {best_fold_index + 1}")
print(f"Best Fold Accuracy: {best_accuracy:.2f}%")
print(f"Mean Accuracy: {np.mean(cv_scores):.2f}%")
print(f"Standard Deviation: {np.std(cv_scores):.2f}%")

Epoch 2/10
7/7 [=====] - 3s 492ms/step - loss: 0.3929 - accuracy: 0.8438
Epoch 3/10
7/7 [=====] - 4s 509ms/step - loss: 0.2335 - accuracy: 0.8973
Epoch 4/10
7/7 [=====] - 3s 492ms/step - loss: 0.1494 - accuracy: 0.9554
Epoch 5/10
7/7 [=====] - 3s 489ms/step - loss: 0.1050 - accuracy: 0.9598
Epoch 6/10
7/7 [=====] - 3s 492ms/step - loss: 0.0440 - accuracy: 0.9955
Epoch 7/10
7/7 [=====] - 3s 487ms/step - loss: 0.0265 - accuracy: 0.9955
Epoch 8/10
7/7 [=====] - 3s 495ms/step - loss: 0.0142 - accuracy: 0.9955
Epoch 9/10
7/7 [=====] - 4s 508ms/step - loss: 0.0051 - accuracy: 1.0000
Epoch 10/10
7/7 [=====] - 4s 535ms/step - loss: 0.0139 - accuracy: 0.9955

Fold 5 Accuracy: 91.07%
Best Fold Index: 2
Best Fold Accuracy: 96.43%
Mean Accuracy: 92.86%
Standard Deviation: 1.96%

```

Fuente. Autoría propia.

En las cuales el sistema indica que las mejores imágenes para prueba de los modelos entrenados son: el fold número 4 para el fruto con un 90.28% y para la hoja, el fold numero 2 con un 96.43%.

Entrenar el modelo con las imágenes indicadas en la validación cruzada, como se observa en las Figura 26 y Figura 27.

Figura 26

Proceso de Entrenamiento del Modelo para el Fruto de Durazno

Jupyter CNN_MODELO_FRUTO (1) Last Checkpoint: 17 hours ago

File Edit View Run Kernel Settings Help

📄 + ✂ 📄 ▶ ■ ↺ ▶▶ Markdown Jup

Entrenamos el modelo

```
[63]: print("Comenzando entrenamiento")
epochs=10
history = model.fit(
    train_ds,
    validation_data=val_ds,
    epochs=epochs
)
print("Modelo entrenado")
```

Comenzando entrenamiento
Epoch 1/10
58/58 ————— 8s 110ms/step - accuracy: 0.6809 - loss: 0.5888 - val_accuracy: 0.8304 - val_loss: 0.4425
Epoch 2/10
58/58 ————— 7s 118ms/step - accuracy: 0.8239 - loss: 0.4112 - val_accuracy: 0.8435 - val_loss: 0.3649
Epoch 3/10
58/58 ————— 8s 130ms/step - accuracy: 0.8515 - loss: 0.3461 - val_accuracy: 0.8696 - val_loss: 0.3283
Epoch 4/10
58/58 ————— 7s 122ms/step - accuracy: 0.8729 - loss: 0.3109 - val_accuracy: 0.8522 - val_loss: 0.3276
Epoch 5/10
58/58 ————— 7s 120ms/step - accuracy: 0.8988 - loss: 0.2581 - val_accuracy: 0.8848 - val_loss: 0.2662
Epoch 6/10
58/58 ————— 7s 128ms/step - accuracy: 0.9306 - loss: 0.1957 - val_accuracy: 0.8957 - val_loss: 0.2493
Epoch 7/10
58/58 ————— 7s 122ms/step - accuracy: 0.9471 - loss: 0.1524 - val_accuracy: 0.9109 - val_loss: 0.2449
Epoch 8/10
58/58 ————— 7s 127ms/step - accuracy: 0.9458 - loss: 0.1444 - val_accuracy: 0.9261 - val_loss: 0.2080
Epoch 9/10
58/58 ————— 8s 128ms/step - accuracy: 0.9658 - loss: 0.1018 - val_accuracy: 0.9152 - val_loss: 0.2187
Epoch 10/10
58/58 ————— 8s 129ms/step - accuracy: 0.9387 - loss: 0.1529 - val_accuracy: 0.9348 - val_loss: 0.1954
Modelo entrenado

Fuente. Autoría propia.

Figura 27

Proceso de Entrenamiento del Modelo para la Hoja de Durazno

```

Entrenamos el modelo

[13]: print("Comenzando entrenamiento")
epochs=10
history = model.fit(
    train_ds,
    validation_data=val_ds,
    epochs=epochs
)
print("Modelo entrenado")

Comenzando entrenamiento
Epoch 1/10
6/6 ----- 4s 221ms/step - accuracy: 0.5972 - loss: 0.6202 - val_accuracy: 0.8636 - val_loss: 0.3730
Epoch 2/10
6/6 ----- 1s 139ms/step - accuracy: 0.9096 - loss: 0.2584 - val_accuracy: 0.8409 - val_loss: 0.4399
Epoch 3/10
6/6 ----- 1s 141ms/step - accuracy: 0.9461 - loss: 0.1480 - val_accuracy: 0.9091 - val_loss: 0.2765
Epoch 4/10
6/6 ----- 1s 151ms/step - accuracy: 0.9697 - loss: 0.1088 - val_accuracy: 0.8864 - val_loss: 0.2554
Epoch 5/10
6/6 ----- 1s 144ms/step - accuracy: 0.9730 - loss: 0.0648 - val_accuracy: 0.9545 - val_loss: 0.2000
Epoch 6/10
6/6 ----- 1s 142ms/step - accuracy: 0.9821 - loss: 0.0634 - val_accuracy: 0.9318 - val_loss: 0.1963
Epoch 7/10
6/6 ----- 1s 141ms/step - accuracy: 0.9964 - loss: 0.0267 - val_accuracy: 0.9318 - val_loss: 0.2075
Epoch 8/10
6/6 ----- 1s 140ms/step - accuracy: 1.0000 - loss: 0.0116 - val_accuracy: 0.9318 - val_loss: 0.2413
Epoch 9/10
6/6 ----- 1s 186ms/step - accuracy: 1.0000 - loss: 0.0062 - val_accuracy: 0.9318 - val_loss: 0.2623
Epoch 10/10
6/6 ----- 1s 142ms/step - accuracy: 1.0000 - loss: 0.0049 - val_accuracy: 0.9091 - val_loss: 0.2693
Modelo entrenado

```

Fuente. Autoría propia.

Probar los modelos de IA con las imágenes de prueba indicadas en la etapa de aplicación de la validación cruzada. De esta manera, se evalúa la exactitud y precisión a través de la matriz de confusión.

La evaluación del modelo entrenado para el fruto se llevó a cabo con las 72 imágenes entre sanas y enfermas indicadas en la etapa 4 validación cruzada, obteniendo como resultado una exactitud del 91.6% y precisión del 100%, como se muestra en la Figura 28.

Tabla 7*Registro de Resultados Obtenidos en la Evaluación del Modelo Entrenado para el Fruto*

Resultados para el modelo IA del fruto										
	Clasificad	Real	F	F	T	T	Precisi	Exactit	Sensibilid	Especificid
	or	es	P	N	N	P	ón	ud	ad	ad
Frutos										
sanos (0)	37	31				3	1,0000	0,91666		
Frutos			0	6	31	5	00	6	0,853658	1,000000
Enferm	35	41								
os (1)										

Nota. Autoría propia.

Formulas utilizadas para el cálculo de exactitud y precisión del modelo entrenado para el fruto.

$$\text{Exactitud} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{35 + 31}{35 + 31 + 0 + 6} = 0.916 = 91.6\%$$

$$\text{Precisión} = \frac{TP}{TP + FP} = \frac{35}{35 + 0} = 1 = 100\%$$

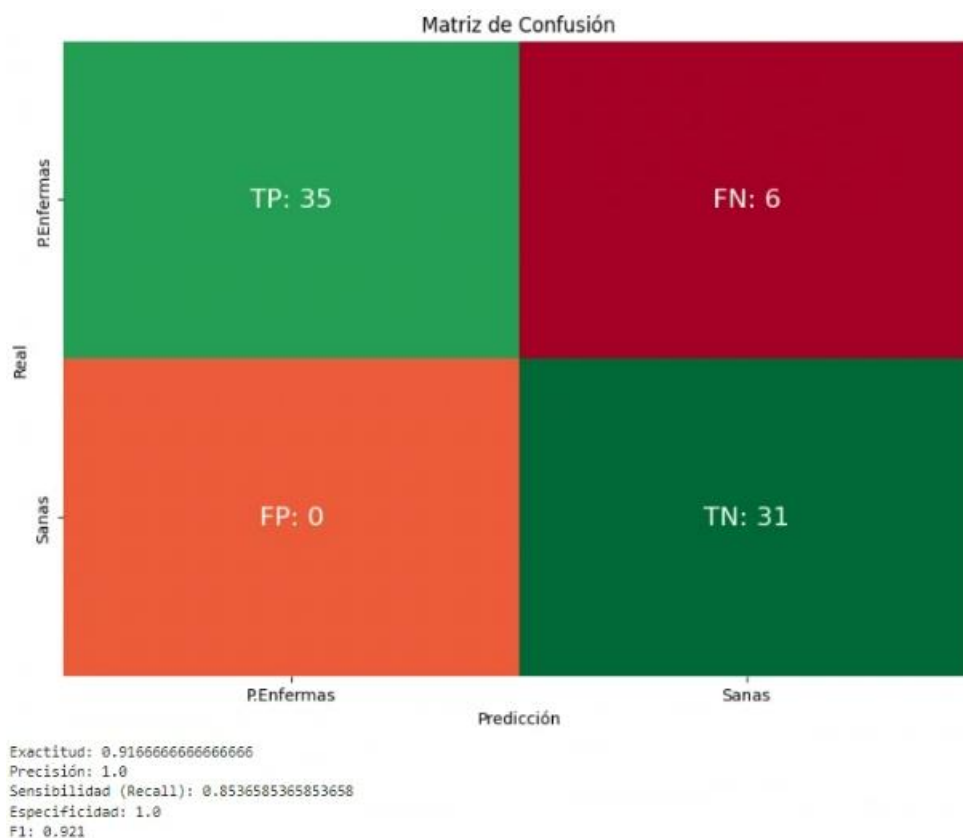
$$\text{Sensibilidad} = \frac{TP}{TP + FN} = \frac{35}{35 + 6} = 0.8536 = 85.36\%$$

$$F_{1Score} = \frac{2 * Precisión * sensibilidad}{Precisión + sensibilidad} = \frac{2 * 1 * 0.853}{1 + 0.853} = 0.921 = 92.1\%$$

$$Especificidad = \frac{TN}{TN + FP} = \frac{31}{31 + 0} = 1 = 100\%$$

Figura 28

Resultado de la Matriz de Confusión de la Evaluación Realizada a el Modelo IA del Fruto



Fuente. Autoría propia.

La evaluación del modelo entrenado de la hoja se llevó a cabo con las 56 imágenes entre sanas y enfermas indicadas en la etapa 4 validación cruzada, obteniendo como resultado una exactitud del 94.6% y precisión del 96.4%, como se muestra en la Figura 29.

Tabla 8*Registro de Resultados Obtenidos en la Evaluación del Modelo Entrenado para la Hoja*

Resultados para el modelo IA de la hoja											
	Clasificad	Real	F	F	T	T	Precisi	Exactit	Sensibilid	Especificid	
	or	es	P	N	N	P	ón	ud	ad	ad	
Hojas											
sanas	28	27									
(0)						2	0,9642	0,94642			
Hojas			1	2	26				0,931034	0,962962	
Enferm	28	29				7	85	8			
as (1)											

Nota. Autoría propia.

Formulas utilizadas para el cálculo de exactitud y precisión del modelo entrenado para la hoja.

$$\text{Exactitud} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{27 + 26}{27 + 26 + 1 + 2} = 0.946 = 94.6\%$$

$$\text{Precisión} = \frac{TP}{TP + FP} = \frac{27}{27 + 1} = 0.964 = 96.4\%$$

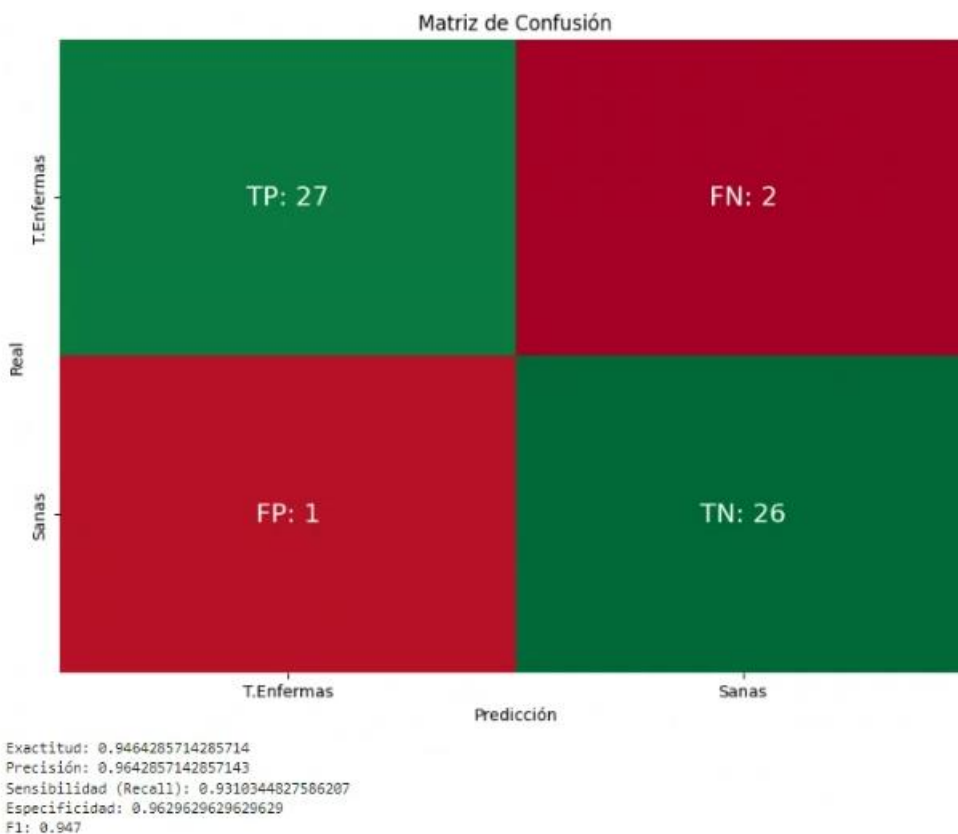
$$\text{Sensibilidad} = \frac{TP}{TP + FN} = \frac{27}{27 + 2} = 0.931 = 93.1\%$$

$$F_{1Score} = \frac{2 * Precisión * sensibilidad}{Precisión + sensibilidad} = \frac{2 * 0.964 * 0.931}{0.964 + 0.931} = 0.947 = 94.7\%$$

$$Especificidad = \frac{TN}{TN + FP} = \frac{26}{26 + 1} = 0.962 = 96.2\%$$

Figura 29

Resultado de la Matriz de Confusión de la Evaluación Realizada a el Modelo Ia de la Hoja.

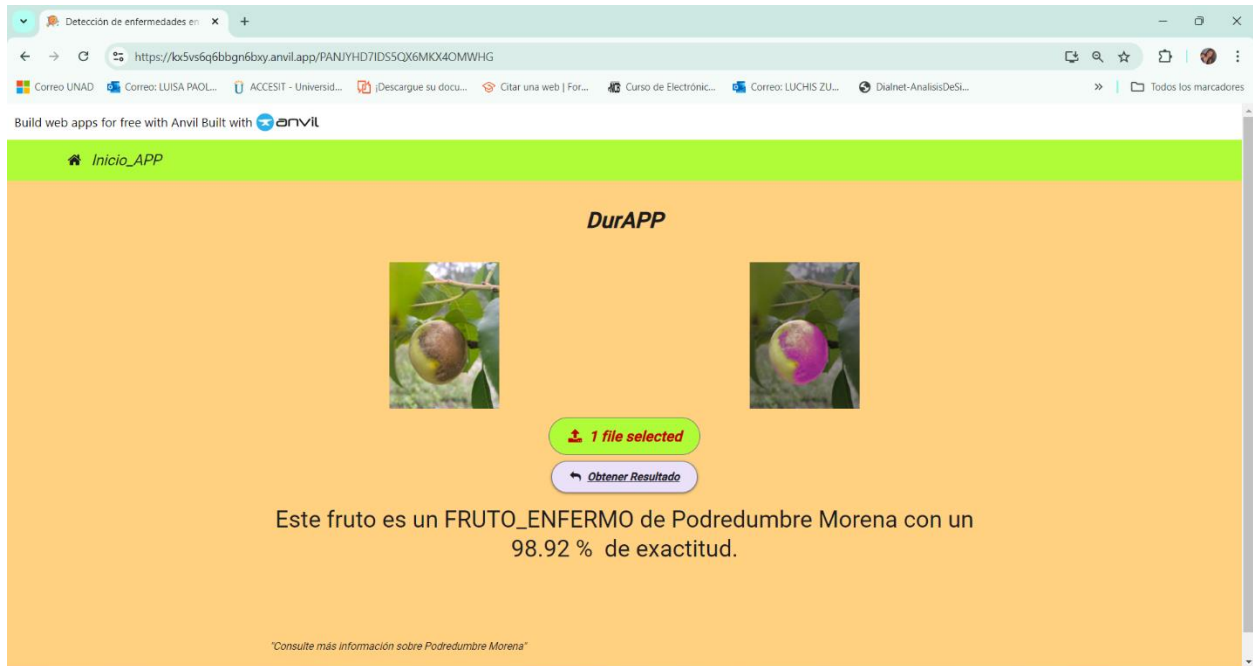


Fuente. Autoría propia.

Por otra parte, se realizan ajustes en la integración del back-end y el front-end, teniendo en cuenta diferentes retos encontrados a lo largo de dicha integración, logrando tiempos de envío y recepción de imágenes bastante buenos, ajustados al ancho de banda del usuario, en la Figura 30 y Figura 31, se muestra la interfaz de la aplicación en funcionamiento, tanto para la carga de imágenes, como en la visualización de los diferentes resultados.

Figura 30

Interfaz de la Aplicación Web, donde se Muestra el Resultado Arrojado sobre el Estado del Fruto de Durazno



Fuente. Autoría propia, se visualiza desde la aplicación web, el resultado de la predicción sobre el estado de un fruto de durazno, donde se evidencia que está enfermo de Podredumbre Morena.

Figura 31

Interfaz de la Aplicación Web, donde se Muestra el Resultado Arrojado sobre el Estado de la Hoja de Durazno



Fuente. Autoría propia, se visualiza desde la aplicación web, el resultado de la predicción sobre el estado de la hoja de durazno, donde claramente se evidencia que se encuentra enferma de Torque.

Por último, el logo fue diseñado cuidadosamente para representar los objetivos del proyecto. En la Figura 32 se muestra este logo, el cual utiliza elementos visuales que simbolizan de manera clara y concisa la esencia del proyecto. Cada componente seleccionado refleja aspectos claves como la innovación y la eficiencia, asegurando que cualquier usuario, al visualizar la imagen, pueda identificar inmediatamente la aplicación web como una herramienta tecnológica que ayuda a la identificación de las enfermedades tanto en el fruto como en las hojas de duraznos.

Figura 32

Logo de la Aplicación Web



Fuente. Autoría propia, representación visual de la aplicación web.

Conclusiones

En este proyecto, se logra implementar un sistema que integra tecnologías de inteligencia artificial y visión por computadora, con el fin de identificar de manera temprana las enfermedades "Podredumbre Morena (*Monilinia spp*) y Torque (*Taphrina deformans*)" en cultivos de durazno. Durante el desarrollo, se enfrentaron numerosos desafíos en programación, tanto en Python como en el desarrollo web, lo que requirió múltiples ensayos en diversas plataformas.

Se exploraron todas las herramientas disponibles en Google Colab y, aunque es una herramienta de programación robusta, su incapacidad para ejecutar el código automáticamente limitó la implementación de la aplicación web. Por lo tanto, se decidió utilizar Jupyter Notebook como editor de código, lo cual permitió superar este obstáculo y lograr una aplicación web totalmente funcional.

Gran parte del éxito de este proyecto se debe a la utilización de Anvil.work para la creación del front end, esta plataforma Low code es sencilla y eficiente para desarrollar interfaces web, permitiendo integrar de manera fluida el back end desarrollado en Python con una interfaz de usuario amigable. Esta herramienta facilitó enormemente el proceso de desarrollo del front end, ahorrando tiempo y recursos, garantizando de antemano una experiencia de usuario óptima.

Por otra parte, se identificó la necesidad de tener una base de datos de imágenes más grande, con el fin de mejorar aún más los resultados del sistema. Una base de datos más amplia y diversa permitiría entrenar los modelos de inteligencia artificial con mayor precisión, incrementando la capacidad de detección y reduciendo los falsos positivos y negativos. La

ampliación de la base de datos de imágenes es esencial para garantizar la robustez y fiabilidad del sistema en diferentes condiciones y entornos.

Otro reto importante fue encontrar los rangos de colores correctos en las imágenes afectadas por las diferentes enfermedades. Las variaciones en iluminación, calidad de las imágenes y condiciones del entorno dificultaron la identificación precisa de los patrones de color característicos de cada enfermedad. A través de distintas técnicas de visión por computadora se lograron definir los rangos de colores que permitieron al sistema detectar las enfermedades con una precisión significativa.

Sin embargo, Los resultados obtenidos reflejan una precisión del 100% en la identificación de enfermedades en los frutos y un 96.4% en las hojas, soportados por una matriz de confusión que confirma la eficacia del modelo. Esta precisión indica que el sistema es capaz de detectar las enfermedades con un alto grado de exactitud, minimizando tanto los falsos positivos como los falsos negativos, lo cual es crucial para la detección de enfermedades en los cultivos.

Teniendo en cuenta los retos superados y los resultados obtenidos, es importante recomendar para futuras investigaciones o proyectos, la ampliación de la base de datos de imágenes. Una base de datos más extensa y variada mejorará la precisión del modelo, garantizando un alto rango de aplicabilidad en los diferentes entornos que ofrecen los cultivos de durazno.

Este proyecto no solo demuestra la viabilidad de utilizar inteligencia artificial y visión por computadora en la agricultura, sino que también destaca la importancia de elegir las herramientas adecuadas para superar los desafíos técnicos. Las lecciones aprendidas y las

soluciones encontradas en este proyecto proporcionan una base sólida para futuras investigaciones y desarrollos en este campo.

Referencias Bibliográficas

- Agronet inicio*. (n.d.). Retrieved April 23, 2024, from
<https://www.agronet.gov.co/Paginas/inicio.aspx>
- Azadnia, R., Fouladi, S., & Jahanbakhshi, A. (2023b). Intelligent detection and waste control of hawthorn fruit based on ripening level using machine vision system and deep learning techniques. *Results In Engineering*, 17, 100891.
<https://doi.org/10.1016/j.rineng.2023.100891>
- Baugher, A. 2003. Anatomy and taxonomy. En: Baugher, A. y S. Singha. Concise encyclopedia of temperate tree fruit. Food Products Press, New York.
- Borrmann, Y. F., Ferraciolli, M., Folego, G., & Rodrigues, L. H. (2020). Identifying Mature And Inmature Tomatoes In A Greenhouse With Deep Learning. XXVIII Congreso {Virtual} de Iniciacao Cientifica Da Unicamp. Brasil: Pro Reitoria de Pesquisa Unicamp. <https://www.prp.unicamp.br/inscricao-congresso/resumos/2020P17585A33995O179.pdf>
- Diaz, B., & Diaz, B. (2022, 21 junio). 14 Métricas esenciales para construir modelos definitivos. *ImpulsateK - Artificial intelligence, tools, insights and wisdom gleaned from the knowledge of others* [Figura]. <https://impulsatek.com/14-metricas-esenciales-para-construir-modelos-definitivos/>
- Fauba. (2023, 26 junio). *Herbario Virtual Fitopatología: Signos de pudrición morena*. [Figura] Herbario Virtual Fitopatología. https://herbariofitopatologia.agro.uba.ar/?page_id=3371
- Fauba. (s. f.). *Herbario Virtual Fitopatología: Torque del Duraznero (Taphrina Deformans)* [Figura]. https://herbariofitopatologia.agro.uba.ar/?page_id=2556

- Gautam, V., Ranjan, R. K., Dahiya, P., & Kumar, A. (2023). ESDNN: A novel ensemble stack deep neural network for mango leaf disease classification and detection. *Multimedia Tools And Applications*.
https://www.researchgate.net/publication/371870111_ESDNN_A_novel_ensemble_stack_deep_neural_network_for_mango_leaf_disease_classification_and_detection
- Geetharamani, G., & Arun Pandian, J. (2019). Identification of plant leaf diseases using a nine-layer deep convolutional neural network. *Computers y Electrical Engineering*, 76, 323-338. <https://doi.org/10.1016/j.compeleceng.2019.04.011>
- Gonzalez, L. (2024, 4 mayo). *Impacto de la IA en la agricultura*. Observatorio Blockchain.
<https://observatorioblockchain.com/ia/impacto-de-la-ia-en-la-agricultura/>
- Google. (s.f.). [Localización de los cultivos de duraznos en la vereda Alejandría del municipio de Combita, Boyacá]. Recuperado el 26 de julio de 2024, de
<https://www.google.com/maps/@5.6757415,-73.2959499,991m/data=!3m1!1e3?entry=ttu>
- Gope, H. L., & Fukai, H. (2022). Peaberry and normal coffee bean classification using CNN, SVM, and KNN: Their implementation in and the limitations of Raspberry Pi 3. *AIMS Agriculture And Food*, 7(1), 149-167. <https://doi.org/10.3934/agrfood.2022010>
- Helal Sheikh, Md., Tashrif Mim, T., Shamim Reza, Md., Shahariar Azad Rabby, A., & Akhter Hossain, S. (2019, 1 julio). *Detection of Maize and Peach Leaf diseases using Image Processing*. IEEE Conference Publication | IEEE Xplore.
<https://ieeexplore.ieee.org/document/8944530>
- L, S. D., K, V., N, A., & Vashistha, S. (2024b). Tomato leaf disease detection using CNN. *Procedia Computer Science*, 235, 2975-2984. <https://doi.org/10.1016/j.procs.2024.04.281>

- Ordóñez, O. (2007). Monografía del durazno, Secretaria de desarrollo Rural. Estado de Puebla.
Disponibile en: <http://www.sdr.gob.mx/Contenido/CadenasProductivas.pdf>.
- Plantación y sostenimiento de una hectárea de cultivo de durazno (prunus pérsica) en la vereda Las Jarras municipio de Isnos.* (n.d.). Retrieved April 23, 2024, from <https://repository.unad.edu.co/handle/10596/18106>
- Ricardo, E. S. W. (2023, 31 marzo). *Desarrollo de aplicación Android móvil utilizando Visión Artificial y Deep Learning para la identificación de aguacates Hass con la plaga Monalonia, en la finca "Las Palmas", ubicada en el municipio de San Agustín, Huila.* <https://repositorio.uan.edu.co/items/e30fd7c8-9d41-4a1a-9fc8-383e1503d8f0>
- Ricardo, Y. R., Joel, G. R. B., Alan, H. G., & Gamero, V. (2023). *Weed identification technique in basil crops using computer vision.* <https://repositorio.utp.edu.pe/handle/20.500.12867/7803?show=full>
- Robles, C., & Cesar, P. (2020, 1 julio). *Desarrollo de aplicaciones móviles de clasificación y detección de objetos a partir de redes convolucionales ligeras.* Universidad Autónoma de Madrid. <http://hdl.handle.net/10486/692598>
- Sajitha, P., Andrushia, A. D., Mostafa, N., Shdefat, A. Y., Suni, S., & Anand, N. (2023). Smart farming application using knowledge embedded-graph convolutional neural network (KEGCNN) for banana quality detection. *Journal Of Agriculture And Food Research, 14*, 100767. <https://doi.org/10.1016/j.jafr.2023.100767>
- Sipsa: Boletín mensual insumos y factores asociados a la producción agropecuaria. (2020, febrero). <https://www.dane.gov.co/>. Recuperado 21 de abril de 2024, de https://www.dane.gov.co/files/investigaciones/agropecuario/sipsa/Bol_Insumos_feb_2020.pdf

Sullca, C., Molina, C., Rodríguez, C., & Fernández, T. (2018). *Detección de Enfermedades y Plagas en Las Hojas de Arándanos Utilizando Técnicas de Visión Artificial*.

<https://es.scribd.com/document/635650894/590-37-1079-1-10-20190328>

TvAgro. (2019, 15 enero). Como es un Cultivo de Duraznos - TvAgro por Juan Gonzalo Angel [Vídeo]. YouTube. https://www.youtube.com/watch?v=GZq_-33TaJw

us.numerica.mx. (2020, 3 agosto). Cómo Realizar la Validación Cruzada y Cruce Seccional de Datos – Blog US.NUMERICA.MX [Figura]. <https://us.numerica.mx/carreras-universitarias/como-realizar-la-validacion-cruzada-y-cruce-seccional-de-datos/>

Villasana-Montes, M. C., Hernández-Rojas, E., Palomino-Reséndiz, R. L., Maya-Gress, K. F., & Palomino-Reséndiz, S. I. (2023). Diseño de sistema de monitoreo para detección temprana de enfermedades y plagas superficiales en plantas mediante visión artificial. *Pädi Boletín Científico De Ciencias Básicas E Ingenierías Del ICBI*, 11(Especial4), 221-230. <https://doi.org/10.29057/icbi.v11iEspecial4.11369>