

**SISTEMA DE IDENTIFICACIÓN DE ENFERMEDADES Y PLAGAS EN EL
CULTIVO DE SANDÍA****DISEASES AND PESTS IDENTIFICATION SYSTEM IN WATERMELON
CULTIVATION**

 **Raúl Cueto Morelo***,  **Juan Atencio Flórez***,
 **Jorge Eliécer Gómez Gómez***

* **Universidad de Córdoba**, Facultad de ingeniería, Ingeniería de Sistemas y
Telecomunicaciones, Semillero de Investigación Pervasive Computing.
Centro de desarrollo Lórica.
E-mail: {rcuetomorelo, atencioflorez61, jelienergomez}@unicordoba.edu.co

Cómo citar: Cueto Morelo, R., Atencio Flórez, J., & Gómez Gómez, J. E. (2023). SISTEMA DE IDENTIFICACIÓN DE ENFERMEDADES Y PLAGAS EN EL CULTIVO DE SANDÍA. REVISTA COLOMBIANA DE TECNOLOGÍAS DE AVANZADA (RCTA), 2(42), 93–104. <https://doi.org/10.24054/rcta.v2i42.2674>

Derechos de autor 2023 Revista Colombiana de Tecnologías de Avanzada (RCTA).
Esta obra está bajo una licencia internacional [Creative Commons Atribución-NoComercial 4.0](https://creativecommons.org/licenses/by-nc/4.0/).



Resumen: En este estudio se desarrolló una aplicación móvil bajo el nombre “Sandiapp”, con el objetivo de identificar las diferentes plagas y enfermedades que afectan el cultivo de sandía en el municipio de San Bernardo del Viento - Córdoba. Para cumplir con este objetivo, se realizó un levantamiento de campo utilizando el método cuantitativo, como estudio sistemático de los hechos dentro de los cuales se presentó el caso, para obtener información útil para formular la propuesta y sustentar la propuesta a través de un sistema que a través del aprendizaje automático identifica los tipos de plagas y enfermedades que afectan los cultivos de sandía. Para el desarrollo de este proyecto se utilizaron ciertos algoritmos de visión artificial, el cual consiste en reconocer formas, distancias, ángulos, colores y determinar las dimensiones de la planta de sandía. Para realizar este procedimiento se ha considerado la forma y tamaño de la lámina. A través de las pruebas realizadas durante el desarrollo de este trabajo se concluye que: Mediante la implementación del sistema de visión artificial se demostró el incremento en el porcentaje de agricultores, los cuales ahora cuentan con un mayor nivel de información sobre plagas y enfermedades del cultivo de sandía.

Palabras clave: Procesamiento de imágenes, aprendizaje informático o automatizado, aprendizaje supervisado, aprendizaje no supervisado, sandía, inteligencia artificial, visión artificial.

Abstract: In this study, a mobile application was developed under the name “Sandiapp”, with the aim of identifying the different pests and diseases that affect the cultivation of watermelon in the municipality of San Bernardo del Viento - Córdoba. To meet this objective, a field survey was carried out using the quantitative method, as a systematic study of the facts within which the case was presented, to obtain useful information to formulate the proposal and support the proposal through a system that through machine learning identifies the types of pests and Diseases that affect watermelon crops. For the development

of this project, certain artificial vision algorithms were used, which consists of recognizing shapes, distances, angles, colors and determining the dimensions of the watermelon plant. To carry out this procedure, the shape and size of the sheet has been considered. Through the tests carried out during the development of this work, it is concluded that: Through the implementation of the artificial vision system, the increase in the percentage of farmers was demonstrated, which now has a higher level of information on pests and diseases of the watermelon crop.

Keywords: Image processing, computer or automated learning, supervised learning, unsupervised learning, watermelon, artificial intelligence, artificial vision.

1. INTRODUCCIÓN

Entre los problemas fitosanitarios se incluyen las dificultades causadas por plagas y enfermedades, que pueden conducir a una disminución de hasta el 30 % de la producción mundial. Dado que las plantas cultivadas desempeñan un papel crucial en la nutrición humana y tienen un impacto significativo en las economías de los países productores, es evidente que los daños derivados de las plagas tienen implicaciones sociales y económicas. Estos problemas son el resultado de la interacción entre patógenos agresivos, organismos hospedadores y condiciones climáticas favorables, creando lo que se conoce como el "Triángulo de las Enfermedades de los Cultivos". Algunos de los factores que favorecen su proliferación son la lluvia, el rocío, la humedad del aire y la temperatura, todos los cuales afectan la aparición, evolución y velocidad de las plagas. La identificación correcta de estos problemas ha surgido como un desafío constante para los agricultores, que enfrentan nuevos obstáculos diariamente para salvaguardar sus cultivos. Actualmente, la detección de enfermedades y plagas en las plantas recae principalmente en la observación visual por parte de los agricultores.

Es de suma importancia lograr una distinción precisa entre plagas y enfermedades en la producción de sandía, ya que esto es esencial para aumentar de manera sostenible los rendimientos en la agricultura. Por esta razón, se ha adoptado el concepto de Agricultura 4.0, que abarca una variedad de tecnologías, dispositivos, protocolos y enfoques informáticos diseñados para mejorar los procesos agrícolas (Gómez-Camperos, J.A., Jaramillo, H.Y., & Guerrero-Gómez, G. 2021). El sistema de identificación y clasificación de las enfermedades en los cultivos de sandía utiliza técnicas y tecnologías avanzadas, especialmente el procesamiento de imágenes, con el fin de determinar el momento en el que surge la fase inicial de

alternaría, una enfermedad común en cultivos. de sandía y que se relaciona con diferentes tipos de hojas afectadas en sandía. Además, esta tecnología también se ha utilizado para detectar las tres plagas más comunes en los cultivos: alternaría, plaga tardía y enfermedades virales (Martínez-Corral, L., Martínez-Rubín, E., Flores-García, F., Castellanos, G.C., Juarez, A.L., & López, M. 2009).

En este contexto, este estudio contribuye al avance de un sistema basado en el aprendizaje automático que puede realizar diagnósticos en el campo por personal sin formación específica, pero aprovechando el conocimiento de expertos cafeteros (Santa María Pinedo, J.C., Ríos López, C.A., Rodríguez Grández, C., & García Estrella, C.W. 2021). Este sistema está diseñado para identificar signos visuales de las enfermedades vegetales más comunes, utilizando hardware asequible, potente y altamente confiable. Después de seleccionar una arquitectura de red profunda con un rendimiento excepcional en la clasificación de enfermedades, ajustamos los parámetros del modelo para optimizar su reproducibilidad sin enfrentar problemas de sobrecalentamiento.

2. METODOLOGÍA

2.1 Tipo de estudio

Se llevó a cabo un estudio de campo utilizando el método cuantitativo, como estudio sistemático de los hechos en los que se presentó el caso, para obtener información útil para formular la propuesta y apoyar la propuesta a través de un sistema que, a través del aprendizaje automático, identifica los tipos de plagas y enfermedades que afectan el cultivo de la sandía. La base de los objetivos establecidos. Asimismo, se realiza un estudio bibliográfico a través de libros, revistas científicas y publicaciones electrónicas para profundizar en los diferentes enfoques del tema de la investigación, y de esta manera se recoge información valiosa como

soporte científico para la project, expanding various theories, concepts and criteria.

2.2 Población y Muestra

2.2.1 Población

El objetivo es crear un sistema que, a través del aprendizaje automático, identifique los tipos de plagas y enfermedades que afectan el cultivo de la sandía en el municipio de San Bernardo del viento.

2.2.2 Muestra

Se tomará una muestra específica de la población, todos ellos son productores de sandía, haciendo un total de 4 grupos de 25 agricultores.

3. TRABAJOS RELACIONADOS

Se presenta una investigación útil para el progreso de la actividad actual. Se han descubierto investigaciones relacionadas con el desarrollo de esta propuesta para una aplicación que, mediante el uso del aprendizaje automático, pueda reconocer las variedades de plagas y enfermedades que afectan el cultivo de la sandía.

Métodos de análisis de imágenes digitales para la identificación de enfermedades y plagas en cultivos: una revisión exhaustiva (Gómez-Camperos, J.A., Jaramillo, H.Y., & Guerrero-Gómez, G. 2021): La detección de plagas depende en gran medida de la observación manual, lo que puede conducir a errores debido a la interpretación individual. El propósito de esta revisión de la literatura es examinar las diferentes estrategias de procesamiento de imágenes utilizadas en el control de enfermedades y plagas en diversos contextos agrícolas.

Identificación de patologías en cultivos de papa mediante procesamiento de imágenes (Martínez-Corral, L., Martínez-Rubín, E., Flores-García, F., Castellanos, G.C., Juarez, A.L., & López, M. 2009): Este análisis describe las tácticas y técnicas implementadas en un sistema de detección y clasificación de enfermedades en los cultivos de patata, tomando ventaja del procesamiento de imágenes para identificar la fase inicial de desarrollo de *alternaria* spp. Aunque esta enfermedad es común en los cultivos de papa, tiene su origen en diversas condiciones.

Un modelo de aprendizaje automático para el diagnóstico de enfermedades en plantas de café (Santa María Pinedo, J.C., Ríos López, C.A.,

Rodríguez Grández, C., & García Estrella, C.W. 2021): Este sistema está diseñado para analizar las características visuales de las enfermedades más comunes en los dispositivos de costo, resistentes y confiables. Una red profunda estructura con alto rendimiento de clasificación se implementa, y los parámetros del modelo se adaptan para optimizar su reproducción sin inducir el sobreajuste.

Creación de una base de datos para la caracterización de la planta de alfalfa, utilizando un enfoque de visión computacional (Malpartida, S., & Ángel, E.T. 2011): El propósito central de este proyecto fue desarrollar una herramienta visual que facilita la evaluación de las insuficiencias nutricionales (N, P y K) y las condiciones de estrés hídrico en las plantas de alfalfa. Este sistema de informes fusiona todos los elementos anteriores para proporcionar una representación precisa de la condición de las plantas de alfalfa. Análisis de patrones visuales a través de una plataforma de visión por ordenador en MATLAB (Vargas, O.L., & Perrez, Á.A. 2019): Los objetivos se centran en la mejora del reconocimiento de patrones mediante sistemas de visión por ordenador, la evaluación del proceso de identificación de patrones, la implementación de plataformas de visión por computadora y la exploración de la interacción entre el reconocimiento de patrones y los sistemas de visión por computadora.

Sistema de visión artificial para el reconocimiento y manipulación de objetos mediante un brazo robot (León León, R.A., Jara, B.J., Cruz Saavedra, R., Terrones Julcamoro, K., Torres Verastegui, A., & Aponte de la Cruz, M.A. 2020).

Tabla 1. Tabla comparativa con respecto a obras relacionadas

Nombre del Artículo	Procesamiento de imágenes	Redes Neuronales	Visión Artificial
Gómez-Camperos 2021	+	-	-
Martínez-Corral 2009	-	+	+
Santa María 2021	+	-	+
Malpartida 2011	+	-	-
Vargas 2019	+	-	+
León León 2020	-	+	-

La manipulación de imágenes se refiere a la captura y alteración de imágenes o secuencias de vídeo con el fin de extraer atributos o parámetros específicos, o para generar una nueva imagen procesada como resultado. Es crucial señalar que la evolución de los métodos de procesamiento de imágenes digitales se deriva de dos ámbitos de aplicación fundamentales:

la mejora de la información visual para simplificar la interpretación humana y el procesamiento automatizado de datos visuales para su uso en dispositivos, lo que abarca la transmisión y/o conservación de estos datos (Ramírez Escalante, Boris. Procesamiento Digital de Imágenes). La eficacia de un sistema de imagen está estrechamente relacionada con sus componentes, de los cuales se pueden identificar seis aspectos clave que son observables y diferenciables (ver figura 1): Captura: En esta etapa se lleva a cabo la adquisición de una imagen visual. Pretratamiento: Abarca técnicas como la reducción del ruido y la mejora de los detalles de la imagen. Segmentación: consiste en la acción de dividir una imagen en objetos de interés. Descripción: Corresponde a la etapa en la que se obtienen atributos apropiados para distinguir entre diferentes tipos de objetos. Reconocimiento: Se refiere al proceso de asignar significado a un conjunto de objetos identificados.




Fig. 1. Estadios de un sistema de visión artificial.
fuente: R. Cueto, J. Atencio, J. Gómez.

4. PROPUESTA DE MODELIZACIÓN BASADA EN EL CONTEXTO

El cultivo de sandía está expuesto a amenazas derivadas de plagas y enfermedades, que pueden tener un impacto negativo tanto en la producción como en la calidad de los frutos. La detección de estas plagas y enfermedades en sus etapas iniciales es de suma importancia, ya que permite la aplicación oportuna de medidas preventivas y correctivas. Una posible solución eficaz a este desafío consiste en la adopción de sistemas basados en la visión por ordenador que, mediante el análisis de imágenes, identifican automáticamente las plagas y enfermedades presentes en las plantas de sandía. Esta innovación presenta un potencial prometedor para mejorar la gestión sanitaria de los cultivos y la toma de decisiones en la industria agrícola. Véase el gráfico 2.

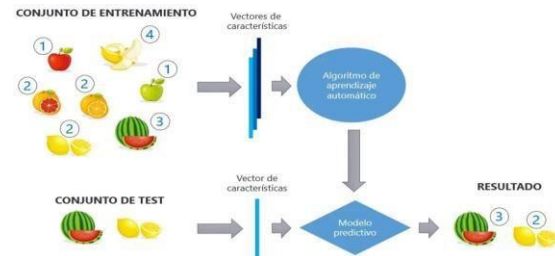


Fig. 2. Modelo de interacción de datos. fuente:
Machine Learning Model

El plan es desarrollar un sistema de visión por computadora que adopte un enfoque de modelado contextual para la detección de plagas y enfermedades en los campos de sandía. En este contexto, el modelado contextual se refiere a la capacidad del sistema para tener en cuenta el entorno circundante y las características específicas de las plantas de sandía al realizar la identificación y clasificación de estas amenazas.

Adquisición de datos: Es necesario obtener imágenes de plantas de sandía tanto en estado saludable como afectadas por diferentes plagas y enfermedades. Estas imágenes constituirán el conjunto de datos de entrenamiento para el sistema de visión por computadora.

Acondicionamiento de la imagen: Antes de introducir imágenes en el modelo, es esencial aplicar un proceso de acondicionamiento para mejorar su calidad y reducir el ruido. Esto podría incluir acciones como corregir el equilibrio de color, ajustar el contraste y eliminar fondos no deseados.

Extracción de características: Para facilitar la identificación y categorización de plagas y enfermedades, es esencial obtener características distintivas de las imágenes. Este proceso puede implicar la aplicación de algoritmos de visión por computadora, como la Transformada de Patrón Local (LBP) o la Transformada de Onda, para capturar patrones salientes presentes en las imágenes. Estos enfoques nos permiten reconocer atributos particulares que son específicos de ciertas plagas y enfermedades. **Modelado contextual:** El sistema de visión artificial debe considerar el contexto del ambiente de cultivo de la sandía al llevar a cabo la identificación y clasificación. Esto implica tener en cuenta elementos como la forma de las hojas, el tono de los frutos, la detección de manchas o daños, y cualquier otro indicador relevante para discernir plagas o enfermedades específicas.

Modelo de formación: Es esencial para entrenar un modelo de aprendizaje automático y una estrategia

avanzada para hacer frente a este desafío implica el uso de una convolución Neural Network (CNN), utilizando el conjunto de imágenes etiquetadas. El modelo debe adquirir la capacidad de identificar patrones y rasgos distintivos relacionados con diversas plagas y enfermedades.

Verificación y ajuste: Una vez completados los entrenamientos, el modelo debe someterse a verificación utilizando un conjunto de datos separado. Puede ser necesario realizar ajustes a hiper parámetros o modificaciones al modelo para mejorar su eficiencia y precisión.

Puesta en marcha e implementación: Una vez el modelo ha sido verificado y afinado, es posible ponerlo en funcionamiento en un sistema de visión por computadora capaz de procesar imágenes simultáneamente. Esto podría implicar el uso de cámaras o sensores para capturar imágenes de plantas de sandía en el campo y transmitir las al sistema de procesamiento. Véase la figura 3.




Fig. 3. Ejemplo de interacción. fuente: R. Cueto, J. Atencio, J. Gómez.

Corresponde al registro de un usuario en la aplicación del sistema, vinculado a cada función dentro del sistema. La información de validación del sistema se preservará en caso de que aún no se haya inscrito. Adicionalmente, en nuestra demostración interactiva, tras cargar o adquirir imágenes, será factible para visualizar las enfermedades detectadas en las imágenes buscadas. Después de subir o tomar fotos, se habilita el análisis de las enfermedades que ocurrirán en las plantas.

5. ARQUITECTURA

La aplicación, identificada como la aplicación Sandi, incluye tres componentes esenciales para su funcionamiento (Resumen Gráfico): A nivel de usuario, inicialmente hay una capa de interfaz o GUI desarrollada utilizando el lenguaje FLUTTER© en el entorno de Android Studio©. Esta capa permite al usuario interactuar con la aplicación instalada en su dispositivo móvil. En segundo lugar, se presenta la capa lógica o interfaz de control, que cubre la programación de las clases de componentes. Esta

sección se desarrolla utilizando el entorno VS Cod (basado en el FLUTTER© SDK) y usos en API biblioteca de enlaces basada en JAVASCRIPT, JAVA y C (Dart©). La tercera capa se conoce como la capa de persistencia, que también se configura en el lado del servidor y está relacionada con el procesamiento de la interfaz de almacenamiento de datos y la gestión de transacciones. La integración de la base de datos en el sistema se lleva a cabo mediante el uso de la API de Google Firebase, que se utiliza para el almacenamiento de información. Los actores principales del sistema son los usuarios (clientes) que interactúan con el sistema a través de los menús de navegación en cada pantalla de la aplicación. La tabla 2 detalla los módulos a los que el usuario puede acceder.

Tabla 2. Módulos de usuario.
fuente: R. Cueto, J. Atencio, J. Gómez.

WIDGETS	LOCALE S	EN LÍNEA
Registro		-
Usuaría		-
Subir Imagen		-
Búsqueda de Enf.		-
Tratamiento		-
Mostrar Cuidado		-
Ver Reporte		-
Filtro		-
Información		-
Perfil		-

Dado que este proyecto es una aplicación móvil, su funcionamiento ha sido diseñado para ejecutarse en la plataforma Android (versión 4.4), que demuestra una mayor compatibilidad con una amplia gama de dispositivos móviles (smartphones) disponibles en el mercado.

La estructura del sistema adopta un enfoque cliente-servidor, donde los clientes interactúan con la interfaz, realizan acciones, actualizan vistas y cargan datos. La arquitectura mantiene el estado de la aplicación, gestiona las solicitudes hacia y desde el servidor y controla la presentación de la información.

Cuando se realiza una operación en la aplicación, como verificar el acceso de un usuario, la aplicación envía una solicitud HTTP (basada en la API de DART=) a un servidor web. Este servidor contiene datos almacenados en una base de datos, que se aloja en un servicio web con el fin de ofrecer asesoramiento en línea.

El servidor web es responsable de la grabación o actualización de información, responder a solicitudes de aplicaciones cliente, asignar tareas a servicios web,

gestionar operaciones de almacenamiento o extracción de datos de la base de datos, actualizar tablas del sistema, cargar datos en un servidor o ejecutar consultas específicas. Volver a la aplicación móvil, procesa y presenta la información en formato JSON. La estructura de nuestro sistema se visualiza en el Resumen Gráfico que se ha preparado.

6. MARCO DE PRUEBA Y EVALUACIÓN DE APLICACIONES MÓVILES

Al abrir la aplicación, se muestra una interfaz donde el usuario puede iniciar sesión, seguido de un formulario de inicio de sesión para aquellos usuarios que ya están registrados en la plataforma, lo que les permite continuar desde esa etapa de lo contrario. Como se muestra en la Figura 5, se muestra la pantalla inicial de la aplicación. Esta pantalla valida que el intento de inicio de sesión del usuario no es válido, disparando un mensaje de error y bloqueando el acceso al menú de opciones del usuario. Véanse las figuras 4 y 5.

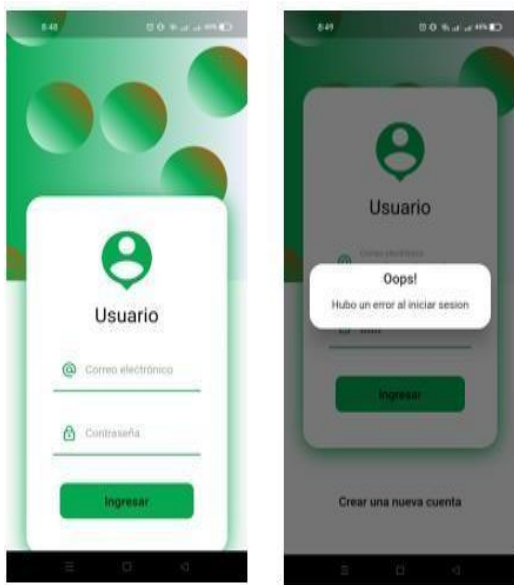


Fig. 4. Comienza la sesión.

Evaluación del proceso de registro de usuarios: La figura 6 ilustra la interfaz correspondiente al procedimiento de registro de usuarios. En esta evaluación, se lleva a cabo el proceso de registro de usuarios, las imágenes se organizan siguiendo el flujo establecido y, en última instancia, se presenta la pantalla resultante



Figura 5. Registro de usuario.
fuente: R. Cueto, J. Atencio, J. Gómez.

La sandía (*Citrullus vulgaris*), una planta que pertenece a la familia de las cucurbitáceas, tiene sus orígenes en el desierto de Kalahari en África, donde todavía se encuentra en su forma silvestre. Los primeros signos de su cultivo se remontan aproximadamente al año 3000 a.C. y se registraron en Egipto, desde donde su cultivo se extendió a diferentes regiones de la zona mediterránea. Con respecto a esta investigación se centró en las enfermedades y plagas en los cultivos de sandía, es relevante destacar que hay varias variedades de este cultivo, cada uno con sus propias enfermedades y plagas específicas, como se mencionó (J. M. G. Recinos, Rendimiento de híbridos de sandía tipo personal; valle del Motagua, Zacapa., Zacapa, 2015).

One of the main challenges facing agriculture hoy es la necesidad de lograr altos rendimientos sin agotar los recursos naturales. Para garantizar la sostenibilidad de la agricultura, ésta debe ser productiva desde el punto de vista económico, pero también debe considerar la preservación de los recursos naturales y la integridad ambiental a nivel local, regional y mundial. Además, es crucial tener en cuenta la diversidad social y cultural al explorar alternativas efectivas, como se sugiere. La sandía, siendo una fruta altamente delicada, es susceptible a

plagas y enfermedades que afectan partes específicas de la planta, particularmente las hojas. En este contexto, se proporciona información relevante sobre el proceso de detección de plagas. Según Ramírez Escalante, Boris. Procesamiento Digital de Imágenes, (2006), en una entrevista, los agricultores a menudo identifican las plagas intuitivamente yendo al campo y observando cuidadosamente los cultivos. Aunque la experiencia puede guiar sus observaciones, es común que los efectos de plagas o enfermedades sean consistentes, como el amarillamiento de las hojas que a menudo se asocia con plagas como el pulgón y enfermedades como el fusarium. Sin embargo, los agricultores con menos experiencia podrían cometer errores y recurrir al uso incorrecto de agroquímicos.

Además, según (J. M. G. Recinos, Rendimiento de híbridos de sandía tipo personal; valle del Motagua, Zacapa., Zacapa, 2015), la inteligencia artificial se refiere a la creación de elementos que exhiben comportamientos inteligentes, que incluyen la capacidad de aprender, adaptarse a los cambios contextos, manifiestan la creatividad y otras habilidades, y todo esto en combinación con la capacidad de realizar tales funciones. Este campo es excepcionalmente diverso, abarcando áreas tan amplias como la neurociencia, la psicología, la tecnología de la información, la ciencia cognitiva, la física, las matemáticas y mucho más. Además, se pueden obtener y generar diversas percepciones y acciones a través de sensores físicos y mecánicos en los dispositivos, así como a través de señales eléctricas o de luz en los sistemas informáticos. Estos procesos se realizan a través de módulos de entrada y salida en programas y su entorno de software. Los ejemplos de estos procedimientos van desde sistemas de monitoreo y automatización de programación hasta diagnósticos de respuesta, interacción con el cliente, reconocimiento de escritura, identificación de voz y detección de patrones. Véase la figura 6. La inteligencia artificial ya se aplica ampliamente en diversos sectores, como la economía, la medicina, la ingeniería y las fuerzas armadas.

Asimismo, se aplica en numerosas aplicaciones de software, videojuegos y estrategias, como el ajedrez computarizado y otros dispositivos electrónicos. Mediante un examen exhaustivo de la literatura.

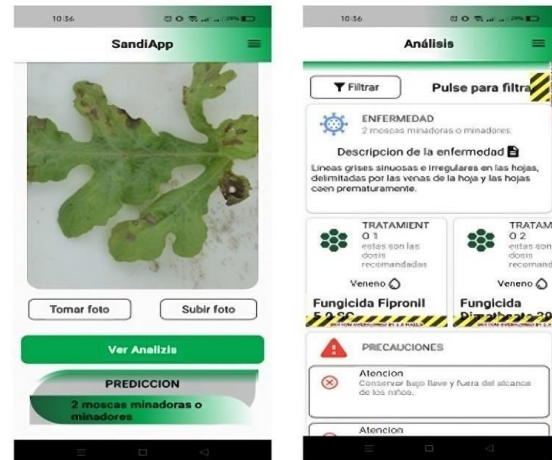


Figura 6. Predicción y su respectivo análisis.
fuente: R. Cueto, J. Atencio, J. Gómez.

6.1 Procedimientos en los que introducimos la formación de los datos obtenidos.

6.1.1 Convertir listas a matrices numpy

```
X = np.array(imagenes)
y = np.array(etiquetas)
```

Aquí, las imágenes de las listas y las etiquetas se convierten en matrices NumPy X e y, respectivamente. Esto es necesario para trabajar con las funciones y métodos proporcionados por la biblioteca NumPy y SciKit-Learn.

6.1.2 Comprobar las dimensiones de las imágenes

```
imprimir ("Dimensiones originales de las imágenes: ", X.shape[1:])
```

Esta línea imprime las dimensiones originales de las imágenes. X.shape devuelve una tupla que contiene las dimensiones de la matriz).

6.1.3 Aplanar las imágenes

```
X = X. remodelación(X.shape[0], -1)
```

Aquí, las imágenes son "aplanadas" usando la remodelación. Esto significa que se transforman de matrices bidimensionales a matrices unidimensionales. Esto es común en el procesamiento de imágenes para que cada imagen se convierta en un vector unidimensional de píxeles.

```
Dividir el conjunto de datos de formación y pruebas:
X_entrenamiento, X_prueba, y_entrenamiento,
y_prueba = train_test_split(X, y, test_size=0.3,
random_state=1)
```

El conjunto de datos se divide en formación (X_{training} , y_{training}) y conjuntos de pruebas (X_{testing} , y_{testing}) utilizando la función `train_test_split` de SciKit-Learn. El 30% del conjunto de datos se utiliza como conjunto de pruebas (`test_size=0,3`) y se establece una semilla aleatoria (`random_state=1`) para garantizar la reproducibilidad.

6.1.4 Crear el clasificador del árbol de decisiones

```
arbol = ClasificadorDelArbolDeDecisiones ()
```

Se crea un objeto clasificador de árbol de decisión usando Clase `ClasificadorDeArbolDeDecisiones` de SciKit-Learn.

6.1.5 entrenar el árbol de decisión:

```
arbol.fit (X_entrenamiento, y_entrenamiento)
```

El árbol de decisión se forma en el conjunto de formación (X_{training} , y_{training}) utilizando el método `fit`. Esto significa que el modelo aprenderá a tomar decisiones basadas en las características de las imágenes para predecir las etiquetas.

6.1.6 predecir etiquetas de prueba

```
y_prediccion = arbol.predict(X_prueba)
```

El árbol de decisiones se utiliza para hacer predicciones sobre el conjunto de pruebas (X_{test}) utilizando el método de predicción.

6.1.7 evaluar la precisión del modelo

```
precision = metrics.accuracy_score (y_prueba,
y_prediccion)
print ("Precisión: ", precision)
```

Finalmente, la precisión del modelo se calcula comparando las etiquetas predichas ($y_{\text{prediction}}$) con las etiquetas reales del conjunto de pruebas (y_{test}) utilizando la función de precisión SciKit-Learn. La precisión se imprime en la pantalla.

En resumen, este código realiza un proceso completo de capacitación y evaluación de un modelo de clasificación basado en árbol de decisiones utilizando conjuntos de datos de imágenes y etiquetas. La precisión del modelo se calcula y se muestra como resultado.

Observamos los resultados del algoritmo del árbol de decisiones.

Resultado: árbol de decisión $19002 \leq 0.45$

Así que, en resumen, lo que hace este código es tomar el árbol de decisión entrenado (árbol), generar una representación de texto de ese árbol, y luego imprimirlo en la consola. Esta representación de

texto proporciona información sobre cómo se divide el árbol en cada nodo, qué características se utilizan en cada división y cuáles son los criterios de decisión en cada nodo. Esto es útil para entender la lógica interna del árbol de decisiones y cómo toma decisiones basadas en las características de entrada. También se incluyen nombres de características para una mejor comprensión (Gómez et al., 2023; Oviedo et al., 2019).




Figura 7. Matriz de confusión.

fuelle: R. Cueto, J. Atencio, J. Gómez

Se crea una figura de visualización con un tamaño de 8x6 pulgadas usando `plt.figure(figsize=(8, 6))`.

`sns.heatmap` de la biblioteca Seaborn se utiliza para trazar la matriz de confusión como un mapa de calor. `confusion_matrix` es la matriz de confusión calculada en el paso anterior, y `annot=True` indica que los valores dentro de las celdas del mapa de calor deben mostrarse.

`fmt="d"` especifica el formato de los valores dentro de las celdas (enteros). `cmap="Blues"` establece el esquema de color para usar en el mapa de calor. En este caso, el esquema de color "Blues" que va desde tonos más claros a más oscuros se utiliza para representar los valores. `cbar=False` evita que se muestre una barra de color en el lado del mapa de calor.

Las etiquetas se agregan a los ejes x e y para indicar las etiquetas verdaderas y predichas, y se agrega un título a la figura.

Finalmente, la visualización se muestra con `plt.show()`. En resumen, este código calcula la matriz de confusión para evaluar el rendimiento del modelo de clasificación y crea una visualización de la matriz de confusión en forma de un mapa de calor para una fácil interpretación de cómo el modelo es correcto o incorrecto en sus predicciones.

6. 2 Modelo de red neuronal y sus épocas

Este código se refiere a la construcción, entrenamiento y evaluación de un modelo de red neuronal utilizando el Keras

biblioteca (que es parte de TensorFlow) en Python. Aquí hay una explicación paso a paso:

Se crea un modelo de red neuronal secuencial que es una pila lineal de capas.

La primera capa es una capa densa con 64 unidades y activación ReLU ('relu'). Esta capa tiene una entrada con la misma forma que las características de entrada de los datos (`input_shape=(X_training.shape [1],)`).

La segunda capa es otra capa densa con una sola unidad y activación sigmoide ('sigmoide'). Esta capa se usa comúnmente en problemas de clasificación binaria para obtener una probabilidad entre 0 y 1 como salida.

El modelo se compila utilizando el optimizador 'adam', que es un optimizador ampliamente utilizado en el entrenamiento de redes neuronales.

La función de pérdida se especifica como 'binary_crossentropy', que sugiere que el problema es la clasificación binaria. Esta función de pérdida mide qué tan bien el modelo se ajusta a las etiquetas verdaderas. También se especifica que queremos rastrear la métrica de precisión durante el entrenamiento.

El modelo se forma utilizando el conjunto de formación (`X_training` y `y_training`) para un número específico de épocas (10 en este caso) utilizando el método `fit`.

El parámetro `batch_size=32` indica que se utilizará un tamaño de lote de 32 muestras a la vez durante el entrenamiento. Esto ayuda a acelerar el proceso de entrenamiento y puede mejorar la estabilidad del entrenamiento. El modelo se evalúa utilizando el conjunto de pruebas (`X_test` y `test`) utilizando el método de evaluación. El resultado de la evaluación se almacena en la variable de evaluación, que contiene la pérdida y la precisión (exactitud) del modelo. Finalmente, la precisión del modelo se imprime en el conjunto de pruebas.

La importancia de este código es que muestra cómo construir, entrenar y evaluar un modelo de red neuronal para resolver un problema de clasificación binaria. Las redes neuronales son una poderosa técnica de aprendizaje profundo y se utilizan en una variedad de aplicaciones, desde el procesamiento de imágenes hasta el procesamiento de lenguaje natural y más. Entender cómo diseñar y entrenar modelos de red neuronal es fundamental para la ciencia de datos avanzada y aplicaciones de aprendizaje

automático. La precisión del modelo en el conjunto de pruebas proporciona información sobre su rendimiento en datos invisibles y puede guiar las decisiones sobre su utilidad en aplicaciones reales.

6.3 Árbol de decisión

Interpretabilidad: Los árboles de decisión son altamente interpretables. Puede visualizar el árbol y entender fácilmente cómo se toman las decisiones en cada nodo. Esto es útil para explicar y justificar las decisiones modelo.

Rendimiento en datos tabulares y características simples: Los árboles de decisión funcionan bien en datos tabulares con características simples. Son buenas para problemas donde las relaciones entre características y etiquetas son claras y no lineales.

Sensibilidad a los datos ruidosos: Los árboles de decisión pueden ser sensibles a los datos ruidosos o atípicos. Pueden estar sobrecargados si no se controlan adecuadamente.

Facilidad de entrenamiento y predicción: Los árboles de decisión son relativamente rápidos para entrenar y predecir en comparación con modelos más complejos como las redes neuronales.

6.4 Red Neuronal

Capacidad de representación: Las redes neuronales tienen una fuerte capacidad de representación y pueden aprender relaciones complejas entre características y etiquetas. Son adecuados para una amplia gama de problemas de aprendizaje automático, incluyendo problemas de visión por computadora, procesamiento del lenguaje natural y más. **No linealidad:** Las redes neuronales pueden modelar relaciones no lineales entre características y etiquetas de manera más efectiva que los árboles de decisión.

Requiere más datos y recursos: Las redes neuronales típicamente requieren conjuntos de datos más grandes y más recursos computacionales para entrenar adecuadamente. También pueden requerir más ajustes de hiper parámetros.

Menos interpretabilidad: Las redes neuronales tienden a ser menos interpretables que los árboles de decisión. La estructura interna de una red neuronal puede ser compleja y difícil de entender.

6.5 comparación

Si el problema es relativamente simple y los datos son tabulares con relaciones lineales o simples entre características y etiquetas, un árbol de decisiones podría ser una opción apropiada debido a su interpretabilidad y eficiencia.

Si el problema es más complejo y requiere capturar relaciones no lineales o patrones sofisticados en los datos, una red neuronal podría ser más apropiada. Sin embargo, esto podría requerir más datos y recursos computacionales.

En general, es una buena práctica probar varios tipos de modelos, incluyendo árboles de decisión y redes neuronales, y comparar sus resultados usando métricas de evaluación como precisión, recuperación y puntaje F1 en un conjunto de pruebas independiente. Esto le ayudará a determinar qué modelo se adapta mejor a su problema específico. También puede considerar la interpretabilidad y los recursos disponibles al tomar su decisión.

7. CONCLUSIONES Y FUTUROS TRABAJOS

Después de realizar las evaluaciones en el proceso de desarrollo de este proyecto, se puede concluir lo siguiente:

A través de la implementación del sistema de visión por computadora, los agricultores han experimentado un aumento en su comprensión de las plagas y enfermedades que afectan a los cultivos de sandía. Según los resultados de la encuesta, se puede deducir que

El 81,2% de los encuestados ha declarado que la información proporcionada ha enriquecido su nivel de conocimiento, satisfaciendo sus expectativas proporcionando detalles concisos y completos. Por otro lado, antes de la introducción del software, solo el 26,5% de los agricultores había mencionado tener niveles básicos y secundarios de información. Evidentemente, el nivel de digitalización ha mejorado considerablemente.

Además, la inclusión de sistemas de visión artificial ha aumentado significativamente la proporción de agricultores que ahora tienen una mejor comprensión de los productos químicos agrícolas recomendados. Según la encuesta, el 82,6% de la población afirma actualmente que la información proporcionada ha contribuido a aumentar su nivel de conciencia. En contraste, antes de la implementación del software, solo el 5,8% de los agricultores había expresado tener un nivel moderado de información. Una vez más, se puede inferir que el sistema ha logrado cumplir sus objetivos declarados.

El desarrollo de un sistema de visión artificial con el propósito de identificar plagas y enfermedades en el cultivo de la sandía constituye una solución innovadora y eficaz a los desafíos que enfrenta la agricultura. Esta solución combina tecnologías

avanzadas como el procesamiento de imágenes y el aprendizaje automático para ofrecer herramientas precisas y confiables que ayudan a los agricultores en la detección y gestión oportuna de plagas y enfermedades que dañan los cultivos de sandía. A través de cámaras y algoritmos avanzados, la tecnología de visión artificial tiene la capacidad de analizar imágenes de plantas de sandía para signos y síntomas de plagas y enfermedades. Esto permite una identificación rápida y precisa, facilitando la toma de decisiones informada y la aplicación de medidas de control específicas. Además, el sistema ofrece varias ventajas para los agricultores. Realice inspecciones exhaustivas y ágiles en grandes áreas de cultivo, reduciendo la necesidad de inspecciones manuales y ahorrando tiempo y recursos. También proporciona evaluaciones objetivas y uniformes, reduce los errores humanos y permite la adopción de medidas preventivas tempranas.

La introducción de un sistema de visión artificial diseñado para reconocer plagas y enfermedades en el cultivo de sandía presenta un gran potencial para aumentar la productividad y la rentabilidad de los agricultores, reduciendo al mínimo el impacto ambiental mediante la reducción del uso de plaguicidas y otros productos químicos. Este enfoque está emergiendo como una herramienta muy prometedora en el campo de la agricultura de precisión, allanando el camino para futuros avances en el control y manejo de cultivos.

La integración del sistema de visión artificial en la producción de sandía ofrece una solución extremadamente eficaz y eficiente para la detección temprana y el control de plagas y enfermedades. Su capacidad para mejorar la eficiencia de la producción, reducir los costos y mitigar el impacto ambiental lo convierte en un recurso invaluable para los agricultores que enfrentan problemas de salud de los cultivos. A continuación, se presentan algunas recomendaciones para fortalecer aún más el desarrollo de sistemas de visión artificial con respecto a la identificación de plagas y enfermedades en el cultivo de sandía: Aumentar la precisión: Continuar mejorando los algoritmos destinados a detectar y reconocer plagas es crucial. Esto implica recopilar una variedad de imágenes de alta resolución para entrenar los modelos de aprendizaje automático, así como realizar pruebas y validaciones constantes para aumentar la precisión y fiabilidad del sistema.

Ampliar la base de datos: Para optimizar la eficacia del sistema, es esencial establecer y mantener una

base de datos actualizada y extensa que cubra imágenes de diversas plagas, enfermedades y situaciones que afectan el cultivo de la sandía. A medida que esta base de datos crece en tamaño y diversidad, la capacidad del sistema para reconocer y categorizar una variedad de desafíos que pueden surgir en los cultivos se mejorará en gran medida.

Integrar múltiples tecnologías: La visión artificial puede enriquecerse con otras tecnologías, como sensores de temperatura, humedad o calidad del suelo, para obtener una comprensión completa del estado de los cultivos de sandía. La combinación de estas tecnologías puede proporcionar una evaluación integral de la salud vegetal y permitir decisiones más precisas y oportunas en el manejo de los cultivos. Desarrollar una interfaz de usuario intuitiva: Para que los agricultores saquen el máximo partido del sistema de visión artificial, es esencial diseñar una interfaz de usuario que sea fácil de entender y usar. Esta interfaz les permite interactuar sin problemas con el sistema, acceder a informes y resultados, y comprender las recomendaciones y las acciones sugeridas.

Adaptabilidad a diferentes ambientes y condiciones: Dado que los cultivos de sandía pueden crecer en varios contextos y condiciones.

Al considerar los factores geográficos y ambientales, es importante que los sistemas de visión artificial sean adaptables a una amplia gama de climas, tipos de sandía y métodos de cultivo. Esto implica abordar las diferencias en la incidencia de plagas y enfermedades dependiendo de las condiciones específicas, asegurando que el sistema sea resistente y preciso en varios escenarios. También es crucial fomentar la colaboración constante y recibir retroalimentación continua.

La colaboración entre investigadores, agricultores y expertos en tecnología agrícola se convierte en un componente esencial para asegurar la evolución constante de este sistema. Las contribuciones de los usuarios finales son inestimables para identificar áreas de mejora y abordar las necesidades individuales de los productores con respecto a la detección y el control de plagas y enfermedades en los cultivos de sandía.

La implementación de estas recomendaciones puede resultar en sistemas de visión artificial cada vez más eficientes y valiosos para la identificación y manejo de plagas y enfermedades en los cultivos de sandía. Esto, a su vez, contribuirá a una agricultura más productiva, sostenible y rentable.

RECONOCIMIENTO

Gracias a la Universidad de Córdoba por financiar este proyecto de investigación según la convocatoria interna con código de proyecto FI-05-19. También agradecemos al grupo de investigación SÓCRATES del programa de Ingeniería de Sistemas y Telecomunicaciones por apoyar el desarrollo de este proyecto.

REFERENCIAS

- Pardo G., A. y Díaz R., J. L. (2004). *Aplicaciones de los convertidores de frecuencia*, Estrategias PWM, Editorial Java E. U., Colombia.
- Ogata, K. (2004). *Ingeniería de Control Moderna*, Prentice Hall, Cuarta edición, Madrid.
- Clymer, J. R. (1992). "Discrete Event Fuzzy Airport Control". *IEEE Trans. On Systems, Man, and Cybernetics*, Vol. 22, No. 2.
- Gómez-Camperos, J.A., Jaramillo, H.Y., & Guerrero-Gómez, G. (2021). Técnicas de procesamiento digital de imágenes para detección de plagas y enfermedades en cultivos: una revisión. *INGENIERÍA Y COMPETITIVIDAD*.
- Martínez-Corral, L., Martínez-Rubín, E., Flores-García, F., Castellanos, G.C., Juárez, A.L., & López, M. (2009). Desarrollo de una base de datos para caracterización de alfalfa (*Medicago sativa* L.) en un sistema de visión artificial.
- Santa María Pinedo, J.C., Ríos López, C.A., Rodríguez Grández, C., & García Estrella, C.W. (2021). Reconocimiento de patrones de imágenes a través de un sistema de visión artificial en MATLAB. *Revista Científica de Sistemas e Informática*.
- Malpartida, S., & Ángel, E.T. (2011). Sistema de visión artificial para el reconocimiento y manipulación de objetos utilizando un brazo robot.
- Vargas, O.L., & Perrez, Á.A. (2019). Implementación de un Sistema de Visión Artificial para la clasificación de naranja producida en el departamento del Quindío.
- León León, R.A., Jara, B.J., Cruz Saavedra, R., Terrones Julcamoro, K., Torres Verastegui, A., & Aponte de la Cruz, M.A. (2020). *DESARROLLO DE SISTEMA DE VISIÓN ARTIFICIAL PARA CONTROL DE CALIDAD DE BOTELLAS EN LA EMPRESA CARTAVIO RUM COMPANY*. Ingeniería Investigación y Desarrollo.

- Ramírez Escalante, Boris. *Procesamiento Digital de Imágenes* [en línea], Verona, [citado agosto, 2006].
- J. M. G. Recinos, *Rendimiento de híbridos de sandía tipo personal; valle del Motagua, Zacapa*, Zacapa, 2015.
- Bautista, R.A., Constante, P., Gordon, A., & Mendoza, D. (2019). Diseño e implementación de un sistema de visión artificial para análisis de datos NDVI en imágenes espectrales de cultivos de brócoli obtenidos mediante una aeronave pilotada remotamente.
- Prócel, P.N., & Garcés, A.M. (2015). Diseño e implementación de un sistema de visión artificial para clasificación de al menos tres tipos de frutas.
- Yandún Velasteguí, M.A. (2020). Detección de enfermedades en cultivos de Papa usando procesamiento de imágenes.
- Martínez, F.H., Montiel, H., & Martínez, F. (2022). A Machine Learning Model for the Diagnosis of Coffee Diseases. *International Journal of Advanced Computer Science and Applications*.
- Ortega, B.R., Biswal, R.R., & Sánchez-Delacruz, E. (2019). Detección de enfermedades en el sector agrícola utilizando Inteligencia Artificial. *Res. Comput. Sci.*, 148, 419-427.
- Zapata, V., & Alejandro, J.R. (2019). Diseño y desarrollo de un sistema prototipo de diagnóstico de afecciones en plantas de cítricos utilizando procesamiento de imágenes y aprendizaje profundo.
- Pillajo, M.A., Pillajo, M.A., & Cabascango, A.S. (2019). Diagnóstico inteligente de enfermedades y plagas en plantas ornamentales.
- Narciso Horna, W.A., & Manzano Ramos, E.A. (2021). Sistema de visión artificial basado en redes neuronales convolucionales para la selección de arándanos según estándares de exportación. *Campus*.
- Huaccha, E.D. (2018). Desarrollo de un sistema de visión artificial para realizar una clasificación uniforme de limones.
- Bautista, R.A., Constante, P., Gordon, A., & Mendoza, D. (2019). Diseño e implementación de un sistema de visión artificial para análisis de datos NDVI en imágenes espectrales de cultivos de brócoli obtenidos mediante una aeronave pilotada remotamente. *Infociencia*.
- Tinajero, J., Acosta, L.A., Chango, E.F., & Moyon, J.F. (2020). Sistema de visión artificial para clasificación de latas de pintura por color considerando el espacio de color RGB.
- Salazar, P., Ortiz, S., Hernandez, T.H., & Bermeo, N.V. (2016). Artificial Vision System Using Mobile Devices for Detection of Fusarium Fungus in Corn. *Res. Comput. Sci.*, 121, 95-104.
- hyar, B.S., & Birajdar, G.K. (2017). Computer vision based approach to detect rice leaf diseases using texture and color descriptors. *2017 International Conference on Inventive Computing and Informatics (ICICI)*, 1074-1078.
- Yasir, R., Rahman, M.A., & Ahmed, N. (2014). Dermatological disease detection using image processing and artificial neural network. *8th International Conference on Electrical and Computer Engineering*, 687-690.
- P. P. Garcia Garcia, *Reconocimiento de imagenes utilizando redes neuronales artificiales*, Madrid, España, 2013.
- Orduz, J. O., León, G. A., Chacón Díaz, A., Linares, V. M., & Rey, C. A. (2000). El cultivo de la sandía o patilla (*Citrullus lanatus*) en el departamento del Meta (No. Doc. 21998) CO-BAC, Bogotá).
- González Sánchez, H. A. (1999). Impacto ambiental de la labranza mecánica convencional. *Departamento de Ciencias Agropecuarias*.
- R. Jorge, *Introducción a los sistemas de visión artificial*, Madrid, España, 2011.
- CHAVEZ, *Procesamiento de imágenes* [en línea], Puebla, Universidad de las Américas Puebla [citado en 6 de Julio de 2015].
- MATWORKS, *Detección de bordes* [en línea], [citado en 6 de octubre de 2015].
- A. Marin Poatoni, *Desarrollo de prototipo de aplicacion (APP), para dispositivos móviles basados en el sistema IOS, para el reconocimiento de objetos "Hojas" en imagenes*, Motecillo, Mexico, 2014.
- H. T. T., L. V. G. Bay, «Speeded-Up Robust,» EE. UU, 2006.
- Gomez, J. G., Hernandez, V., & Ramirez- Gonzalez, G. (2023). Traffic classification in IP networks through Machine Learning techniques in final systems. *IEEE Access*.
- Oviedo, B., Zambrano-Vega, C., & Gómez, J. (2019). Clasificador Bayesiano Simple aplicado al aprendizaje. *Revista Ibérica de Sistemas e Tecnologías de Informação*, 18, 74-85.