



**UNIVERSIDAD TÉCNICA ESTATAL DE QUEVEDO**  
**FACULTAD DE CIENCIAS DE LA INGENIERÍA**  
**CARRERA DE SOFTWARE**

Trabajo de Integración  
Curricular previa la obtención  
del Grado Académico de  
Ingeniero de Software

**Proyecto de Investigación:**

**“DETECCIÓN DE PLAGAS QUE AFECTAN AL TAMAÑO DE LA MUSA AAB  
UTILIZANDO UNA APLICACIÓN MÓVIL CON RECONOCIMIENTO DE  
IMÁGENES”**

**Autor:**

Jaime Andres Mora Vera

**Director del proyecto de investigación:**

Ing. Ariosto Eugenio Vicuña Pino, MSc.

**QUEVEDO - LOS RÍOS – ECUADOR**

**2024**



## DECLARACIÓN DE AUTORÍA Y CESIÓN DE DERECHOS

Yo, **JAIME ANDRES MORA VERA**, declaro que la investigación aquí descrita es de mi autoría; que no ha sido previamente presentado para ningún grado o calificación profesional; y, que he consultado las referencias bibliográficas que se incluyen en este documento.

La Universidad Técnica Estatal de Quevedo, puede hacer uso de los derechos correspondientes a este documento, según lo establecido por la Ley de Propiedad Intelectual, por su Reglamento y por la normatividad institucional vigente.

---

**Jaime Andres Mora Vera**

**C.I: 0940544901**



## **CERTIFICACIÓN DE CULMINACIÓN DEL PROYECTO DE INVESTIGACIÓN**

El suscrito, **Ing. Ariosto Eugenio Vicuña Pino, MSc**, docente de la Universidad Técnica Estatal de Quevedo, certifico que el estudiante **Jaime Andres Mora Vera** ha realizado el Proyecto de Investigación de grado titulado **“DETECCIÓN DE PLAGAS QUE AFECTAN AL TAMAÑO DE LA MUSA AAB UTILIZANDO UNA APLICACIÓN MÓVIL CON RECONOCIMIENTO DE IMÁGENES”** previo a la obtención del título de **Ingeniero de Software**, bajo mi dirección habiendo cumplido con las disposiciones reglamentarias establecidas para el efecto.

---

**Ing. Ariosto Eugenio Vicuña Pino, MSc.**

**DIRECTOR DEL PROYECTO DE INVESTIGACIÓN**



## CERTIFICADO DEL REPORTE DE LA HERRAMIENTA DE PREVENCIÓN DE COINCIDENCIA Y/O PLAGIO ACADÉMICO

El suscrito Ing. Ariosto Eugenio Vicuña Pino, MSc, **CERTIFICA** que:

El proyecto de investigación titulado “**DETECCIÓN DE PLAGAS QUE AFECTAN AL TAMAÑO DE LA MUSA AAB UTILIZANDO UNA APLICACIÓN MÓVIL CON RECONOCIMIENTO DE IMÁGENES**” ha sido analizado mediante la herramienta COMPILATIO y no presentó problemas de plagio.



Ing. Ariosto Eugenio Vicuña Pino, MSc

**DIRECTOR DEL PROYECTO DE INVESTIGACIÓN**



**UNIVERSIDAD TÉCNICA ESTATAL DE QUEVEDO**  
**FACULTAD DE CIENCIAS DE LA INGENIERÍA**  
**CARRERA DE SOFTWARE**

**PROYECTO DE INVESTIGACIÓN**

**Título:**

“Detección de plagas que afectan al tamaño de la Musa AAB utilizando una aplicación móvil con reconocimiento de imágenes”

Presentado al Consejo Directivo de Facultad como requisito previo a la obtención del título de Ingeniero de Software.

Aprobado por:

---

**PRESIDENTE DEL TRIBUNAL**

Ing., Cristian Gabriel Zambrano Vega, PhD.

---

**MIEMBRO DEL TRIBUNAL**

Ing. Rodríguez Gavilanes Nancy Magali, MSc

---

**MIEMBRO DEL TRIBUNAL**

Ing. Gleiston Cicerón Guerrero Ulloa, PhD.

**QUEVEDO - LOS RÍOS - ECUADOR**

**2024**

## **AGRADECIMIENTO**

Expreso mi profundo agradecimiento a mi familia, especialmente a mis padres Jaime y Karina, por haberme brindado su apoyo total durante todo el transcurso de mi preparación académica. Le agradezco a mi padre por enseñarme a ser una persona fuerte que no doblegue ante las dificultades, y a mi madre por recordarme siempre que el respeto y la determinación son las virtudes más importantes de una persona. Expreso también mi apoyo a mi compañera de vida, Daniela, por acompañarme en los momentos de éxito, así como en los momentos de dificultades y apoyarme ante dificultades.

Agradezco también al Ing. Ariosto Vicuña por haberme guiado durante el desarrollo de este trabajo, y en varias instancias de mi formación profesional, compartiendo su conocimiento y experiencia académica y profesional. Asimismo, extiendo mi agradecimiento a los docentes que han sido parte de mi preparación académica, por su entrega, dedicación y esfuerzo para formar profesionales.

Finalmente, agradezco a mis colegas, quienes han formado parte de mi preparación académica aportando nuevas perspectivas, nuevos conocimientos y siempre dispuestos a ayudar a los amigos.

## **DEDICATORIA**

*Dedico este proyecto a mis padres por haber sido el pilar fundamental de mi formación profesional, a quienes doy el mérito de haber forjado en mí el carácter de un profesional. Dedico también este trabajo a mi hijo, ya que él ha sido mi mayor motivación para esforzarme cada día por ser un mejor profesional, al igual que a su madre y mi compañera de vida, por darme tranquilidad en los momentos difíciles. También dedico este proyecto a mis docentes, especialmente al Ing. Ariosto Vicuña por su dedicación supervisando el desarrollo de esta investigación.*

**Jaime Andres Mora Vera**

## **RESUMEN EJECUTIVO Y PALABRAS CLAVES**

La detección temprana de plagas en la Musa AAB (plátano) es crucial para lograr una producción óptima. Sin embargo, la poca experiencia de agricultores es una limitante para hallar y eliminar estas plagas. El constante avance tecnológico y la integración de herramientas de software en la agricultura permiten idear soluciones a distintos problemas con una mayor eficiencia, además de lograr minimizar recursos. El objetivo de esta investigación fue obtener una aplicación móvil que integra un modelo de clasificación de imágenes para detectar enfermedades presentes en las hojas de plátanos. Para conseguir esta meta, se requirió realizar una revisión literaria para identificar las plagas más comunes. Posteriormente, se obtuvo un conjunto de imágenes de dichas plagas para entrenar un modelo de clasificación de imágenes. Este modelo fue implementado en una aplicación móvil nativa de Android y se realizó una prueba de usabilidad para evaluarla. Los resultados de la revisión literaria fueron la identificación de 6 plagas como las más comunes. Se obtuvo un conjunto de imágenes de 2856 elementos que permitió el entrenamiento del modelo, el cual mostró una precisión de 98% en la identificación de plagas. Así, la aplicación móvil constituye una solución positiva de acuerdo con la prueba de usabilidad realizada con expertos.

Palabras Clave: Plátano, Plagas, Visión por Computadora, CNN, Aplicación móvil

## **ABSTRACT**

Early detection of pests in Musa AAB (plantain) is crucial to achieve optimal production. However, farmers' limited experience is a constraint to finding and eliminating these pests. The constant technological advancement and integration of software tools in agriculture allow for solutions for many problems with greater efficiency, as well as minimizing resources. The main goal of this research was to develop a mobile application integrating an image classification model to detect diseases present in banana leaves. To achieve this goal, a literature review was required to identify the most common pests. Subsequently, a set of images of these pests was obtained to train an image classification model. This model was implemented in a native Android mobile application, and a usability test was conducted to evaluate it. The results of the literature review identified 6 pests as the most common. A set of 2856 images was obtained, allowing for the training of the model, which showed a 98% accuracy in pest identification. The mobile application constitutes a positive solution according to the usability test conducted with experts.

## TABLA DE CONTENIDO

PORTADA .....	i
DECLARACIÓN DE AUTORÍA Y CESIÓN DE DERECHOS .....	ii
CERTIFICACIÓN DE CULMINACIÓN DEL PROYECTO DE INVESTIGACIÓN..	iii
CERTIFICADO DEL REPORTE DE LA HERRAMIENTA DE PREVENCIÓN DE COINCIDENCIA Y/O PLAGIO ACADÉMICO.....	iv
CERTIFICACIÓN DE APROBACIÓN DEL PROYECTO INVESTIFACIÓN .....	v
AGRADECIMIENTO .....	vi
DEDICATORIA.....	vii
RESUMEN EJECUTIVO Y PALABRAS CLAVES .....	viii
ABSTRACT .....	ix
CÓDIGO DUBLÍN.....	xvii
INTRODUCCIÓN.....	1
CAPÍTULO I: CONTEXTUALIZACIÓN DE LA INVESTIGACIÓN.....	3
1.1.    Problema de investigación.....	4
1.1.1.    Planteamiento del problema .....	4
1.1.2.    Formulación del problema.....	6
1.1.3.    Sistematización del problema.....	6
1.2.    Objetivos.....	6
1.2.1.    Objetivo general .....	6
1.2.2.    OBJETIVOS ESPECIFICOS .....	6
1.3.    Justificación .....	7
CAPÍTULO II: MARCO CONCEPTUAL.....	9
2.1.    Marco conceptual .....	10
2.1.1.    Plátanos.....	10
2.1.2.    La tecnología en la agricultura .....	12
2.2.    Marco Referencial .....	16

CAPÍTULO III: METODOLOGÍA DE LA INVESTIGACIÓN .....	17
3.1. Localización.....	18
3.2. Tipo de investigación.....	18
3.3. Métodos de investigación .....	18
3.3.1. Método analítico .....	19
3.3.2. Método inductivo.....	19
3.4. Fuentes de recopilación de información.....	19
3.5. Diseño de la investigación.....	19
3.5.1. Identificación de plagas del plátano y sus variedades .....	20
3.5.1.1. Revisión bibliográfica.....	20
3.5.1.2. Obtención de un conjunto de imágenes .....	22
3.5.1.3. Entrevistas a expertos .....	22
3.5.2. Generación de un modelo de clasificación de imágenes .....	23
3.5.2.1. Preparación del conjunto de entrenamiento y de prueba.....	23
3.5.2.2. Diseño del modelo .....	23
3.5.2.3. Entrenamiento del modelo.....	24
3.5.2.4. Validación del modelo.....	25
3.5.3. Desarrollo de la aplicación móvil.....	26
3.5.3.1. Metodología de desarrollo .....	26
3.5.4. Evaluación de la usabilidad de la aplicación .....	27
3.6. Instrumentos de investigación .....	30
3.7. Tratamiento de los datos.....	30
3.8. Recursos humanos y materiales.....	30
3.8.1. Recursos humanos .....	30
3.8.2. Recursos de Hardware .....	31
3.8.3. Recursos de Software .....	31
CAPÍTULO IV: RESULTADOS Y DISCUSIÓN .....	32

4.1.	Variedades de plátanos .....	33
4.2.	Plagas en plátanos.....	34
4.3.	Obtención del Conjunto de Imágenes.....	35
4.4.	Entrenamiento del Modelo .....	36
4.5.	Desarrollo del prototipo de Aplicación Móvil.....	42
4.6.	Prueba de usabilidad.....	45
CAPÍTULO V: CONCLUSIONES Y RECOMENDACIONES .....		47
5.1.	Conclusiones.....	48
5.2.	Recomendaciones.....	49
BIBLIOGRAFÍA .....		50
ANEXOS .....		57

## ÍNDICE DE FIGURAS

Figura 1: Plátanos .....	10
Figura 2: Enfermedad del Moko.....	11
Figura 3: Mal de Panamá.....	12
Figura 4: Procesamiento de imágenes con visión por computadora .....	15
Figura 5: Redes Neuronales Convolucionales.....	15
Figura 6: Localización de la UTEQ.....	18
Figura 7: Conjunto de imágenes en Kaggle.....	36
Figura 8: Arquitectura de la red neuronal.....	38
Figura 9: Resultados del entrenamiento del modelo .....	39
Figura 10: Matriz de confusión .....	41
Figura 11: Diagrama de casos de uso .....	43
Figura 12: Primera versión de las interfaces .....	44
Figura 13: Versión final del prototipo .....	44

## ÍNDICE DE TABLAS

Tabla 1: Cadenas de búsqueda para la revisión literaria .....	21
Tabla 2: Criterios de Aceptación .....	21
Tabla 3: Métricas de usabilidad conforme norma ISO 9241 .....	28
Tabla 4: Recursos de hardware.....	31
Tabla 5: Recursos de software.....	31
Tabla 6: Variedades comunes de plátanos en Ecuador.....	33
Tabla 7: Principales plagas que afectan al tamaño del plátano .....	34
Tabla 8: Comparativa de el rendimiento de los modelos pre entrenados .....	37
Tabla 9: Capas de la red neuronal .....	39
Tabla 10: Métricas de eficiencia del modelo.....	42
Tabla 11: Anotaciones durante la técnica de observación directa.....	45
Tabla 12: Métricas de eficiencia de los usuarios usando la aplicación .....	46

## ÍNDICE DE ECUACIONES

Ecuación 1: Fórmula de precisión general del modelo.....	25
Ecuación 2: Fórmula de precisión del modelo por clase .....	25
Ecuación 3: Fórmula de sensibilidad del modelo por clase.....	25
Ecuación 4: Fórmula del puntaje F1 por clase .....	26
Ecuación 5: Cálculo de puntaje SUS.....	29

## ÍNDICE DE ANEXOS

Anexo 1: Código de la estructura de la red neuronal .....	58
Anexo 2: Código del entrenamiento del modelo .....	59
Anexo 3: Imágenes aumentadas de cada clase .....	59
Anexo 4: Diagrama de clases de la aplicación móvil .....	60
Anexo 5: Interfaz principal de la aplicación en Android Studio .....	60
Anexo 6: Código de clasificación de imágenes en Java .....	61
Anexo 7: Cálculo del puntaje SUS en Excel .....	62
Anexo 8: Cálculo en Excel de métricas de eficiencia del modelo.....	62
Anexo 9: Formato del cuestionario SUS utilizado en la investigación .....	63
Anexo 10: Caso de uso 1 - Clasificar imagen .....	64
Anexo 11: Caso de uso 2 - Capturar imagen desde cámara .....	65
Anexo 12: Caso de uso 3 - Capturar imagen desde galería .....	66
Anexo 13: Caso de uso 4 - Consultar historial de predicciones .....	67
Anexo 14: Caso de uso 5 - Consultar información de plagas.....	68
Anexo 15: Caso de uso 6 – Consultar variedades de plátanos .....	69
Anexo 16: Caso de uso 7 - Consultar consejos para plantaciones.....	70

## CÓDIGO DUBLÍN

<b>Título:</b>	Detección de plagas que afectan al tamaño de la musa AAB utilizando una aplicación móvil con reconocimiento de imágenes
<b>Autor:</b>	Mora Vera Jaime Andres
<b>Palabras Clave:</b>	Plátano, Plagas, Visión por Computadora, CNN, Aplicación móvil
<b>Fecha de publicación:</b>	2024
<b>Director del proyecto:</b>	Ing. Ariosto Eugenio Vicuña Pino
<b>Editorial:</b>	Universidad Técnica Estatal de Quevedo
<b>Resumen:</b>	La detección temprana de plagas en la Musa AAB (plátano) es crucial para lograr una producción óptima. Sin embargo, la poca experiencia de agricultores es una limitante para hallar y eliminar estas plagas. El constante avance tecnológico y la integración de herramientas de software en la agricultura permiten idear soluciones a distintos problemas con una mayor eficiencia, además de lograr minimizar recursos. El objetivo de esta investigación fue obtener una aplicación móvil que integra un modelo de clasificación de imágenes para detectar enfermedades presentes en las hojas de plátanos. Para conseguir esta meta, se requirió realizar una revisión literaria para identificar las plagas más comunes. Posteriormente, se obtuvo un conjunto de imágenes de dichas plagas para entrenar un modelo de clasificación de imágenes. Este modelo fue implementado en una aplicación móvil nativa de Android y se realizó una prueba de usabilidad para evaluarla. Los resultados de la revisión literaria fueron la identificación de 6 plagas como las más comunes. Se obtuvo un conjunto de imágenes de 2856 elementos que permitió el entrenamiento del modelo, el cual mostró una precisión de 98% en la identificación de plagas. Así, la aplicación móvil constituye una solución positiva de acuerdo con la prueba de usabilidad realizada con expertos.
<b>Abstract:</b>	Early detection of pests in Musa AAB (plantain) is crucial to achieve optimal production. However, farmers' limited experience is a constraint to finding and eliminating these pests. The constant technological advancement and integration of software tools in agriculture allow for solutions for many problems with greater efficiency, as well as minimizing resources. The main goal of this research was to develop a mobile application integrating an image classification model to detect diseases present in banana leaves. To achieve this goal, a literature review was required to identify the most common pests. Subsequently, a set of images of these pests was obtained to train an image classification model. This model was implemented in a native Android mobile application, and a usability test was conducted to evaluate it. The results of the literature review identified 6 pests as the most common. A set of 2856 images was obtained, allowing for the training of the model, which showed a 98% accuracy in pest identification. The mobile application constitutes a positive solution according to the usability test conducted with experts.
<b>Descripción:</b>	87 hojas: Dimensiones 21 cm x 29,7 cm + CD-ROM 6162
<b>URI:</b>	

## INTRODUCCIÓN

La *Musa* es un tipo de planta herbácea perenne, de la cual descienden diferentes variedades de especies como el plátano o el banano [1]. El banano es conocido con el nombre científico de *Musa AAA* y el plátano como *Musa AAB* [2]. El proceso de producción de estas plantas es muy similar, dado que ambas provienen de la misma especie, y asimismo las enfermedades y problemas que pueden presentarse en los árboles tienen características semejantes.

La agricultura es uno de los pilares fundamentales para la sostenibilidad de la población mundial. Los productos de origen agrícola son la base de la alimentación en todo el mundo, pero el aporte de los agricultores no es únicamente para satisfacer las necesidades alimenticias de los ciudadanos [3]. El comercio de los productos agrícolas representa una de las fuentes de financiamiento para los países que son altamente productores de materias primas, como lo es Ecuador. Uno de los principales productos que exporta Ecuador al exterior son el plátano y el banano, que provienen de la familia *Musa*. Esta fruta es muy comercializada en todo el mundo, de tal forma que juega también un papel crucial en la economía.

La demanda del plátano y banano es muy alta a nivel mundial. Sin embargo, estos productos agrícolas son susceptibles a enfermedades que afectan a su correcto crecimiento y desarrollo, teniendo consecuencias negativas en la producción y en la economía [2]. Al existir deficiencia en el crecimiento de la fruta, el tamaño es una característica que se ve afectada, lo que compromete su calidad final.

Este problema puede manejarse detectando las enfermedades y plagas en etapas tempranas del crecimiento de la planta. Una de las formas habituales para identificarlas es realizar una revisión visual a la planta y a la fruta para detectar características propias de las enfermedades. El inconveniente de esta práctica es que la evaluación debe ser realizada por expertos, ya que los agricultores con poca experiencia podrían dar resultados poco precisos.

Actualmente la tecnología se encuentra presente en el campo de la agricultura, existiendo proyectos donde se brinda apoyo contra problemas en plantaciones mediante el uso de tecnologías de software y hardware [4]. Es por esto que se propone el desarrollo de un

sistema que permita detectar plagas en la planta de plátano para determinar si la especie del plátano puede ser afectada negativamente en su tamaño adecuado para su comercialización.

La propuesta consiste en obtener un conjunto de imágenes donde se clasifiquen variedades de plátanos y las plagas que las afectan. Este conjunto de datos sirve para entrenar un modelo que pueda clasificar imágenes capturadas por los agricultores de tan forma que las compare con los datos del conjunto de imágenes y determine a qué plaga corresponde. Para poder lograr esto se propone desarrollar un prototipo de aplicación móvil que capture las imágenes para evaluarlas con el modelo entrenado y brindar una predicción o diagnóstico de la fruta.

**CAPÍTULO I**  
**CONTEXTUALIZACIÓN DE LA INVESTIGACIÓN**

## **1.1. Problema de investigación**

### ***1.1.1. Planteamiento del problema***

Existen una amplia variedad de plátanos, cada uno con sus propias características distintivas [5]. Estas frutas tropicales vienen en diferentes formas, colores y sabores. Algunas variedades de plátanos se distinguen por sus características físicas, presentando una estructura redondeada o formando ángulos; o puede existir diferenciación por su color, que es un indicador de madurez de la fruta; también el tamaño es una característica distintiva de cada variedad [6]. Las distintas especies de plátano tiene sus propios rasgos y es apreciada en diferentes culturas y gastronomías alrededor del mundo[7].

La calidad del plátano está determinada por diferentes indicadores que brindan información representativa de distintos atributos. Si bien cada variedad de plátano tiene sus estándares de calidad para cada característica, un aspecto en común que es objeto de evaluación para cualquier tipo de plátano es el tamaño de la fruta [8]. El diámetro de los plátanos también puede variar, siendo más grueso en las variedades más grandes.

El plátano es vulnerable a diversas enfermedades y plagas que pueden afectar tanto su calidad como su producción [9]. Una de las enfermedades más comunes es la Sigatoka Negra [10] causada por el hongo *Mycosphaerella fijiensis*, que afecta las hojas de la planta y reduce su capacidad para realizar la fotosíntesis. Estas plagas pueden tener un impacto significativo en el producto final. Al igual que la Sigatoka, hay otras enfermedades que influyen considerablemente en la calidad del producto, afectando en características determinantes como el tamaño de la fruta.

La evaluación de la calidad normalmente es realizada por personas que revisan el producto y determinan si se cumplen con los estándares de calidad. El problema de esta práctica es que una evaluación realizada por agricultores con poca experiencia implica el riesgo de sesgo en los resultados de dicha evaluación. Por este motivo, la utilización de una herramienta tecnología traería ventajas para aquellas personas sin experiencia, y debería reducir el margen de error al evaluar el producto de forma más rápida y exacta.

Para lograr esto se obtuvo un conjunto de imágenes de plagas en plátanos que sirva como base para comparar y determinar si el plátano ha sido atacado por alguna plaga que comprometa los estándares de calidad y de tamaño del producto final. Fue posible encontrar

diversas fuentes de donde se pueden obtener imágenes de plagas para poder realizar el estudio. Sin embargo, fue necesario realizar una revisión de las imágenes por parte de un experto en el área para confirmar que dichas fotografías sean apropiadas.

Para realizar la detección de las plagas en plátanos es necesario realizar una comparación con las imágenes recopiladas. Este análisis puede ser realizado por un software, para lo cual se requirió el uso de un componente que reconozca la imagen capturada y la compare con el conjunto de fotografías. Para conseguirlo, se debe entrenar un modelo de reconocimiento de imágenes; es decir, un componente que estudia las características de cada elemento del conjunto de datos, para luego determinar a qué clase corresponde una imagen capturada.

Gracias a los constantes avances tecnológicos, se propone el desarrollo de una aplicación móvil que haga uso del aprendizaje automático y reconocimiento de imágenes para detectar plagas presentes en plátanos, y además determinar si el tamaño de la fruta podría verse afectado por dicha plaga. Esta propuesta tiene como alcance brindarles a los agricultores una aplicación mediante la cual capturen imágenes con un dispositivo móvil, como un smartphone, para posteriormente evaluar la fruta o la planta.

Esta herramienta implica un gran apoyo para los agricultores y especialistas en el cultivo de plátanos, ya que será posible identificar los plagas o enfermedades del plátano de forma veloz. Además, la aplicación brindaría información adicional sobre la afección en el plátano con la finalidad de ayudar al usuario a manejar la posible enfermedad presenta, o evitar futuras enfermedades. Esto implicaría una ayuda a los agricultores para tomar medidas preventivas y/o correctivas sobre sus cultivos.

### **Diagnóstico**

La carencia de experiencia entre los agricultores respecto a la identificación de plagas que afectan los cultivos de plátanos, junto con la carencia de herramientas de software dedicadas, constituye una barrera significativa. Esta limitación impide la detección temprana y precisa de enfermedades que afectan a los plátanos, generando consecuencias negativas para la productividad y la salud de los cultivos.

## **Pronóstico**

La incorrecta e inoportuna detección de plagas en las plantaciones de plátanos es un problema que de no ser abordado adecuadamente podría resultar en pérdidas económicas significativas, reducción de la calidad de los productos y amenazas a la seguridad alimentaria local.

### ***1.1.2. Formulación del problema***

¿Cómo debe construirse una aplicación móvil para detectar plagas en variedades de especies de Musa ABB utilizando inteligencia artificial?

### ***1.1.3. Sistematización del problema***

¿Cómo debe estar estructurado un conjunto de imágenes para clasificar plagas y variedades de especies de plátanos?

¿Qué plagas y qué variedades de especies de plátano deben incluirse dentro del conjunto de imágenes?

¿De qué manera debe entrenarse un modelo de aprendizaje automático para que detecte plagas en variedades de especies de plátanos?

¿Cómo debe diseñarse una aplicación móvil para que los agricultores puedan detectar plagas en sus cultivos de especies de plátanos?

## **1.2. Objetivos**

### ***1.2.1. Objetivo general***

Desarrollar un prototipo de aplicación móvil para detectar plagas en plátanos utilizando un modelo de clasificación de imágenes

### **1.2.2. OBJETIVOS ESPECIFICOS**

- Identificar plagas del plátano que afecten al tamaño de la fruta para incorporarlas en un modelo de reconocimiento de imágenes en una aplicación móvil.
- Generar un modelo de reconocimiento de imágenes utilizando de herramientas de aprendizaje automático para clasificar los tipos de plagas del plátano.

- Desarrollar una aplicación móvil para detectar plagas en plátanos implementando un modelo de clasificación de imágenes.
- Evaluar la usabilidad del prototipo de aplicación móvil con la ayuda de expertos en plátanos para determinar el nivel de satisfacción de los usuarios y eficiencia del software.

### **1.3. Justificación**

Detectar enfermedades en etapas tempranas de cultivo y de forma precisa es fundamental para asegurar la calidad, salud y productividad de las plantas. Esto es igual de válido para el plátano, una fruta que tiene una gran demanda a nivel mundial. Las enfermedades en musáceas pueden tener efectos negativos en su tamaño y calidad, lo cual tiene implicaciones económicas para los agricultores y empresas de la industria platanera.

El enfoque de la detección de plagas utilizando una aplicación móvil de reconocimiento de imágenes es relevante en el contexto actual. La implementación de las tecnologías avanzadas, como la inteligencia artificial y análisis de imágenes es un recurso factible que puede ser de utilidad para identificar de forma temprana las plagas en musáceas, pudiendo tener resultados más precisos que la observación humana.

Contar con un conjunto de imágenes que recopile diferentes plagas y características de diferentes variedades de plátanos permite entrenar un modelo de aprendizaje automático con alta precisión. Además, este conjunto de datos puede ser de utilidad para otras investigaciones y proyectos relacionados, por lo que resulta un aporte a la comunidad de investigadores.

Entrenar un modelo es una solución rápida y simple para detectar plagas en plátanos, de forma que se mitiga el riesgo de sesgo que representa la supervisión humana. Gracias a las capacidades computacionales actuales, el modelo puede procesar grandes cantidades de datos rápidamente, lo que resulta en diagnósticos más rápidos y precisos. Además, el modelo puede ser mejorado progresivamente con el aumento de imágenes para entrenarlo, lo que incrementaría la precisión, realizando evaluaciones más confiables.

Los beneficios que representan el conjunto de datos y el modelo entrenado no pueden ser aprovechados adecuadamente por los agricultores sin una herramienta fácil de usar y

accesible. Es por este motivo que, dado en auge tecnológico moderno, la construcción de una aplicación móvil es ideal como una herramienta sencilla de obtener y fácil de manejar, lo cual supone una ventaja importante en la agricultura.

Este aporte tecnológico para la agricultura apoya a los Objetivos de Desarrollo Sostenible en Ecuador. El objetivo de producción y consumo responsables tiene como metas reducir las pérdidas de alimentos en las cadenas de producción y suministro [11]. La implementación de un sistema que detecte plagas en etapas previas a la cosecha puede permitir tomar acciones anticipadas para preservar la calidad del producto.

Además, dentro del Plan de Creación de Oportunidades de Ecuador [12], el desarrollo de esta aplicación es un aporte al tercer objetivo, el cual busca fomentar la productividad de diferentes sectores, entre ellos el agrícola. La elaboración del conjunto de datos para el sistema constituye un aporte a la comunidad de investigación, lo cual se encamina al objetivo de potenciar las capacidades de la ciudadanía y promover una educación innovadora.

**CAPÍTULO II**  
**MARCO CONCEPTUAL**

## 2.1. Marco conceptual

### 2.1.1. Plátanos

El plátano es una fruta tropical que crece en racimos de un árbol que, en la mayoría de las variedades, crece entre 3 y 10 metros [13]. Esta fruta es un alimento básico en diferentes regiones tropicales del mundo. El plátano es una fuente significativa de carbohidratos y millones de personas en África, el Caribe, América Latina, Asia y el Pacífico dependen de esta fruta en su dieta diaria [14]. Cada región tiene sus preferencias respecto a las variedades de plátanos que allí se importan.

Existen más de 1000 variedades de plátanos y bananas que se comercializan en el mundo, pero la variedad más común en el mercado es el tipo Cavendish, llegando a conformar alrededor del 47% de la producción mundial [6]. En promedio, alrededor del 90% de las exportaciones de este producto proviene de países de América Central, Sudamérica, y Filipinas. Los principales países importadores de plátano y bananas son Estados Unidos, la Unión Europea, China, Rusia y Japón. La exportación de bananas ayuda a financiar la importación de otros alimentos en países que tienen a la producción de bananas como una de sus principales actividades [7].

Figura 1

*Plátanos*



Fuente: Britannica [13]


### ***2.1.1.1. Plagas en plátanos.***

El plátano es susceptible a diferentes plagas y enfermedades, que tienen varios orígenes, pero esto implica limitaciones muy importantes en su producción [15]. Algunas de estas enfermedades son el marchitamiento por *Fusarium*, o llamado también como la “Enfermedad de Panamá”, o la Sigatoka Negra, que es un problema bastante común a nivel mundial.

Una enfermedad común es la podredumbre del rizoma, que es causada por una bacteria denominada *Erwinia Chrysanthemi*. Su efecto consiste en la reducción del rendimiento de la planta y su progresivo deterioro. Esta enfermedad se transmite por medio de infecciones que se alojan en semillas, en el suelo o en herramientas de trabajo [16].

Otra enfermedad de origen bacteriano es el Moko, también conocido como marchitez bacteriana, se produce debido a una bacteria llamada *Ralstonia Solanacearum*. Esta afección deteriora la planta progresivamente llevando a la planta a marchitarse. La bacteria es altamente letal, y puede presentarse en diferentes condiciones del ecosistema donde crece el plátano [17].

Figura 2  
*Enfermedad del Moko*



Fuente: Kapadnis S. [18]

Una de las enfermedades más comunes de las que padecen los sembríos de plátano a nivel mundial es la Sigatoka Negra, la cual es transmitida por medio de esporas a través del aire, y son las hojas las que son contagiadas [19]. El hongo causante de esta enfermedad es el

Ascomycet, y sus efectos son lesiones en la planta en forma de cortes y muerte celular cuando las toxinas fúngicas son expuestas a la luz.

El picudo negro, o también conocido con el nombre técnico *Cosmopolites sordidus*; es una de las principales plagas en las plantaciones de plátano [20]. Esta plaga afecta al tallo de la planta, causando daños en la estructura que está compuesta de las hojas. Se puede identificar este problema gracias a su apariencia negra y amarillenta, con notorio desgaste o marchitamiento.

El mal de Panamá, conocido como fusariosis o marchitez por *Fusarium*, representa una de las principales amenazas a las que se exponen las diferentes especies de las musáceas (bananos y plátanos). Este es un patógeno que ataca al sistema vascular, bloqueándolo de forma que se impide el transporte de agua y nutrientes en toda la planta [21].

Figura 3

*Mal de Panamá*



Fuente: Kapadnis S. [18]

### **2.1.2. La tecnología en la agricultura**

En los últimos años la tecnología, como la visión por computadora, y los sistemas se han convertido en herramientas importantes para la agricultura. En la actualidad estos sistemas están tomando más protagonismo en los procesos agrícolas, y con esto lograr una mayor productividad y eficiencia [22], [23]. Algunos de estos sistemas aprovechan los beneficios

del internet de las cosas (IoT) [24], mientras que otros buscan soluciones más accesibles para los agricultores, como aplicaciones móviles.

#### ***2.1.2.1. Aplicaciones móviles en la agricultura.***

Las aplicaciones móviles son herramientas extremadamente útiles de fácil acceso en la actualidad [25]. En el ámbito agrícola, las aplicaciones móviles son herramientas adecuadas debido a que son accesibles desde cualquier dispositivo móvil, en lugar de gastar dinero en equipos costosos. Recientemente existen un gran número de aplicaciones móviles enfocadas en la agricultura que buscan solucionar distintos problemas [26].

#### ***2.1.2.2. Inteligencia artificial.***

La inteligencia artificial es un campo de la ciencia que buscan simular procesos de la inteligencia humana. Ha demostrado su potencial para revolucionar industrias, servicios y aspectos sociales, ya que se están logrando resultados con alta efectividad [27]. Dentro de la inteligencia artificial existen un gran número de herramientas, algoritmos, técnicas, y demás recursos que permiten llevar a cabo su cometido. Pero el objetivo principal de la inteligencia artificial es realizar procesos que requieren de la inteligencia humana, de tal forma que obtenga los mismos resultados en un menor tiempo y con una menor probabilidad de fallos.

La inteligencia artificial ha tenido un crecimiento importante en los últimos años y ha tenido un gran impacto en diferentes campos, como la educación, la medicina, las industrias, el comercio, y varios más [28]. A pesar de estas ventajas que supone la inteligencia artificial, existen también debates respecto a aspectos éticos y morales, impactos sociales que podría tener los fines o los medios por los cuales se hace uso de la inteligencia artificial.

#### ***2.1.2.3. Aprendizaje automático.***

El aprendizaje automático, dentro del contexto de la informática, se refiere a la capacidad de sistemas para seguir patrones y aprender de ellos, y todo esto a partir de datos que son la base para el entrenamiento [29]. Los sistemas de aprendizaje automático no siempre cuentan con reglas fijas, sino que siguen patrones relacionando los datos a medida que se recibe nueva información, y así lograr mejorar su rendimiento en tareas específicas.

El aprendizaje automático requiere de datos para poder ser entrenado desde un principio, pero estos datos no siempre están clasificados. Por esto se pueden identificar dos categorías: aprendizaje supervisado y aprendizaje no supervisado [30]. El aprendizaje supervisado se caracteriza por tener datos etiquetados, de tal forma que las entradas de datos y las salidas de respuestas están vinculadas. El objetivo de este tipo de aprendizaje es aprender cuáles son las salidas correctas a partir de entradas concretas. Por otro lado, el aprendizaje no supervisado tiene un fin distinto ya que no se cuenta con etiquetas para los datos, ni relaciones preestablecidas entre las entradas y las salidas. Durante el entrenamiento se intenta buscar agrupaciones, conocido como clustering, o estructuras significativas.

Dentro del aprendizaje automático existe el concepto del aprendizaje profundo (Deep Learning) y consiste en un conjunto de clasificadores, como redes neuronales, que trabajan juntos y se basan en regresiones lineales que intentan crear una función de ajuste y que trabajan con funciones de activación [31].

#### ***2.1.2.4. Clasificación de imágenes.***

En el contexto de la computación y el aprendizaje automático, la clasificación de imágenes consiste en realizar una recopilación de imágenes, para posteriormente segmentar el conjunto en diferentes categorías, para posteriormente entrenar un modelo para detectar a cuál de las categorías pertenece una imagen específica [32]. Para conseguir esto, comúnmente se llevan a cabo diferentes procesos, iniciando por proveer un conjunto de datos que debe ser segmentado en clases. Luego se suele realizar un preprocesado de los datos donde se realiza algún proceso de edición de las imágenes a fin de que se tenga homogeneidad y se conserve solo la información relevante. Finalmente se lleva a cabo el entrenamiento con el conjunto de datos, que debe ser evaluado para medir su efectividad.

#### ***2.1.2.5. Visión por computadora.***

La visión por computadora es un proceso por medio del cual las computadoras extraen la información más relevante o útil del mundo por medio de imágenes [33]. Este campo tiene muchas aplicaciones como la robótica, procesamiento de documentos, navegación, entre otras. En los años recientes la visión por computadora ha ganado terreno en investigaciones a nivel mundial, y en el ámbito agrícola se han implementado proyectos haciendo uso de estas tecnologías [34].

Figura 4

*Procesamiento de imágenes con visión por computadora*



Fuente: MathWorks [35]


### 2.1.2.6. Redes Neuronales Convolucionales (CNN).

Las redes neuronales han ganado popularidad en proyectos donde se requiere realizar una clasificación de imágenes, esto es debido a sus habilidades de capturar representaciones espaciales [36]. Las redes neuronales convolucionales tienen la particularidad que no trabajan únicamente con nodos de entrada y salida, sino que también tienen nodos “ocultos” que forman capas jerárquicas [37].

Otro elemento indispensable en las redes neuronales convolucionales son las funciones de activación. Estas funciones son utilizadas para generar relaciones no lineales entre las entradas y salidas [38]. Esto quiere decir que las funciones de activación se activan en la salida de cada neurona, y determinan si la siguiente se activa o no.

Figura 5

*Redes Neuronales Convolucionales*



Fuente: MathWorks [35]

## ***2.2. Marco Referencial***

Actualmente existen diferentes trabajos donde se aplican mecanismos similares a los que se proponen en este proyecto, pero cada uno con sus enfoques distintivos. En el trabajo de Saranya et al. [39] se busca identificar el nivel de madurez de bananas por medio de imágenes. En su artículo describen el proceso de generación del sistema, que inicia con un conjunto de datos que cuenta con 4 estados de madurez. Posteriormente, se dividen los datos en un subconjunto de entrenamiento y otro de pruebas, y después se utilizan un conjunto de redes neuronales convolucionales (CNN) para entrenar un modelo.

En un artículo de Quian Xiang et al. [40] se entrenó un modelo que buscaba clasificar imágenes de diferentes frutas. Para esto se utilizó un conjunto de datos de diferentes frutas, y se entrenó un modelo a partir de dichos datos. El modelo aprendía de la información proporcionada gracias a la utilización de redes neuronales. Se utilizó TensorFlow y un modelo pre entrenado MobileNetV2. Primero se debía generar el modelo base para posteriormente utilizar TensorFlow y generar un nuevo entrenamiento.

El preprocesado de las imágenes también puede ser una etapa importante para la clasificación de imágenes como lo hacen Li-Hua Li et al. [41]. En su metodología primero realizan la extracción de las imágenes, para posteriormente preprocesarlas antes de entrenar el modelo. Ese preprocesado remueve el fondo de la imagen y normaliza el tamaño en el mismo para todos. Luego se mejora el color en los espacios RGB de la imagen. Al igual que los demás proyectos, las redes neuronales fueron empeladas para el aprendizaje automatizado.


**CAPÍTULO III**  
**METODOLOGÍA DE LA INVESTIGACIÓN**

### 3.1. Localización

El proyecto fue desarrollado en los laboratorios de cómputo de la Universidad Técnica Estatal de Quevedo (UTEQ), Campus Central ubicado en la ciudad de Quevedo, provincia de los Ríos, Ecuador, en la Av. Quito km. 11/2 vía a Santo Domingo de los Tsáchilas. En la Figura 6 se observa la localización del campus.

Figura 6

*Localización de la UTEQ*



Fuente: Google Maps

### 3.2. Tipo de investigación

Este estudio adopta un enfoque exploratorio, dado que, aunque la clasificación de imágenes utilizando técnicas de aprendizaje profundo es un área ampliamente estudiada, la aplicación específica en la detección de plagas de plátanos es relativamente inexplorada. Al explorar diversas metodologías, el estudio busca descubrir patrones, posibles limitaciones y oportunidades de mejora que no están evidentemente definidos en la literatura existente.

### 3.3. Métodos de investigación

En este apartado se describen los métodos aplicados para llevar a cabo esta investigación, resaltando las implicaciones y objetivos del uso de cada método.

### **3.3.1. Método analítico**

El método analítico en este estudio se emplea para descomponer sistemáticamente el problema de la detección de plagas en plátanos utilizando técnicas de clasificación de imágenes. El objetivo es identificar factores que influyen en el rendimiento del modelo y analizar cómo diferentes configuraciones y técnicas afectan los resultados. Este enfoque permite obtener una comprensión más profunda de las mejores prácticas y potenciales áreas para mejoras en la detección automatizada de plagas.

### **3.3.2. Método inductivo**

En este estudio, el método inductivo se aplica en la fase de las pruebas de usabilidad de la aplicación móvil. Este software está diseñado para que los agricultores tengan una interfaz para realizar la detección de plagas en plátanos. A través de este enfoque, se observarán y registrarán las interacciones de los usuarios reales con la aplicación, recogiendo datos sobre su comportamiento, preferencias y posibles dificultades al usar la herramienta.

### **3.4. Fuentes de recopilación de información**

Se recorrieron a diversas fuentes académicas y bases de datos reconocidas. Se empleó Google Scholar como herramienta principal para obtener un amplio alcance de la literatura existente. Además, se accedió a bases de datos especializadas como IEEE Xplore, ACM y Science Direct, con el objetivo de hallar trabajos relacionados, publicaciones académicas, artículos de investigación, revisiones y conferencias, enfocadas en el estudio de la clasificación de imágenes y la detección de plagas en agricultura. Paralelamente, se consultaron fuentes locales como el Instituto Nacional Autónomo de Investigaciones Agropecuarias (INIAP) de Ecuador y el Instituto Nacional de Estadísticas y Censos (INEC), para brindar un contexto sobre la agricultura y las plagas en plátanos en la región.

### **3.5. Diseño de la investigación**

Esta sección detalla cómo se organizó la investigación para explorar las técnicas de clasificación de imágenes en plagas de plátanos, describiendo los métodos empleados y las fases del proyecto, desde la recopilación inicial de datos hasta la implementación final en una aplicación móvil.

### **3.5.1. Identificación de plagas del plátano y sus variedades**

Para identificar las plagas que afectan a diferentes especies de plátano se recurrió a una revisión bibliográfica no sistemática, aplicando criterios de aceptación y definiendo términos y parámetros para la búsqueda. Posteriormente se entrevistó a un experto en plátanos con la finalidad de, por un lado, validar y complementar la información obtenida a partir de la revisión bibliográfica.

#### **3.5.1.1. Revisión bibliográfica**

Se realizó una revisión bibliográfica no sistemática para obtener información sobre las variedades y plagas que afectan a las especies de plátanos. La investigación se llevó a cabo en diferentes fuentes como motores de búsqueda académicos, tales como Google Scholar; o en algunas bases de datos indexadas.

La revisión bibliográfica tiene como finalidad identificar las principales plagas que afectan al crecimiento del plátano, pero también conocer sus características y métodos de tratamiento. Otro aspecto relevante es determinar las diferencias en la forma en la que estas plagas afectan a las variedades de plátanos. Además, se desea hallar trabajos similares para identificar métodos de detección de plagas mediante imágenes.

Para realizar la revisión de la literatura se consideró algunos términos relevantes para la búsqueda. Estos términos fueron empleados para realizar dos cadenas de búsqueda, una en español y otra en inglés, con el fin de obtener la mayor cantidad de resultados posibles.

- Plátanos
- Bananas
- Musa
- Clasificación
- Especies
- Variedades
- Enfermedades
- Plagas
- Pestes
- Infecciones
- Visión por computadora
- Clasificación de imágenes
- Aprendizaje profundo

En la tabla 1 se muestra las cadenas de búsqueda creadas a partir de los términos que se han mencionado previamente.

Tabla 1

*Cadenas de búsqueda para la revisión literaria*

<b>Idioma</b>	<b>Cadena de búsqueda</b>
Español	(plátanos OR bananas OR musa) AND (clasificación OR especies OR variedades) AND (enfermedades OR plagas OR pestes OR infecciones) AND (visión por computadora OR clasificación de imágenes OR aprendizaje profundo)
Inglés	(plantain OR bananas OR musa) AND (classification OR species OR variety) AND (disease OR plagues OR pests OR infections) AND (computer vision OR image classification OR deep learning)

Elaborado: Autor

Para la selección de la literatura relevante y estudios relacionados se tuvo en cuenta los criterios de aceptación que se muestran en la tabla 2.

Tabla 2

*Criterios de Aceptación*

<b>Criterios de aceptación</b>
<p>La información brindada debió ser relevante dentro del contexto de la identificación de plagas que afectan al tamaño del plátano, abordando aspectos claves como características visuales y métodos de prevención y control.</p> <p>Se priorizaron publicaciones que provengan de revistas científicas, libros, tesis o conferencias académicas de prestigio y, adicionalmente, publicaciones oficiales de entidades gubernamentales importantes.</p> <p>Las fuentes seleccionadas debieron proceder de instituciones académicas, centros de investigación o entidades gubernamentales con autoridad en el área de estudio. Los estudios deben ser consistentes en los resultados y la metodología aplicada.</p>

---

Se priorizaron los estudios más recientes, de preferencia que hayan sido publicados dentro de los últimos 5 años. Sin embargo, se podrán considerar trabajos anteriores que aporten conceptos clave o históricos para la investigación.

Se incluyeron fuentes que ofrecen una perspectiva amplia sobre el problema de la investigación, abarcando variedad de enfermedades, especies, regiones geográficas y tecnologías utilizadas.

---

Elaborado: Autor

### ***3.5.1.2. Obtención de un conjunto de imágenes***

Una vez identificadas las plagas comunes que afectan a los plátanos, fue necesario recopilar un conjunto de fotografías de estas enfermedades para entrenar el modelo de clasificación de imágenes. Se optó por extraer estos recursos desde repositorios web debido a que la captura de imágenes en plantaciones se vio limitada por la lejanía entre los sembríos y la crisis de seguridad al momento de realizar la investigación. Además, al tratarse de varias plagas es poco probable que se encuentren plantaciones infectadas con cada una de ellas.

El conjunto de imágenes requerido debió cumplir con algunos requisitos para poder llevar a cabo un entrenamiento apropiado. Uno de los requerimientos fue contener al menos 40 imágenes como mínimo por cada enfermedad, cuantos más elementos se obtengan, mayor será la información que tendrá el modelo de la que aprender. Las fotografías deben agruparse en carpetas con el nombre de cada plaga para poder ser analizadas durante el entrenamiento del modelo. Las imágenes deben enfocar zonas de la hoja del plátano ya que es en esta sección de la planta donde se manifiestan mayormente las enfermedades.

### ***3.5.1.3. Entrevistas a expertos***

Para llevar a cabo la entrevista a expertos en el sector platanero se realizó un cuestionario, con un enfoque direccionado a validar la selección de plagas y recibir recomendaciones sobre en el enfoque de la aplicación. Durante las entrevistas se socializó el objetivo de la investigación para brindar contexto a los expertos y así obtener opiniones enfocadas en cumplir con la finalidad del proyecto.

Habiendo realizado una revisión bibliográfica se pidió a los expertos revisar la información obtenida, donde se les presentó la lista de plagas, descripción y tratamientos de cada una.

Además se mostraron las imágenes correspondientes a cada plaga que se obtuvieron desde un repositorio web, para validar si estas imágenes son correctas y así asegurar la veracidad de los resultados del entrenamiento del modelo. Finalmente, se les dio a conocer el objetivo de la aplicación móvil a desarrollar y se pidió la opinión de los expertos para que así sugieran características o mejoras durante el diseño del software. Los comentarios de los expertos fueron tomadas en cuenta para los requisitos del sistema.

### **3.5.2. Generación de un modelo de clasificación de imágenes**

El entrenamiento del modelo de clasificación se realizó mediante la utilización del lenguaje de programación Python, empleando la interfaz de Jupyter Notebook como entorno de desarrollo. Para esto se empleó el conjunto de imágenes obtenido, sobre el cual se aplicó la técnica de aprendizaje profundo CNN. Este conjunto de imágenes fue dividido en dos subconjuntos, permitiendo así evaluar el desempeño del modelo. El modelo fue exportado para su posterior utilización en la aplicación móvil.

#### ***3.5.2.1. Preparación del conjunto de entrenamiento y de prueba***

Se realizó una revisión del conjunto de imágenes para verificar la correcta estructura de las carpetas para lograr un correcto entrenamiento. Posteriormente se realizó una segmentación de las imágenes en dos subconjuntos: el primero fue utilizado para entrenar el modelo y el segundo se utilizó para validar los resultados del entrenamiento. Se optó por destinar el 80% de elementos para el subconjunto de entrenamiento y el 20% restante para el subconjunto de validación.

#### ***3.5.2.2. Diseño del modelo***

En esta fase se definieron los parámetros de entrenamiento del modelo de clasificación de imágenes, para lo cual se utilizó la biblioteca Keras de TensorFlow. Esta biblioteca permite utilizar varios algoritmos de aprendizaje para generar un modelo, y el enfoque adoptado se basa en Redes Neuronales Convolucionales (CNN). Se optó por utilizar CNN debido a que se han obtenido buenos resultados en otros trabajos relacionados donde se estudia la visión por computadora [39], [42], [43].

Se llevó a cabo un estudio experimental destinado a evaluar y comparar la eficacia de diferentes modelos pre entrenados. La implementación de modelos pre entrenados ha demostrado una eficacia superior en comparación con aquellas instancias donde no se han aplicado ninguno, de acuerdo con algunas investigaciones [43], [44], [45]. Se seleccionaron seis modelos pre entrenados para su evaluación en condiciones uniformes, para lo cual se diseñó una red neuronal básica y se utilizó un segmento del conjunto de imágenes para acelerar el proceso de evaluación. Los modelos probados fueron EfficientNetB0, ResNet50, DenseNet121, MobileNetV2, InceptionV3 y Xception.

Tras seleccionar el modelo pre entrenado con mejores resultados, se procedió a diseñar la arquitectura neuronal. Para esto se tomó como referencia estructuras de redes neuronales documentadas en investigaciones previas como punto de partida [9], [44], [46]. Seguidamente, se refinó el modelo iteradamente, para lo cual se incluyeron la optimización de la densidad neuronal mediante la modulación del número de neuronas por capa, la incorporación de capas adicionales para profundizar la estructura de la red, y la selección estratégica de funciones de activación para mejorar la capacidad de generalización del modelo. Estos ajustes se realizaron con el objetivo de alcanzar un equilibrio entre complejidad computacional y rendimiento predictivo.

### ***3.5.2.3. Entrenamiento del modelo***

Se hicieron configuraciones al conjunto de imágenes ya cargado en el entorno de desarrollo para optimizar el rendimiento del entrenamiento y mejorar los resultados. Estas configuraciones constaron en cargar las imágenes en caché para evitar los cuellos de botella y realizar reordenamiento de los elementos durante cada iteración. Después se normalizaron las imágenes para que las redes neuronales puedan procesar con mayor facilidad los datos. La normalización consistió en cambiar la escala de los valores RGB de las fotografías para que en lugar de tener un rango entre 0 a 255, estos se encuentren entre 0 y 1. Para iniciar el entrenamiento se estableció la cantidad de 100 épocas, es decir la cantidad de iteraciones en las que reentrenará el modelo. Durante el entrenamiento del modelo se midió la precisión en cada época, observando mejores resultados en cada época tanto en el conjunto de entrenamiento como en el de validación.

#### 3.5.2.4. Validación del modelo

Una vez finalizado el entrenamiento se utilizó un segmento del conjunto de imágenes de 397 elementos para evaluar la eficiencia del modelo en la predicción de plagas de plátanos. Con el modelo entrenado se realizaron predicciones para cada una de las imágenes y los resultados fueron comparados con los valores reales por medio de una matriz de confusión. En la matriz de confusión se contrastaron en un eje las predicciones y en el otro eje las etiquetas reales, permitiendo visualizar los aciertos y errores. Estos resultados se interpretan como verdaderos positivos (VP), falsos positivos (FP), verdaderos negativos (VN) y falsos negativos (FN). Con estos datos se realizó el cálculo de las métricas de precisión general del modelo, precisión en cada clase, sensibilidad, y puntaje F1.

La precisión general del modelo hace referencia a la proporción de predicciones acertadas que consigue el modelo con relación a la cantidad total de elementos a ser evaluados. Para obtener el valor de esta métrica se utiliza la fórmula que se muestra en la ecuación 1.

$$\text{Precisión general} = \frac{\text{Aciertos}}{\text{Aciertos} + \text{Fallos}}$$

Ecuación 1: Fórmula de precisión general del modelo

La precisión de cada clase se refiere al porcentaje de predicciones positivas que fueron correctas en cada clase. Esta métrica se calcula utilizando la ecuación 2.

$$\text{Precisión por clase} = \frac{VP}{VP + FP}$$

Ecuación 2: Fórmula de precisión del modelo por clase

La sensibilidad mide la capacidad del modelo para detectar correctamente los casos reales de cada clase. Para calcular la sensibilidad se aplica la ecuación 3.

$$\text{Sensibilidad} = \frac{VP}{VP + FN}$$

Ecuación 3: Fórmula de sensibilidad del modelo por clase

Finalmente, el puntaje F1 es la media armónica de la precisión y la sensibilidad. Lo que brinda esta métrica es un balance entre la precisión y la sensibilidad. Para medir el puntaje F1 se utiliza la ecuación 4.

$$\text{Punraje } F1 = 2 \times \frac{\text{Precision} \times \text{Sensibilidad}}{\text{Precision} + \text{ensibilidad}}$$

Ecuación 4: Fórmula del puntaje F1 por clase

### 3.5.3. Desarrollo de la aplicación móvil

Se desarrolló un prototipo de aplicación móvil donde se implementó el modelo entrenado previamente para realizar el reconocimiento de imágenes capturadas desde el dispositivo móvil. Se optó por utilizar la metodología de prototipado rápido [47] para el desarrollo de la aplicación.

#### 3.5.3.1. Metodología de desarrollo

La metodología de desarrollo elegida para el proyecto fue Prototipado Rápido debido a que esta ofrece algunos beneficios como retroalimentación temprana, flexibilidad, hay poco riesgo de falla en el producto final y los costos son mínimos [47]. A continuación se describen los pasos de esta metodología.

**Planificación inicial.** En esta etapa se definen los objetivos del prototipo, además de las funcionalidades fundamentales que tendrá el sistema. Se consideraron los requisitos generados a partir de la opinión de los expertos a quienes se les consultó en una entrevista previa. Se priorizó la funcionalidad principal de la aplicación para la primera iteración, y a partir de esta versión se generó nuevas actualizaciones al software.

**Desarrollo del prototipo.** Para el desarrollo del prototipo se requirió el uso de dos herramientas para crear el prototipo. Tras revisar herramientas de prototipado se eligió al software Figma para elaborar las primeras versiones del diseño debido a su utilidad en la creación de interfaces [48]. Se diseñaron interfaces como una primera versión del prototipo, para luego refinarlas y crear un prototipo funcional. Para la creación del prototipo funcional se empleó Android Studio, de tal forma que se generó una aplicación que fue instalada en un dispositivo Android para ser evaluada posteriormente.

**Evaluación.** Tras el desarrollo del prototipo, este fue sometido a una etapa de evaluación y pruebas que tienen como finalidad recoger retroalimentación. Se solicitó la colaboración de agricultores que analizaron el diseño de la aplicación y realizaron sugerencias. A estas mejoras sugeridas les complementamos los errores que se encontraron en los primeros prototipos funcionales. La información recogida en esta fase fue utilizada para generar una nueva versión del prototipo.

**Iteración.** Esta etapa consistió en revisar los datos recogidos durante las evaluaciones del prototipo para determinar las nuevas características que fueron agregadas en nuevas versiones del prototipo. Cada ciclo de iteración se enfocó en mejorar el prototipo, refinando las funcionalidades, la interfaz de usuario y la experiencia del usuario. Este proceso iterativo continuó hasta que se logró un consenso sobre que el prototipo ha alcanzado un nivel de madurez adecuado para ser utilizado por los usuarios finales.

#### **3.5.4. Evaluación de la usabilidad de la aplicación**

Se realizó una prueba de usabilidad con agricultores que encajaron con el perfil de usuario establecido para la aplicación móvil. Esta evaluación con usuarios tuvo como objetivos en primer lugar determinar el nivel de satisfacción de los usuarios y, en segundo lugar, determinar mediante métricas la eficiencia del software. Para evaluar la satisfacción del usuario con el software, se utilizó el cuestionario SUS, complementándose con la técnica de Observación directa y se registraron métricas relacionadas con la eficiencia del software durante la participación de los usuarios.

##### **3.5.4.1. Preparación de las pruebas**

Para la realización de las pruebas se realizó una planificación que inició definiendo el perfil de usuario de la aplicación. Al definir el tipo de usuario que probaría la aplicación se les realizó la solicitud para participar en las pruebas de usabilidad. La invitación fue realizada de forma verbal en persona, y se acordó el lugar y el horario en el que se llevaría a cabo la reunión.

Para evaluar la satisfacción del usuario con el software, se utilizó el cuestionario SUS. Este instrumento fue diseñado por Brooke en 1995 [49] y es una herramienta rápida y efectiva

para recoger la percepción subjetiva de los usuarios sobre la usabilidad del software. Este cuestionario consta de 10 preguntas con opciones de respuesta que van desde "Totalmente de acuerdo" hasta "Totalmente en desacuerdo", evaluando aspectos generales de usabilidad como la complejidad percibida, la necesidad de asistencia al usar el software o la voluntad de usar el producto frecuentemente.

La observación directa complementa a la técnica anterior ya que brinda un recoger datos cualitativos sobre la interacción del usuario con el software [50]. Esta técnica consiste en monitorear a los usuarios mientras realizan las actividades asignadas y se toma nota de aspectos relevantes en el contexto de la usabilidad. Algunos de estos aspectos son la comodidad y confianza demostrada por el usuario al usar la aplicación, la eficacia de las funcionalidades y los errores que cometan los participantes.

Se consideraron varias métricas para medir la eficiencia de aplicaciones móviles como lo sugiere Hussain [51] tomando en cuenta los estándares de la norma ISO 9241 [52]. Las métricas que se seleccionaron fueron aquellas relacionadas a la efectividad y eficiencia del software. En la tabla 3 se muestran las métricas a ser consideradas.

Tabla 3  
*Métricas de usabilidad conforme norma ISO 9241*

<b>Efectividad</b>	<b>Eficiencia</b>
Porcentaje de objetivos culminados	Tiempo promedio por tarea
Porcentaje de usuarios que completaron las tareas	Tareas completadas por unidad de tiempo
Promedio de tareas culminadas	Costos monetarios por ejecutar la tarea

Fuente: International Organization for Standardization – Adaptación ISO 9241

Elaborado: Autor

### **3.5.4.2. Ejecución de las pruebas**

La realización de las pruebas se llevó a cabo de forma individual con cada participante. Se realizó la reunión en un horario y ubicación acordados. Se les proporcionó a los participantes un teléfono móvil en el cual ya estaba instalada la aplicación, y además contenía imágenes en la galería para poder facilitar el avance de la prueba.

Se les solicitó a los usuarios que completaran varias tareas utilizando la aplicación, mientras eran observados para documentar cualquier dificultad o comportamiento durante la interacción con el software. Tras finalizar las tareas asignadas se les pidió a los participantes que llenaran el cuestionario de Usabilidad del Sistema (SUS).

### **3.5.4.3. Recopilación de resultados**

Una vez finalizada la prueba de usabilidad con los usuarios, se procedió a realizar la recopilación de los resultados, tanto del cuestionario SUS como de la observación directa y las métricas establecidas. Para calcular el puntaje SUS se utilizó la ecuación 5.

$P = \text{Suma de promedios de las preguntas pares (2, 4, 6, 8, 10)}$

$I = \text{Suma de promedios de las preguntas impares (1, 3, 5, 7, 9)}$

$SUS = \text{Puntaje SUS}$

$$SUS = ((I - 5) + (25 - P)) * 2,5$$

Ecuación 5: Cálculo de puntaje SUS

Se registró el tiempo que les tomó realizar las tareas a los usuarios, así como aquellas tareas que completaban y se promediaron. Adicionalmente, se revisaron todas las anotaciones que se realizaron durante las pruebas con el fin de determinar qué aspectos deberían mejorarse y proponer mejoras para una futura versión del software. Paralelamente se registró el tiempo que le tomó a los participantes completar las tareas y la cantidad de tareas que finalizaron.

### **3.6. Instrumentos de investigación**

Los instrumentos que se emplearon en el desarrollo de esta investigación fueron los siguientes:

- Reuniones con el director del proyecto
- Entrevistas con profesionales involucrados en el campo platanero
- Optimización de hiperparámetros
- Observación directa
- Encuesta SUS

### **3.7. Tratamiento de los datos**

Se empleó el entorno de desarrollo Jupyter Notebook con el lenguaje de programación Python para procesar las imágenes que fueron utilizadas para el entrenamiento. Con este software se realizaron ajustes a las fotografías, se segmentaron, y se elaboraron los gráficos para la evaluación de los resultados del entrenamiento. Por otro lado, el software Excel permitió realizar los cálculos del puntaje SUS obtenido de la prueba de usabilidad.

### **3.8. Recursos humanos y materiales**

Para la ejecución de este proyecto de investigación se emplearon recursos materiales, tanto de software como de hardware; y también recursos humanos, mismos que se detallan a continuación.

#### **3.8.1. Recursos humanos**

Este proyecto fue desarrollado de forma activa por el estudiante de la carrera de Ingeniería de Software Jaime Mora Vera, bajo la supervisión y el respaldo del Ing. Ariosto Vicuña Pino en calidad de director del proyecto, al igual que el Ing. Orlando Erazo como tutor académico, ambos docentes de la Universidad Técnica Estatal de Quevedo. También se contó con la colaboración de agricultores con experiencia en el ámbito platanero quienes aportaron con sus conocimientos y participaron en las pruebas de usabilidad.

### 3.8.2. Recursos de Hardware

Los recursos físicos utilizados en la investigación se muestran en la tabla 4.

Tabla 4

*Recursos de hardware*

<b>Cantidad</b>	<b>Equipo</b>	<b>Características</b>
1	Laptop Lenovo Flex 14	Procesador: AMD Ryzen 7 Tarjeta gráfica: Radeon Vega 12 RAM: 20GB Almacenamiento: 512 GB SSD
1	Impresora EPSON	Modelo L3110
1	Smartphone Redmi Note 12	Procesador: Snapdragon 685 RAM: 8 GB Almacenamiento: 256 GB

Elaborado: Autor

### 3.8.3. Recursos de Software

Las aplicaciones y demás recursos de software utilizados se describen en la tabla 5.

Tabla 5

*Recursos de software*

<b>Software</b>	<b>Descripción</b>
Windows 11 Home	Sistema operativo sobre el cual se trabajó
Jupyter Notebook	Entorno de desarrollo sobre el cual se entrenó el modelo de clasificación de imágenes con Python
Android Studio versión Hedgehog	Entorno de Desarrollo en el cual se desarrolló la aplicación móvil en Android con Java
Microsoft Excel	Versión de Office 365 para realizar cálculos de las métricas de usabilidad

Elaborado: Autor




**CAPÍTULO IV**  
**RESULTADOS Y DISCUSIÓN**

#### 4.1. Variedades de plátanos

Los resultados de la revisión bibliográfica y las entrevistas han brindado las siguientes variedades en reportes de diferentes países: Cavendish, plátano rojo, manzano, plátano baby y Lady finger. Sin embargo, este estudio al haber sido está realizado en el territorio del Ecuador, se han tomado en cuenta las especies más comunes de este país, y de acuerdo con información proporcionada por el INIAP [53] y el INEC [54] se ha realizado la clasificación que se muestra en la tabla 6.

Tabla 6

*Variedades comunes de plátanos en Ecuador*

<b>Variedad</b>	<b>Características</b>	<b>Imagen</b>
Dominico	Tiene entre 22 y 40 cm de largo, mientras que su anchura está entre los 2 y 4 cm. Es mayormente comercializado en mercados locales. Es un poco más pequeño que el Barraganete.	
Barraganete	Es un plátano grande y robusto, de cáscara más gruesa. Mide entre 22 y 30 centímetros. Este plátano puede medir hasta 5 cm de ancho y su producción está destinada en gran parte a la exportación.	
Hartón	Es similar al Dominico, mide alrededor de 23 centímetros. Esta variedad se consume también en mercados locales y es más resistente a diferentes enfermedades.	

Fuente: INIAP [53] - INEC [54]




Elaborado: Autor

## 4.2. Plagas en plátanos




Al igual que con las variedades de plátanos, se han identificado distintas plagas y se han recopilado características de cada una de estas. Las plagas afectan de forma indistinta a las variedades antes catalogadas. A continuación se muestra en la tabla un compacto de las plagas más comunes que atacan a la planta, donde se detallan las características de los síntomas que son apreciables a simple vista en la planta, acompañados por una imagen representativa por cada plaga. Estos resultados fueron revisados y validados por un experto en el área del plátano y se resumen en la tabla 7.

Tabla 7

*Principales plagas que afectan al tamaño del plátano*

<b>Enfermedad</b>	<b>Características</b>	<b>Imagen</b>
Daños causados por insectos	Existen una gran diversidad de insectos que afectan al plátano, deteriorando las plantas y perjudicando al crecimiento de la fruta. Habitualmente se presentan pequeñas perforaciones y desgaste en las hojas [55].	
Sigatoka Negra	Se presenta como marchitamiento (necrosis) de las hojas con una tonalidad negra. Esta enfermedad frena el crecimiento de la planta y de los frutos [56].	
Sigatoka Amarilla	Esta enfermedad se presenta como rayas marrones que posteriormente se convierten en manchas de color marrón con tonalidad rojiza, rodeado por un halo amarillo. Con el tiempo estas manchas se convierten en zonas necróticas [57].	

---

<p>Virus del mosaico de las brácteas (BBrMV)</p>	<p>Este virus afecta a las brácteas (hojas donde se desarrolla el fruto), el pseudotallo y la nervadura central (zona central de las hojas). Se presentan manchas discontinuas de color marrón rojizo oscuro [58].</p>	
<p>Mal de Panamá</p>	<p>Esta enfermedad ataca al sistema vascular de la planta. Los síntomas son apenas evidentes en las hojas cuando se tornan de un tono marrón amarillento. Esta enfermedad acaba con la planta y con sus frutos [59].</p>	
<p>Moko</p>	<p>Esta enfermedad es similar al mal de Panamá ya que ataca al sistema vascular de la planta. Los síntomas visibles se presentan en las hojas que se marchitan y secan tomando un tono marrón pálido [60].</p>	

---

Elaborado: Autor

Fuente de las imágenes: Kapadnis (Kaggle) [18]

### 4.3. Obtención del Conjunto de Imágenes

Luego de una búsqueda exhaustiva en sitios y repositorios web habiendo revisado varios conjuntos de imágenes, se identificó un conjunto que cuenta con imágenes que cumplen con las características adecuadas para el entrenamiento del modelo. Este conjunto de imágenes fue obtenido en el repositorio de Kaggle [61] y pertenece a Sujay Kapadnis [18], un analista de datos de Mumbai, India. Se observa en la figura 7 el conjunto de imágenes en el repositorio Kaggle.

Figura 7

Conjunto de imágenes en Kaggle



Fuente: Kapadnis (Kaggle) [18]

Este conjunto de imágenes cuenta con las seis enfermedades comunes que se fueron descritas anteriormente. Dentro del repositorio se encontraron dos subconjuntos, uno contiene las imágenes originales y el otro tiene elementos a los que ya se han aplicado técnicas de “aumento” de imágenes. Este segundo subconjunto de imágenes es el que se ha destinado al entrenamiento del modelo ya que las técnicas de aumento ayudan a obtener mejores resultados en la clasificación de imágenes y tiene una mayor cantidad de elementos (2856 fotografías) que el subconjunto de las imágenes originales (408 fotografías).

#### 4.4. Entrenamiento del Modelo

En el proceso de evaluación y selección del modelo pre entrenado se realizó un análisis comparativo entre varios de estos, asegurándose de que todos fueran evaluados bajo las mismas condiciones de entorno. Cada modelo fue sometido a pruebas utilizando un entorno controlado y uniforme, lo cual incluyó idénticos conjuntos de imágenes de prueba, parámetros de evaluación y recursos computacionales. Se muestra en la tabla 8 los resultados de la evaluación de cada modelo.

Tabla 8

*Comparativa de el rendimiento de los modelos pre entrenados*

<b>Modelo</b>	<b>Pérdida (entrenam.)</b>	<b>Precisión (entrenam.)</b>	<b>Pérdida (validación)</b>	<b>Precisión (validación)</b>
<b>EfficientNetB0</b>	0,0014	1,0000	0,2697	0,9259
<b>ResNet50</b>	0,0013	1,0000	0,3168	0,9383
<b>DenseNet121</b>	0,0792	0,9725	0,4281	0,8889
<b>MobileNetV2</b>	0,1216	0,9939	0,7677	0,7654
<b>InceptionV3</b>	1,3969	0,4557	1,7037	0,3827
<b>Xception</b>	0,4229	0,8379	1,8217	0,4691

Elaborado: Autor

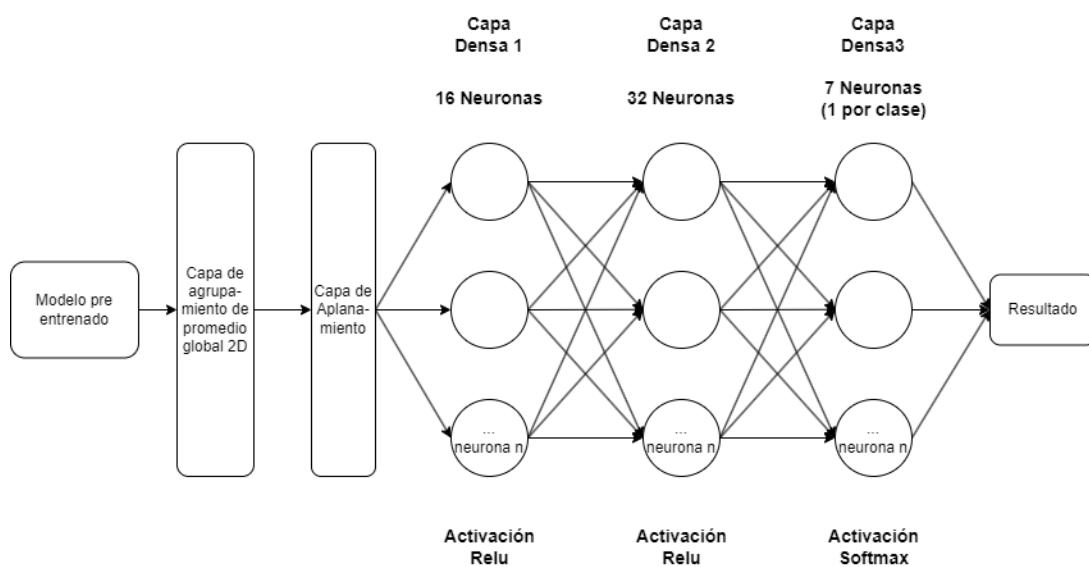
Se seleccionó el modelo EfficientNetB0 por encima del modelo ResNet50 debido a que presentaba una pérdida menor y la precisión es casi la misma. Una vez definido el modelo base para el entrenamiento, se diseñó la red neuronal. Se llevó a cabo un proceso experimental para optimizar la arquitectura de la red. Finalmente, se optó por una arquitectura secuencial que utiliza al modelo pre entrenado como capa base para procesar los datos de las imágenes.

Se adoptó una arquitectura secuencial para la red neuronal ya que brinda simplicidad y eficacia en la tarea de clasificación de imágenes. En una arquitectura secuencial, cada capa recibe información exclusivamente de la capa anterior y brinda una salida de datos que es recibida únicamente por la siguiente capa. Esto facilita un flujo lineal de datos que le ayuda al modelo identificar la jerarquía de características de forma estructurada y sistemática. Al emplear este tipo de arquitectura.

Posterior a la capa del modelo pre entrenado se utilizó una capa de agrupamiento bidimensional y una capa de aplanamiento para proporcionar una salida de datos adecuado para las capas densas posteriores. Se aplicaron tres capas densas con 16, 32 y 7 neuronas respectivamente para procesar las características de cada imagen y dar un resultado final. En la figura 8 se aprecia de forma gráfica la estructura de la red neuronal anteriormente descrita.

Figura 8

*Arquitectura de la red neuronal*



Elaborado: Autor

La figura 8 ilustra visualmente la configuración detallada de la red neuronal utilizada. Para lograr una comprensión más profunda de cada componente de la red, se realizó una tabla donde se desglosan las especificaciones y funciones de cada capa incluida en el modelo. En esta tabla, se detallan aspectos como el tipo de capa, la cantidad de neuronas o unidades, la función de activación empleada y cualquier característica relevante. A continuación se muestra la tabla 9 con la información antes descrita.

Tabla 9

*Capas de la red neuronal*

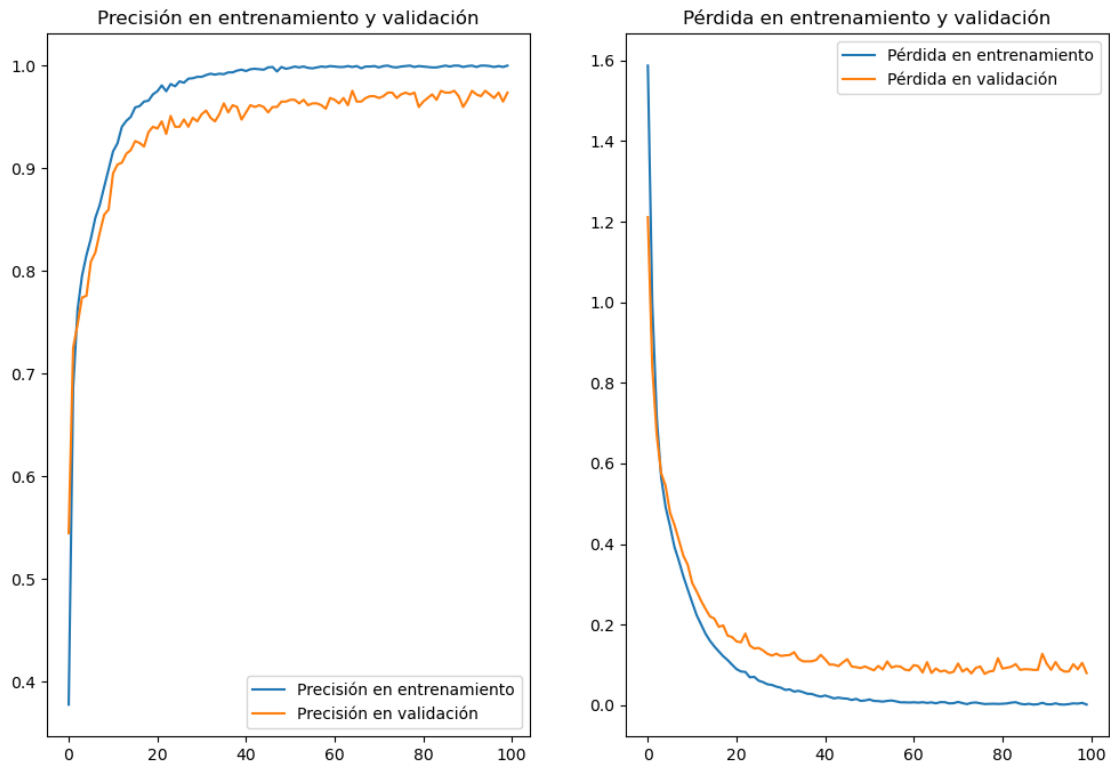
<b>Capa</b>	<b>Descripción</b>
Modelo pre entrenado	Capa que usa un modelo de red neuronal ya entrenado con otros conjuntos de datos como base para extraer características complejas y mejorar la eficiencia y tiempo del entrenamiento.
Capa de agrupamiento de promedio global 2D	Reduce las dimensiones de las características de entrada resumiendo la dimensión espacial de cada mapa en un solo valor promedio. Esto reduce el número de parámetros minimizando el sobreajuste.
Capa de aplanamiento	Esta capa transforma la matriz bidimensional anterior en un vector unidimensional para poder ser utilizado en las capas densas.
Capa Densa 1	Capa que aprende combinaciones no lineales de las características extraídas. Utiliza 16 neuronas y la función de activación Relu para evitar la linealidad.
Capa Densa 2	Es igual a la capa anterior, pero aumenta el número de neuronas a 32 para analizar más características que la capa anterior. También se usa la función de activación Relu.
Capa Densa 3	Esta capa tiene únicamente 7 neuronas, una por cada clase a predecir. Esta capa toma la decisión final al momento de clasificar y utiliza la función de activación Softmax.

Elaborado: Autor

Usando esta red neuronal convolucional se consiguió entrenar un modelo que obtuvo un 99% de precisión con el conjunto de entrenamiento y un 97% en el conjunto de validación. El entrenamiento se llevó a cabo realizando 100 iteraciones (denominadas épocas) donde en cada iteración se intentaba alcanzar una precisión mayor que la época anterior y los resultados se muestran en la figura 9 .

Figura 9: Resultados del entrenamiento del modelo

## Resultados del entrenamiento del modelo

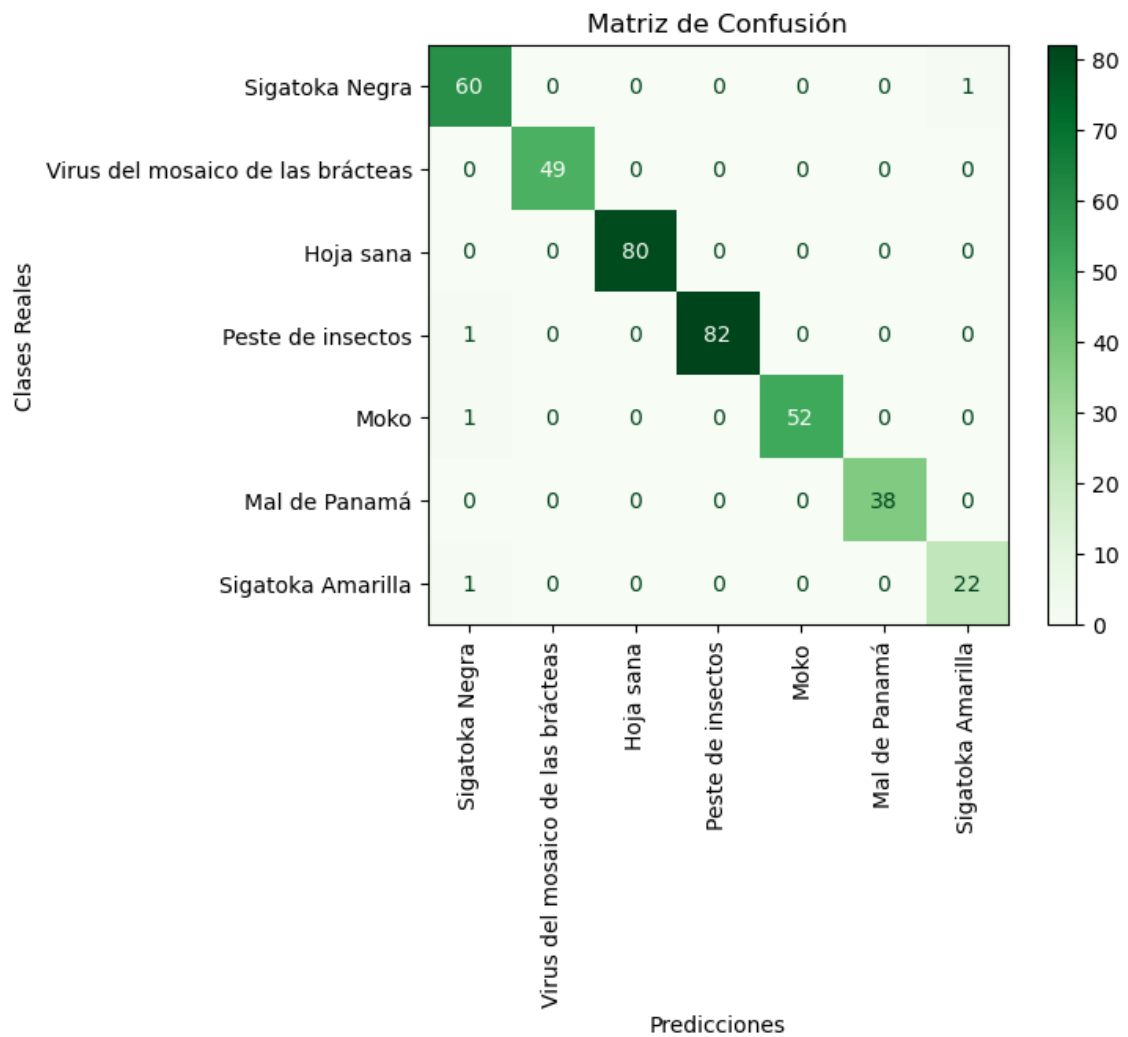


Elaborado: Autor

Finalmente, se realizó una matriz de confusión para verificar la precisión del modelo ya entrenado. Se tomaron 387 imágenes del conjunto original y se lo evaluó al modelo realizando predicciones sobre esas imágenes. Los resultados que se muestran en la figura 10 evidencian una precisión del 98,97%. Este resultado puede ser contrastado con otro análisis que se realizó sobre el mismo conjunto de imágenes del repositorio Kaggle [62], donde se utilizó otra red neuronal convolucional y obtuvo una precisión inferior a la del presente estudio, con un 95,20% de predicciones acertadas.

Figura 10

Matiz de confusión



Elaborado: Autor

Con los datos obtenidos de la matriz de confusión se calcularon métricas las relacionadas con la calidad del modelo. Como ya se adelantó, la precisión general del modelo fue de un 98,97% y, además, por cada clase se midió la precisión individual, la sensibilidad y el puntaje F1. Estos resultados se evidencian en la tabla 10 que se muestra a continuación.

Tabla 10

Métricas de eficiencia del modelo

<b>Clase</b>	<b>Precisión</b>	<b>Sensibilidad</b>	<b>Puntaje F1</b>
Sigatoka negra	0,9524	0,9836	0,9677
Virus del mosaico de las brácteas	1,0000	1,0000	1,0000
Hoja sana	1,0000	1,0000	1,0000
Peste de insectos	1,0000	0,9880	0,9939
Moko	1,0000	0,9811	0,9905
Mal de Panamá	1,0000	0,9744	0,9870
Sigatoka Amarilla	0,9565	0,9565	0,9565

Elaborado: Autor


#### **4.5.Desarrollo del prototipo de Aplicación Móvil**

Para el desarrollo del prototipo se recogieron los requisitos fundamentales para el prototipo a partir de las opiniones de los expertos en el ámbito platanero. Estos requisitos fueron analizados para posteriormente diseñar los casos de uso de la aplicación.

Dentro de las funcionalidades de la aplicación resalta la actividad de clasificar imágenes, la cual consiste en cargar una imagen, ya sea capturándola con la cámara o eligiéndola desde la galería, para que el modelo entrenado la analice y muestre el resultado de la clasificación de dicha imagen. Además de esta funcionalidad, se cuenta con secciones informativas de la aplicación que brindan contenido sobre las variedades de plátano, información sobre las enfermedades y cómo tratarlas, y también una interfaz con consejos sobre cuidados en la plantación. Dentro de los casos de uso también se consideró la funcionalidad de revisar el historial de las predicciones realizadas. En la figura 11 se muestra el diagrama de casos de uso donde se representan las funcionalidades principales del prototipo.

Figura 11

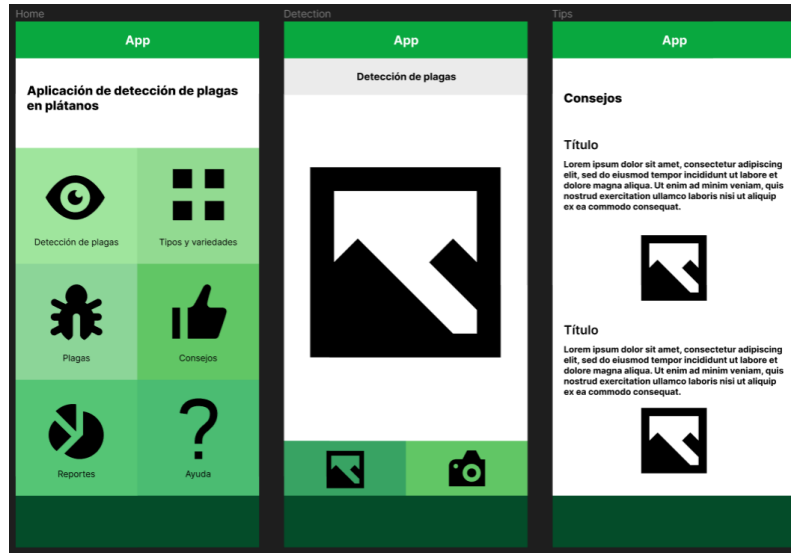
Diagrama de casos de uso



Elaborado: Autor

En el gráfico anterior se puede apreciar que el caso de uso de clasificar imágenes constituye la funcionalidad principal de la aplicación, y también brinda la posibilidad de capturar imágenes desde la cámara, así como desde la galería. Además de la clasificación de imágenes, el prototipo de aplicación móvil cuenta con contenido informativo, y a partir de estos casos de uso se diseñaron las interfaces. Durante la construcción de las interfaces se realizaron varias iteraciones de mejora, acorde con el esquema de la metodología de prototipado rápido. Las primeras versiones no funcionales fueron diseñadas en Figma, donde se plasmó un primer concepto para las interfaces del software. En la Figura 12 se aprecia estas interfaces iniciales.


Figura 12  
Primera versión de las interfaces



Elaborado: Autor

Estas interfaces fueron siendo modificadas progresivamente hasta que se implementó un prototipo funcional utilizando Android Studio. Esta versión funcional ha sido mejorada y se agregaron nuevas características en cada iteración. En la figura 13 se observan las interfaces de la última versión desarrollada de la aplicación.

Figura 13  
*Versión final del prototipo*



Elaborado: Autor

#### 4.6. Prueba de usabilidad

La evaluación de la usabilidad de nuestra aplicación se realizó mediante un enfoque multidimensional que integró cuestionarios de Usabilidad del Sistema (SUS), observación directa y análisis de métricas de eficiencia. Los resultados de esta evaluación proporcionan una visión de la experiencia del usuario y la eficacia de la aplicación.

El puntaje obtenido en el cuestionario SUS fue de 73, lo cual se interpreta como un buen nivel de usabilidad de la aplicación. Este resultado sugiere que los usuarios encontraron la aplicación fácil de usar. Según el autor de la técnica [49], un puntaje SUS por encima de 68 se considera por encima del promedio, por lo tanto, un puntaje de 73 indica que la aplicación demostró brindar una buena experiencia de usuario a los participantes.

Durante el desarrollo de las pruebas de usabilidad se aplicó la técnica de observación directa sobre las actividades que realizaron los usuarios. Se realizaron anotaciones sobre la interacción de los participantes con el software, así como los inconvenientes que experimentaron. En la tabla 10 se muestran las observaciones relevantes realizadas.

Tabla 11

*Anotaciones durante la técnica de observación directa*

---

#### **Observaciones sobre la interacción de los usuarios con la aplicación**

---

Las interfaces deberían contar con un botón para regresar a la interfaz anterior, ya que la navegación resultó ligeramente complicada para algunos usuarios.

Algunos usuarios tuvieron dificultad para leer el texto del menú principal, podría usarse un tamaño de fuente más grande.

Los elementos del gráfico circular que muestra la información de la cantidad de predicciones realizadas no eran fácilmente visibles, especialmente el texto.

El botón para cambiar idioma pasa desapercibido al estar al final de la interfaz, por lo que los usuarios ignoraron esta funcionalidad.

---

Elaborado: Autor

Las métricas de eficiencia recogidas durante la prueba brindaron datos cuantitativos sobre el rendimiento de los usuarios al interactuar con la aplicación. Estas métricas incluyen el tiempo promedio por tarea, la tasa de errores y el porcentaje de tareas completadas con éxito. En la tabla 11 se muestran los datos recogidos de la interacción de los usuarios.

Tabla 12

Métricas de eficiencia de los usuarios usando la aplicación

<b>Métrica</b>	<b>Valor</b>
Porcentaje de tareas completadas	100%
Porcentaje de usuarios que completaron las tareas	100%
Promedio de tareas culminadas	2 Tareas por usuario
Tiempo promedio por tarea	1 minuto y 20 segundos
Tareas completadas por minuto	0.75 tareas por minuto

Elaborado: Autor

**CAPÍTULO V**  
**CONCLUSIONES Y RECOMENDACIONES**

## 5.1. Conclusiones

La información que se recopiló a partir de la revisión bibliográfica evidenció que existen varias especies de plátanos en el Ecuador, pero algunas son mucho más comerciales que otras, destacándose el Dominico, Barraganete y Hartón. Hay una amplia variedad de enfermedades que afectan al plátano, pero sus efectos no difieren entre las distintas variedades. La única diferencia notable es la del hartón, el cual es resistente a ciertas enfermedades. Es por esto que se puede concluir que la detección de estas enfermedades puede ser igual de efectivo en cualquiera de las especies de plátanos clasificadas.

El conjunto de imágenes obtenido y la estructura de las redes neuronales fueron apropiadas para el entrenamiento del modelo. El hecho de aplicar técnicas de aumentación de imágenes implicó obtener resultados positivos al entrenar. Los resultados dieron una precisión del 99% en la clasificación de imágenes lo cual indica que la precisión del modelo es bastante buena y podría ser muy positivo para los agricultores que prueben esta aplicación. La herramienta Jupyter Notebook y la librería de TensorFlow facilitaron el entrenamiento y la exportación del modelo, permitiendo incluirlo en la aplicación móvil de forma sencilla.

El desarrollo de prototipado rápido permitió tener una visión sencilla de los cambios relevantes y necesarios en un prototipo. La aplicación tiene una interfaz sencilla para poder ser utilizada sin mayor complejidad por los agricultores.

Los resultados de las pruebas de usabilidad realizadas han reflejado un buen nivel de satisfacción y aceptación de los usuarios. El puntaje del cuestionario SUS indicó un buen nivel de satisfacción de los usuarios, mientras que gracias a la observación directa se han obtenido datos relevantes para mejorar la calidad de la aplicación en relación con la experiencia del usuario. Las métricas de eficiencia demuestran que la aplicación es fácil de usar, ya que todos los usuarios lograron completar sus tareas de forma exitosa, y en un tiempo relativamente corto.

## **5.2. Recomendaciones**

Es recomendable explorar la implementación de diferentes algoritmos de aprendizaje automático en el proceso de entrenamiento del modelo de detección de plagas. Aunque la investigación actual se ha enfocado en redes neuronales convolucionales, la experimentación con otras técnicas como máquinas de soporte vectorial (SVM) o Random forest, puede proporcionar otras soluciones en busca de mejorar el modelo.

También el conjunto de imágenes podría ampliarse, incorporando nuevas variedades de enfermedades y más fotografías. Esto ayudaría a los agricultores a tener una mayor variedad de plagas o enfermedades para ser detectadas con el uso de la aplicación móvil. Además, podrían incorporarse nuevas funcionalidades que le brinden más beneficios a los agricultores, como recursos multimedia que los ayuden a instruirse.

## BIBLIOGRAFÍA

- [1] Royal Britanic Gardens Kew, «Musa L.», Musaceae.
- [2] M. Araya, «Situación actual del manejo de nematodos en banano (Musa AAA) y plátano (Musa AAB) en el trópico americano», *Manejo convencional y alternativo de la Sigatoka negra, nematodos y otras plagas asociadas al cultivo de musáceas en los trópicos*, pp. 79-102, 2003.
- [3] G. E. Martínez-Solórzano y J. C. Rey-Brina, «Bananos (Musa AAA): Importancia, producción y comercio en tiempos de Covid-19», *Agronomía Mesoamericana*, pp. 1034-1046, sep. 2021, doi: 10.15517/am.v32i3.43610.
- [4] R. Sharma, «Artificial Intelligence in Agriculture: A Review», en *2021 5th International Conference on Intelligent Computing and Control Systems (ICICCS)*, IEEE, may 2021, pp. 937-942. doi: 10.1109/ICICCS51141.2021.9432187.
- [5] S. P. Raut y S. Ranade, «Diseases of Banana and their Management», en *Diseases of Fruits and Vegetables: Volume II*, Dordrecht: Kluwer Academic Publishers, pp. 37-52. doi: 10.1007/1-4020-2607-2\_2.
- [6] Food and Agriculture Organization of the United Nations, «Banana facts and figures». Accedido: 16 de julio de 2023. [En línea]. Disponible en: <https://www.fao.org/economic/est/est-commodities/oilcrops/bananas/bananafacts/en/>
- [7] Food and Agriculture Organization of the United Nations, «Bananas», Markets and Trade. Accedido: 15 de julio de 2023. [En línea]. Disponible en: <https://www.fao.org/markets-and-trade/commodities/bananas/en/>
- [8] N. B. A. Mustafa *et al.*, «Image processing of an agriculture produce: Determination of size and ripeness of a banana», en *2008 International Symposium on Information Technology*, IEEE, ago. 2008, pp. 1-7. doi: 10.1109/ITSIM.2008.4631636.
- [9] M. Nandhini, K. U. Kala, M. Thangadarshini, y S. Madhusudhana Verma, «Deep Learning model of sequential image classifier for crop disease detection in plantain tree cultivation», *Comput Electron Agric*, vol. 197, p. 106915, jun. 2022, doi: 10.1016/j.compag.2022.106915.

- [10] M. Chillet, C. Abadie, O. Hubert, Y. Chilin-Charles, y L. de Lapeyre de Bellaire, «Sigatoka disease reduces the greenlife of bananas», *Crop Protection*, vol. 28, n.º 1, pp. 41-45, ene. 2009, doi: 10.1016/j.cropro.2008.08.008.
- [11] Naciones Unidas Ecuador, «ODS 12- PRODUCCIÓN Y CONSUMO RESPONSABLES», Los Objetivos de Desarrollo Sostenible en Ecuador. Accedido: 14 de julio de 2023. [En línea]. Disponible en: <https://ecuador.un.org/es/sdgs/12>
- [12] Observatorio Regional de Planificación para el Desarrollo, «Plan de Creación de Oportunidades 2021-2025 de Ecuador». Accedido: 9 de julio de 2023. [En línea]. Disponible en: <https://observatorioplanificacion.cepal.org/es/planes/plan-de-creacion-de-oportunidades-2021-2025-de-ecuador>
- [13] Britannica, «Plantain». Accedido: 27 de junio de 2023. [En línea]. Disponible en: <https://www.britannica.com/plant/plantain>
- [14] J. Tchango Tchango, A. Bikoï, J. Escalant, J. Ngalani, R. Achard, y D. Mejia, « PLANTAIN: Post-harvest Operations», *Food and Agriculture Organization of the United Nations* , 1999.
- [15] M. A. Benavides Renteria y E. E. Jaramillo Aguilar, «Enfermedades causadas por bacterias fitopatógenas en cultivos de banano (musa aaa) y plátano (musa abb) y sus estrategias de control», Universidad Técnica de Machala, Machala, 2019.
- [16] E. S. Villamar Vera, «Diversificación agrícola, su importancia en el manejo de plagas en cultivo de banano (Musa paradisiaca AAA) para una agricultura sustentable», BABAHOYO: UTB, 2022, 2022.
- [17] K. A. Portilla Benalcázar y R. A. Mihai, «Evaluación del estado nutricional, metabólico y biológico de plantas de Musa x paradisiaca L. (plátano) sanas y afectadas por la enfermedad del Moko», Universidad de las Fuerzas Armadas, Sangolquí, 2023.
- [18] S. Kapadnis, «Banana Disease Recognition Dataset». Kaggle, diciembre de 2023. Accedido: 28 de diciembre de 2024. [En línea]. Disponible en: <https://www.kaggle.com/datasets/sujaykapadnis/banana-disease-recognition-dataset>
- [19] D. P. Bebbber, «Climate change effects on Black Sigatoka disease of banana», *Philosophical Transactions of the Royal Society B: Biological Sciences*, vol. 374, n.º 1775, p. 20180269, jun. 2019, doi: 10.1098/rstb.2018.0269.

- [20] I. Armendáriz, P. A. Landázuri, J. M. Taco, y S. M. Ulloa, «Efectos del control del picudo negro (*Cosmopolites sordidus*) en el plátano.», *Agronomía Mesoamericana*, vol. 27, n.º 2, p. 319, jun. 2016, doi: 10.15517/am.v27i2.20552.
- [21] C. Carr, M. Sánchez, F. Alfaro, R. Villalta, J. Sandoval, y M. Guzmán Quesada, «Marchitez por *Fusarium* o mal de Panamá del banano y otras musáceas». julio de 2017.
- [22] H. Tian, T. Wang, Y. Liu, X. Qiao, y Y. Li, «Computer vision technology in agricultural automation —A review», *Information Processing in Agriculture*, vol. 7, n.º 1, pp. 1-19, mar. 2020, doi: 10.1016/j.inpa.2019.09.006.
- [23] D. Li, Z. Song, C. Quan, X. Xu, y C. Liu, «Recent advances in image fusion technology in agriculture», *Comput Electron Agric*, vol. 191, p. 106491, dic. 2021, doi: 10.1016/j.compag.2021.106491.
- [24] M. S. Farooq, S. Riaz, A. Abid, T. Umer, y Y. Bin Zikria, «Role of IoT Technology in Agriculture: A Systematic Literature Review», *Electronics (Basel)*, vol. 9, n.º 2, p. 319, feb. 2020, doi: 10.3390/electronics9020319.
- [25] H. Khalid, E. Shihab, M. Nagappan, y A. E. Hassan, «What Do Mobile App Users Complain About?», *IEEE Softw*, vol. 32, n.º 3, pp. 70-77, may 2015, doi: 10.1109/MS.2014.50.
- [26] M. E. Karar, F. Alsunaydi, S. Albusaymi, y S. Alotaibi, «A new mobile application of agricultural pests recognition using deep learning in cloud computing system», *Alexandria Engineering Journal*, vol. 60, n.º 5, pp. 4423-4432, oct. 2021, doi: 10.1016/j.aej.2021.03.009.
- [27] P. P. Angelov, E. A. Soares, R. Jiang, N. I. Arnold, y P. M. Atkinson, «Explainable artificial intelligence: an analytical review», *WIREs Data Mining and Knowledge Discovery*, vol. 11, n.º 5, sep. 2021, doi: 10.1002/widm.1424.
- [28] C. Zhang y Y. Lu, «Study on artificial intelligence: The state of the art and future prospects», *J Ind Inf Integr*, vol. 23, p. 100224, sep. 2021, doi: 10.1016/j.jii.2021.100224.
- [29] C. Janiesch, P. Zschech, y K. Heinrich, «Machine learning and deep learning», *Electronic Markets*, vol. 31, n.º 3, pp. 685-695, sep. 2021, doi: 10.1007/s12525-021-00475-2.

- [30] A. Jaiswal, A. R. Babu, M. Z. Zadeh, D. Banerjee, y F. Makedon, «A Survey on Contrastive Self-Supervised Learning», *Technologies (Basel)*, vol. 9, n.º 1, p. 2, dic. 2020, doi: 10.3390/technologies9010002.
- [31] S. Dong, P. Wang, y K. Abbas, «A survey on deep learning and its applications», *Comput Sci Rev*, vol. 40, p. 100379, may 2021, doi: 10.1016/j.cosrev.2021.100379.
- [32] M. E. Paoletti, J. M. Haut, J. Plaza, y A. Plaza, «Estudio Comparativo de Técnicas de Clasificación de Imágenes Hiperespectrales», *Revista Iberoamericana de Automática e Informática industrial*, vol. 16, n.º 2, p. 129, mar. 2019, doi: 10.4995/riai.2019.11078.
- [33] D. Walters, «Computer Vision», en *Encyclopedia of Computer Science*, GBR: John Wiley and Sons Ltd., 2003, pp. 431-435.
- [34] M. V. Shewale y R. D. Daruwala, «High performance deep learning architecture for early detection and classification of plant leaf disease», *J Agric Food Res*, vol. 14, p. 100675, dic. 2023, doi: 10.1016/j.jafr.2023.100675.
- [35] MathWorks, «¿Qué es la visión artificial?», Visión Artificial. Accedido: 14 de diciembre de 2023. [En línea]. Disponible en: <https://la.mathworks.com/discovery/computer-vision.html>
- [36] D. Hong, L. Gao, J. Yao, B. Zhang, A. Plaza, y J. Chanussot, «Graph Convolutional Networks for Hyperspectral Image Classification», *IEEE Transactions on Geoscience and Remote Sensing*, vol. 59, n.º 7, pp. 5966-5978, jul. 2021, doi: 10.1109/TGRS.2020.3015157.
- [37] Á. Artola Moreno y J. A. Pérez Carrasco, «Clasificación de imágenes usando redes neuronales convolucionales en Python», Universidad de Sevilla, Sevilla, 2019. Accedido: 9 de julio de 2023. [En línea]. Disponible en: <https://idus.us.es/handle/11441/89506>
- [38] S. Dong, P. Wang, y K. Abbas, «A survey on deep learning and its applications», *Comput Sci Rev*, vol. 40, p. 100379, may 2021, doi: 10.1016/j.cosrev.2021.100379.
- [39] N. Saranya, K. Srinivasan, y S. K. P. Kumar, «Banana ripeness stage identification: a deep learning approach», *J Ambient Intell Humaniz Comput*, vol. 13, n.º 8, pp. 4033-4039, ago. 2022, doi: 10.1007/s12652-021-03267-w.

- [40] Q. Xiang, X. Wang, R. Li, G. Zhang, J. Lai, y Q. Hu, «Fruit Image Classification Based on MobileNetV2 with Transfer Learning Technique», en *Proceedings of the 3rd International Conference on Computer Science and Application Engineering*, New York, NY, USA: ACM, oct. 2019, pp. 1-7. doi: 10.1145/3331453.3361658.
- [41] L.-H. Li, Y.-S. Chu, J.-Y. Chu, y S.-H. Guo, «A Machine Learning Approach for Detection Plant Disease», en *Proceedings of the 3rd International Conference on Vision, Image and Signal Processing*, New York, NY, USA: ACM, ago. 2019, pp. 1-6. doi: 10.1145/3387168.3387238.
- [42] R. C. Ucat y J. C. Dela Cruz, «Postharvest Grading Classification of Cavendish Banana Using Deep Learning and Tensorflow», en *2019 International Symposium on Multimedia and Communication Technology (ISMAC)*, IEEE, ago. 2019, pp. 1-6. doi: 10.1109/ISMAC.2019.8836129.
- [43] M. F. Mohamedon, F. Abd Rahman, S. Y. Mohamad, y O. Omran Khalifa, «Banana Ripeness Classification Using Computer Vision-based Mobile Application», en *2021 8th International Conference on Computer and Communication Engineering (ICCCE)*, IEEE, jun. 2021, pp. 335-338. doi: 10.1109/ICCCE50029.2021.9467225.
- [44] A. H. Rangkuti, S. L. Lau, V. A. Hasbi, F. H. Indallah, Ranny, y R. Aryanto, «Comparison of CNN models for optimizing Banana Image Classification», en *2023 IEEE International Conference on Computing (ICOCO)*, IEEE, oct. 2023, pp. 456-461. doi: 10.1109/ICOCO59262.2023.10397962.
- [45] O. Yildirim, M. Talo, B. Ay, U. B. Baloglu, G. Aydin, y U. R. Acharya, «Automated detection of diabetic subject using pre-trained 2D-CNN models with frequency spectrum images extracted from heart rate signals», *Comput Biol Med*, vol. 113, p. 103387, oct. 2019, doi: 10.1016/j.compbio.2019.103387.
- [46] B. Khagi, B. Lee, J.-Y. Pyun, y G.-R. Kwon, «CNN Models Performance Analysis on MRI images of OASIS dataset for distinction between Healthy and Alzheimer's patient», en *2019 International Conference on Electronics, Information, and Communication (ICEIC)*, IEEE, ene. 2019, pp. 1-4. doi: 10.23919/ELINFOCOM.2019.8706339.
- [47] S. D. Tripp y B. Bichelmeyer, «Rapid prototyping: An alternative instructional design strategy», *Educational Technology Research and Development*, vol. 38, n.º 1, pp. 31-44, mar. 1990, doi: 10.1007/BF02298246.

- [48] G. Freitas, M. S. Pinho, M. S. Silveira, y F. Maurer, «A Systematic Review of Rapid Prototyping Tools for Augmented Reality», en *2020 22nd Symposium on Virtual and Augmented Reality (SVR)*, IEEE, nov. 2020, pp. 199-209. doi: 10.1109/SVR51698.2020.00041.
- [49] J. Brooke, «SUS: A quick and dirty usability scale», *Usability Eval. Ind.*, vol. 189, mar. 1995.
- [50] S. M. Thompson, «Remote observation strategies for usability testing», *Information Technology and Libraries*, vol. 22, pp. 22-31, mar. 2003.
- [51] A. Hussain, N. L. Hashim, N. Nordin, y H. Mohamad Tahir, «A METRIC-BASED EVALUATION MODEL FOR APPLICATIONS ON MOBILE PHONES», *Journal of Information and Communication Technology*, vol. 12, pp. 59-61, 2013, doi: 10.32890/jict.12.2013.8137.
- [52] International Organization for Standardization, «Ergonomics of human-system interaction — Part 11: Usability: Definitions and concepts», 2018. Accedido: 11 de diciembre de 2023. [En línea]. Disponible en: <https://www.iso.org/standard/63500.html>
- [53] F. Fernández, J. Pico, y B. Avellán, *Guía para la Producción y Manejo Integrado del Cultivo de Plátano*, 1.<sup>a</sup> ed. INIAP, 2021.
- [54] Instituto Nacional de Estadística y Censo, «FICHA TÉCNICA DE AGRICULTURA», 2012.
- [55] J. U. Krishnan, C. A. Jayaprakas, E. R. Harish, y L. S. Rajeswari, «Banana (*Musa* spp.) an unseen umbrella crop? Insect diversity on *Musa* spp. in the Indo-Pacific region», *Orient Insects*, vol. 54, n.º 3, pp. 433-445, jul. 2020, doi: 10.1080/00305316.2019.1667926.
- [56] D. Luna-Moreno *et al.*, «Early Detection of the Fungal Banana Black Sigatoka Pathogen *Pseudocercospora fijiensis* by an SPR Immunosensor Method», *Sensors*, vol. 19, n.º 3, p. 465, ene. 2019, doi: 10.3390/s19030465.
- [57] A. de Campos Dianese, T. G. Guimarães, A. C. Kreling, A. A. Sussel, J. V. Malaquias, y E. P. Amorim, «Reaction of Banana (*Musa* spp. L.) genotypes to yellow Sigatoka (*Pseudocercospora musae* (Zimm.) on Brazil's central plateau and an epidemiological study of the disease Progress curves comparing four non-flexible models»,

- Phytoparasitica*, vol. 48, n.º 1, pp. 107-115, feb. 2020, doi: 10.1007/s12600-019-00774-7.
- [58] R. Selvarajan, V. Balasubramanian, P. Priyanka, R. M. Jebakumar, K. P. Selvam, y S. Uma, «Evidence of seed transmission of Banana bract mosaic virus in Musa synthetic diploid H-201, a possible threat to banana breeding», *Eur J Plant Pathol*, vol. 156, n.º 4, pp. 1181-1187, abr. 2020, doi: 10.1007/s10658-019-01924-7.
- [59] R. C. Ploetz, «Panama Disease: A Classic and Destructive Disease of Banana», *Plant Health Prog*, vol. 1, n.º 1, ene. 2000, doi: 10.1094/PHP-2000-1204-01-HM.
- [60] M. Ramírez, B. W. Neuman, y C. A. Ramírez, «Bacteriophages as promising agents for the biological control of Moko disease (*Ralstonia solanacearum*) of banana», *Biological Control*, vol. 149, p. 104238, oct. 2020, doi: 10.1016/j.biocontrol.2020.104238.
- [61] «Kaggle datasets». Accedido: 14 de septiembre de 2023. [En línea]. Disponible en: <https://www.kaggle.com/datasets>
- [62] B. Blas Rimac, «Classification Banana Disease - ViT Accuracy 95.20%», Kaggle. Accedido: 27 de diciembre de 2024. [En línea]. Disponible en: <https://www.kaggle.com/code/bryambblasrimac/classification-bananadisease-vit-accuracy-95-20>

## **ANEXOS**

```

num_classes = len(class_names)

model = Sequential([
    base_model,
    layers.GlobalAveragePooling2D(),
    layers.Rescaling(1./255, input_shape=(img_height, img_width, 3)),
    layers.Flatten(),
    layers.Dense(16, activation='relu'),
    layers.Dense(32, activation='relu'),
    layers.Dense(num_classes, activation='softmax')
])

```

[12]:

```

model.compile(optimizer='adam',
              loss=tf.keras.losses.SparseCategoricalCrossentropy(from_logits=True),
              metrics=['accuracy'])
model.summary()

```

WARNING:tensorflow:From C:\Users\jaime\anaconda3\Lib\site-packages\keras\src\optimizers\\_init\_.py:309: The name tf.train.Optimizer is deprecated. Please use tf.compat.v1.train.Optimizer instead.

Model: "sequential"

Layer (type)	Output Shape	Param #
efficientnetb0 (Functional)	(None, 7, 7, 1280)	4049571
global_average_pooling2d (GlobalAveragePooling2D)	(None, 1280)	0
rescaling_3 (Rescaling)	(None, 1280)	0
flatten (Flatten)	(None, 1280)	0
dense (Dense)	(None, 16)	20496
dense_1 (Dense)	(None, 32)	544
dense_2 (Dense)	(None, 7)	231

```

Total params: 4070842 (15.53 MB)
Trainable params: 21271 (83.09 KB)
Non-trainable params: 4049571 (15.45 MB)

```

## Anexo 1: Código de la estructura de la red neuronal

```


import time
start_time = time.time()

epochs=100
history = model.fit(
    train_ds,
    validation_data=val_ds,
    epochs=epochs
)


end_time = time.time()
total_time = end_time - start_time
print("Tiempo total de entrenamiento:", total_time, "segundos")
-----
457/457 [=====] - 99s 216ms/step - loss: 0.0020 - accuracy: 1.0000 - val_loss: 0.0879 - val_accuracy: 0.9755
Epoch 93/100
457/457 [=====] - 98s 214ms/step - loss: 0.0044 - accuracy: 0.9987 - val_loss: 0.1070 - val_accuracy: 0.9720
Epoch 94/100
457/457 [=====] - 98s 214ms/step - loss: 0.0019 - accuracy: 1.0000 - val_loss: 0.0896 - val_accuracy: 0.9702
Epoch 95/100
457/457 [=====] - 98s 214ms/step - loss: 0.0014 - accuracy: 1.0000 - val_loss: 0.0834 - val_accuracy: 0.9755
Epoch 96/100
457/457 [=====] - 98s 215ms/step - loss: 0.0027 - accuracy: 0.9996 - val_loss: 0.0836 - val_accuracy: 0.9720
Epoch 97/100
457/457 [=====] - 98s 215ms/step - loss: 0.0044 - accuracy: 0.9987 - val_loss: 0.1016 - val_accuracy: 0.9685
Epoch 98/100
457/457 [=====] - 98s 215ms/step - loss: 0.0037 - accuracy: 0.9996 - val_loss: 0.0891 - val_accuracy: 0.9737
Epoch 99/100
457/457 [=====] - 109s 239ms/step - loss: 0.0056 - accuracy: 0.9987 - val_loss: 0.1050 - val_accuracy: 0.9650
Epoch 100/100
457/457 [=====] - 88s 193ms/step - loss: 0.0016 - accuracy: 1.0000 - val_loss: 0.0797 - val_accuracy: 0.9737
Tiempo total de entrenamiento: 9976.940877914429 segundos

```

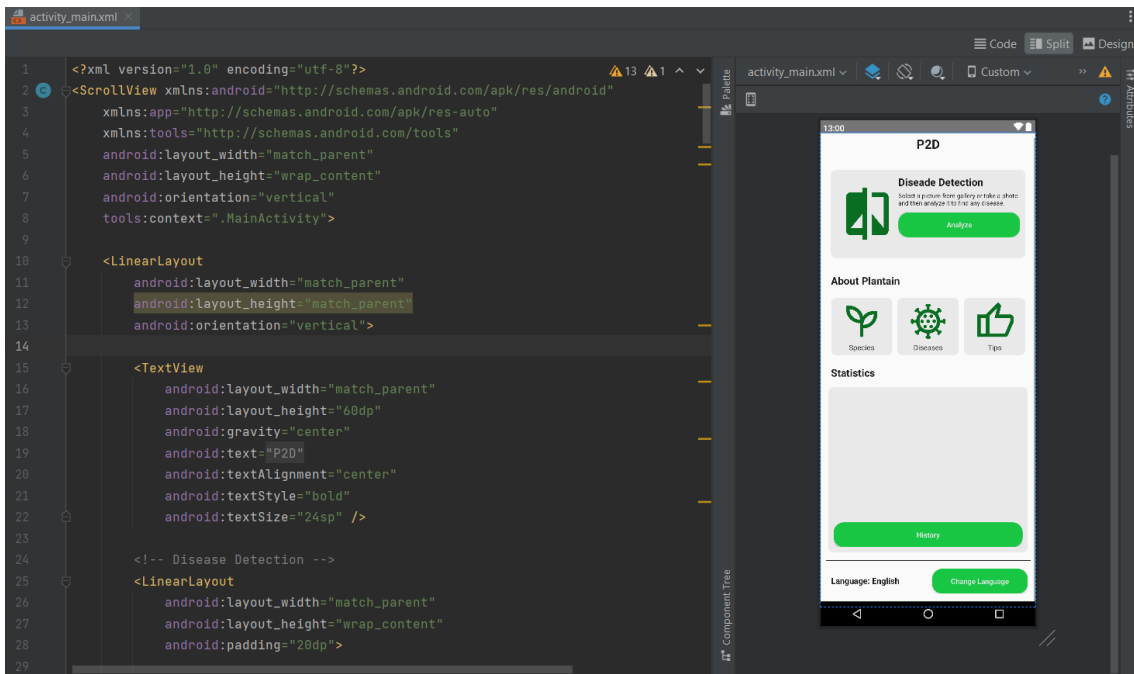
### Anexo 2: Código del entrenamiento del modelo



### Anexo 3: Imágenes aumentadas de cada clase



Anexo 4: Diagrama de clases de la aplicación móvil



Anexo 5: Interfaz principal de la aplicación en Android Studio

```

1 usage  👤 andrewdev18 *
public void classifyImage(Bitmap image) {
    try {
        PDDModel model = PDDModel.newInstance(getApplicationContext());

        // Creates inputs for reference.
        TensorBuffer inputFeature0 = TensorBuffer.createFixedSize(new int[]{1,
            imageSize, imageSize, 3}, DataType.FLOAT32);

        ByteBuffer byteBuffer = ByteBuffer.allocateDirect(capacity: 4 *
            imageSize * imageSize * 3);
        byteBuffer.order(ByteOrder.nativeOrder());
        int[] intValues = new int[imageSize * imageSize];
        image.getPixels(intValues, offset: 0, image.getWidth(), x: 0, y: 0,
            image.getWidth(), image.getHeight());

        int pixel = 0;
        for (int i = 0; i < imageSize; i++) {
            for (int j = 0; j < imageSize; j++) {
                int val = intValues[pixel++]; //RGB
                byteBuffer.putFloat(value: ((val >> 16) & 0xFF) * (1.f / 1));
                byteBuffer.putFloat(value: ((val >> 8) & 0xFF) * (1.f / 1));
                byteBuffer.putFloat(value: (val & 0xFF) * (1.f / 1));
            }
        }

        inputFeature0.loadBuffer(byteBuffer);

        PDDModel.Outputs outputs = model.process(inputFeature0);
        TensorBuffer outputFeature0 = outputs.getOutputFeature0AsTensorBuffer();

        float[] confidences = outputFeature0.getFloatArray();
        int maxResultDisease = 0;
        float maxConfidence = 0;
        float minConfidence = 0;
        for (int i = 0; i < confidences.length; i++) {
            System.out.println("Confidence: " + confidences[i]);
            if (confidences[i] > maxConfidence) {
                maxConfidence = confidences[i];
                maxResultDisease = i;
            }
            if (confidences[i] <= minConfidence) {
                minConfidence = confidences[i];
            }
        }
        float accuracy = (maxConfidence * 100f);
        accuracyTxt.setText(decFormat.format(accuracy) + "%");
        setResultString(maxResultDisease);

        //Store image and result
        String imageName = history.storeImage(image);
        history.storeResult(maxResultDisease, accuracy, imageName);

        //model.close();
    } catch (IOException e) {
        e.printStackTrace();
    } catch (Exception e) {
        System.out.println("TFLite Error: " + e.getMessage());
    }
}

```

Anexo 6: Código de clasificación de imágenes en Java

	Gusta la aplicación	Innecesariamente difícil	Fácil de usar	Necesito ayuda	Funciones bien integradas	Inconsistencia	Fácil de aprender	Complicado	Confianza al usarlo	Debo aprender antes de usar	
USR	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	
1	4	2	3	4	5	1	4	2	3	2	
2	4	2	3	3	4	1	3	3	3	3	
3	5	1	4	2	4	1	5	2	4	2	
4	3	1	4	3	5	2	3	3	3	4	
5	5	1	5	1	4	1	5	1	5	1	
6	3	2	3	3	4	1	3	4	3	4	
7	4	1	4	2	5	1	3	2	4	2	<b>PUNTAJE</b>
<b>AVG</b>	<b>4,00</b>	<b>1,43</b>	<b>3,71</b>	<b>2,57</b>	<b>4,43</b>	<b>1,14</b>	<b>3,71</b>	<b>2,43</b>	<b>3,57</b>	<b>2,57</b>	<b>73,21</b>

### Anexo 7: Cálculo del puntaje SUS en Excel

CLASE	A	B	C	D	E	F	G		
A	60	0	0	0	0	0	1		
B	0	49	0	0	0	0	0		
C	0	0	80	0	0	0	0		
D	1	0	0	82	0	0	0		
E	1	0	0	0	52	0	0		
F	0	0	0	0	0	38	0		
G	1	0	0	0	0	0	22		

<b>CLASE A</b>		<b>CLASE B</b>		<b>CLASE C</b>		<b>PRECISION GLOBAL</b>	<b>0,9897</b>
VP	60	VP	49	VP	80		
FP	3	FP	0	FP	0		
FN	1	FN	0	FN	0		
VN	323	VN	338	VN	307		
PRECISIÓN	0,9524	PRECISIÓN	1,0000	PRECISIÓN	1,0000	<b>CLASE G</b>	
SENSIBILIDAD	0,9836	SENSIBILIDAD	1,0000	SENSIBILIDAD	1,0000	VP	22
F1 SCORE	0,9677	F1 SCORE	1,0000	F1 SCORE	1,0000	FP	1
						FN	1
						VN	363
<b>CLASE D</b>		<b>CLASE E</b>		<b>CLASE F</b>		PRECISIÓN	0,9565
VP	82	VP	52	VP	38	SENSIBILIDAD	0,9565
FP	0	FP	0	FP	0	F1 SCORE	0,9565
FN	1	FN	1	FN	1		
VN	304	VN	334	VN	348		
PRECISIÓN	1,0000	PRECISIÓN	1,0000	PRECISIÓN	1,0000		
SENSIBILIDAD	0,9880	SENSIBILIDAD	0,9811	SENSIBILIDAD	0,9744		
F1 SCORE	0,9939	F1 SCORE	0,9905	F1 SCORE	0,9870		

### Anexo 8: Cálculo en Excel de métricas de eficiencia del modelo

# CUESTIONARIO SUS

Pienso que me gustaría usar este producto con frecuencia.

Poco						Mucho
	1	2	3	4	5	

Encontré el producto innecesariamente complejo.

Poco						Mucho
	1	2	3	4	5	

Me pareció que el producto era fácil de usar.

Poco						Mucho
	1	2	3	4	5	

Creo que voy a necesitar la ayuda de una persona técnica para poder usar este producto.

Poco						Mucho
	1	2	3	4	5	

Me pareció que las diversas funciones de este producto están bien integradas.

Poco						Mucho
	1	2	3	4	5	

Me pareció que había demasiada inconsistencia en este producto.

Poco						Mucho
	1	2	3	4	5	

Pienso que la mayoría de las personas aprenderían a usar este producto muy rápidamente.

Poco						Mucho
	1	2	3	4	5	

Me pareció que el producto es muy complicado de usar.

Poco						Mucho
	1	2	3	4	5	

Me sentí con mucha confianza al usar el producto.

Poco						Mucho
	1	2	3	4	5	

Tenía que aprender muchas cosas antes de que pudiera comenzar a utilizar este producto.

Poco						Mucho
	1	2	3	4	5	

Anexo 9: Formato del cuestionario SUS utilizado en la investigación

Caso de uso	CU-01: Clasificar imagen
Actor	Usuario
Propósito	Analizar una imagen capturada por el usuario e identificar a cuál de las plagas del plátano pertenece.
Resumen	El usuario ingresa a la interfaz de clasificación, captura una imagen, el sistema la clasifica y muestra información.
Tipo	
Precondiciones	Debe existir una imagen cargada para ser analizada.
Casos de uso asociados	CU-02, CU-03
<b>Flujo normal de eventos</b>	
<b>Acción del actor</b>	<b>Respuesta del sistema</b>
1. El caso de uso inicia con el usuario ingresando a la interfaz de clasificación de imágenes.	2. El sistema muestra los controles para capturar la imagen.
3. El usuario elige una de las opciones para capturar la imagen: Si el usuario elige capturar desde cámara el sistema pasa al caso de uso UC-02. Si el usuario elige capturar desde galería el sistema pasa al caso de uso UC-03.	4. El sistema muestra la imagen en pantalla y se habilita un botón para analizar la imagen seleccionada.
5. Si el usuario desea repetir la foto la debe capturar de nuevo regresando al paso 3, sino avanza al paso 6.	6. El caso de uso finaliza cuando sistema procesa la imagen la clasifica y muestra el resultado en pantalla con información sobre la plaga detectada.
<b>Flujo alterno de eventos</b>	
<b>Acción del actor</b>	<b>Respuesta del sistema</b>
3. El usuario presiona el botón para analizar una imagen, pero sin haber capturado una fotografía primero	4. El sistema no encuentra alguna imagen para procesar y no permite avanzar en el proceso. El caso de uso se reanuda cuando el usuario haya seleccionado una imagen.

Anexo 10: Caso de uso 1 - Clasificar imagen

Caso de uso	CU-02: Capturar imagen desde cámara	
Actor	Usuario	
Propósito	Capturar una imagen con la cámara para usarla en la detección de plagas.	
Resumen	El sistema solicita permisos al usuario para usar la cámara y el usuario captura una imagen.	
Tipo	Secundario	
Precondiciones	El sistema debe tener permisos para usar la cámara.	
Casos de uso asociados	CU-01	
<b>Flujo normal de eventos</b>		
<b>Acción del actor</b>	<b>Respuesta del sistema</b>	
1. Este caso de uso inicia cuando el usuario selecciona la opción de capturar una imagen usando la cámara.	2. El sistema verifica si tiene permisos para usar la cámara. Si no tiene permisos, se los solicita al usuario en el paso 3, pero si el sistema ya tiene permisos el sistema avanza al paso 4.	
3. El usuario elige permitir o negar el permiso al sistema para usar la cámara. Si el usuario lo niega, el caso de uso finaliza, caso contrario, avanza al paso 4.	4. El sistema le muestra la interfaz de la cámara al usuario para capturar la imagen.	
5. El caso de uso finaliza cuando el usuario captura la imagen. Una vez finalizado se pasa al caso de uso CU-01.		
<b>Flujo alterno de eventos</b>		
<b>Acción del actor</b>	<b>Respuesta del sistema</b>	
3. El usuario niega el permiso para usar la cámara y el caso de uso finaliza.		

Anexo 11: Caso de uso 2 - Capturar imagen desde cámara

Caso de uso	CU-03: Capturar imagen desde la galería	
Actor	Usuario	
Propósito	Capturar una imagen desde la galería para usarla en la detección de plagas.	
Resumen	El sistema solicita permisos al usuario para acceder a la galería y el usuario captura una imagen.	
Tipo	Secundario	
Precondiciones	El sistema debe tener permisos para acceder a la galería.	
Casos de uso asociados	CU-01	
<b>Flujo normal de eventos</b>		
<b>Acción del actor</b>	<b>Respuesta del sistema</b>	
1. Este caso de uso inicia cuando el usuario selecciona la opción de capturar una imagen desde la galería.	2. El sistema verifica si tiene permisos para acceder a galería. Si no tiene permisos, se los solicita al usuario en el paso 3, pero si el sistema ya tiene permisos el sistema avanza al paso 4.	
3. El usuario elige permitir o negar el permiso al sistema para acceder a galería. Si el usuario lo niega, el caso de uso finaliza, caso contrario, avanza al paso 4.	4. El sistema le muestra la interfaz de la galería al usuario para capturar la imagen.	
5. El caso de uso finaliza cuando el usuario captura la imagen. Una vez finalizado se pasa al caso de uso CU-01.		
<b>Flujo alterno de eventos</b>		
<b>Acción del actor</b>	<b>Respuesta del sistema</b>	
3. El usuario niega el permiso para acceder a la galería y el caso de uso finaliza.		

Anexo 12: Caso de uso 3 - Capturar imagen desde galería

Caso de uso	CU-04: Consultar historial
Actor	Usuario
Propósito	Revisar el historial de las predicciones realizadas.
Resumen	El usuario accede al historial de las predicciones y revisa las imágenes capturadas.
Tipo	Primario
Precondiciones	Ninguno
Casos de uso asociados	Ninguno
<b>Flujo normal de eventos</b>	
<b>Acción del actor</b>	<b>Respuesta del sistema</b>
	1. El caso de uso inicia cuando el sistema carga en la pantalla principal un gráfico con la cantidad de predicciones realizadas y un botón para ver el historial.
2. El usuario presiona el botón para observar el historial	3. El sistema muestra la interfaz con el historial de todas las predicciones realizadas.
4. El caso de uso finaliza cuando el usuario selecciona uno de los registros y observa la imagen guardada.	
<b>Flujo alterno de eventos</b>	
<b>Acción del actor</b>	<b>Respuesta del sistema</b>
-	-

Anexo 13: Caso de uso 4 - Consultar historial de predicciones

Caso de uso	CU-05: Consultar información de plagas	
Actor	Usuario	
Propósito	Revisar la información de las plagas disponibles en el sistema.	
Resumen	El usuario ingresa a la interfaz de información de plagas y revisa el contenido sobre cada plaga.	
Tipo	Primario	
Precondiciones	Deben existir plagas registradas en el sistema.	
Casos de uso asociados	Ninguno	
<b>Flujo normal de eventos</b>		
<b>Acción del actor</b>	<b>Respuesta del sistema</b>	
1. El caso de uso inicia cuando el usuario ingresa inicia el sistema e ingresa a la interfaz de información de las plagas.	2. El sistema muestra un menú con cada plaga disponible.	
3. El usuario selecciona una de las plagas que le muestra el sistema.	4. El caso de uso finaliza mostrándole al usuario una pantalla con toda la información sobre la plaga seleccionada.	
<b>Flujo alterno de eventos</b>		
<b>Acción del actor</b>	<b>Respuesta del sistema</b>	
-	-	

Anexo 14: Caso de uso 5 - Consultar información de plagas

Caso de uso	CU-06: Consultar variedades de plátanos
Actor	Usuario
Propósito	Revisar la información de las variedades de plátano.
Resumen	El usuario ingresa a la interfaz de información de variedades y revisa el contenido sobre cada una.
Tipo	Primario
Precondiciones	Deben existir variedades registradas en el sistema.
Casos de uso asociados	Ninguno
<b>Flujo normal de eventos</b>	
<b>Acción del actor</b>	<b>Respuesta del sistema</b>
1. El caso de uso inicial cuando el usuario selecciona en el menú principal la opción de ver las variedades de plátano.	2. El sistema carga la información de cada variedad y la muestra en la interfaz.
3. El caso de uso finaliza cuando el usuario revisa la información de las variedades.	
<b>Flujo alterno de eventos</b>	
<b>Acción del actor</b>	<b>Respuesta del sistema</b>
-	-

Anexo 15: Caso de uso 6 – Consultar variedades de plátanos

Caso de uso	CU-07: Consultar consejos para plantaciones
Actor	Usuario
Propósito	Revisar consejos para cuidar las plantaciones de plátanos.
Resumen	El usuario ingresa a la interfaz de consejos para plantaciones y revisa el contenido.
Tipo	Primario
Precondiciones	Deben existir consejos registrados en el sistema.
Casos de uso asociados	Ninguno
<b>Flujo normal de eventos</b>	
<b>Acción del actor</b>	<b>Respuesta del sistema</b>
1. El caso de uso inicial cuando el usuario selecciona en el menú principal la opción de ver los consejos para plantaciones.	2. El sistema carga la información de cada consejo y la muestra en la interfaz.
3. El caso de uso finaliza cuando el usuario revisa los consejos en la interfaz.	
<b>Flujo alternativo de eventos</b>	
<b>Acción del actor</b>	
-	-

Anexo 16: Caso de uso 7 - Consultar consejos para plantaciones