



Uleam

Extensión El Carmen

UNIVERSIDAD LAICA "ELOY ALFARO" DE MANABÍ

EXTENSIÓN EN EL CARMEN

CARRERA DE INGENIERÍA EN SOFTWARE

Creada Ley No. 10 – Registro Oficial 313 de noviembre 13 de 1985

PROYECTO INTEGRADOR

**PREVIO A LA OBTENCIÓN DEL TÍTULO DE INGENIERO
EN SOFTWARE**

Transfer Learning para la detección de *Pseudocercospora fijiensis* en la Granja Experimental ULEAM, extensión El Carmen

AUTOR

ANTHONY ADRIAN PITA CEDEÑO

TUTOR

ING. CARLOS VINICIO LOPEZ RODRIGUEZ

EL CARMEN, SEPTIEMBRE 2026

CERTIFICACIÓN DEL TUTOR

	NOMBRE DEL DOCUMENTO: CERTIFICADO DE TUTOR(A).	CÓDIGO: PAT-04-F-004
	PROCEDIMIENTO: TITULACIÓN DE ESTUDIANTES DE GRADO BAJO LA UNIDAD DE INTEGRACIÓN CURRICULAR	REVISIÓN: 1
		Página 1 de 1

CERTIFICACIÓN

En calidad de docente tutor de la Extensión El Carmen de la Universidad Laica "Eloy Alfaro" de Manabí, CERTIFICO:


Haber dirigido, revisado y aprobado preliminarmente el Trabajo de Integración Curricular bajo la autoría del estudiante **ANTHONY ADRIAN PITA CEDEÑO**, legalmente matriculado/a en la carrera de Tecnologías de la Información período académico 2026-1, cumpliendo el total de 288 horas, cuyo tema del proyecto o núcleo problémico es **"Transfer Learning para la detección de Pseudocercospora fijiensis en la Granja Experimental ULEAM, extensión El Carmen"**.

La presente investigación ha sido desarrollada en apego al cumplimiento de los requisitos académicos exigidos por el Reglamento de Régimen Académico y en concordancia con los lineamientos internos de la opción de titulación en mención, reuniendo y cumpliendo con los méritos académicos, científicos y formales, y la originalidad del mismo, requisitos suficientes para ser sometida a la evaluación del tribunal de titulación que designe la autoridad competente.

Particular que certifico para los fines consiguientes, salvo disposición de Ley en contrario.

El Carmen, 31 de julio de 2026.

Lo certifico,


Ing. Carlos Vinicio López Rodríguez, Mg
Docente Tutor
Área: Tecnologías de la Información

Tribunal de sustentación

TRIBUNAL DE SUSTENTACIÓN



UNIVERSIDAD LAICA "ELOY ALFARO" DE MANABÍ

EXTENSIÓN EN EL CARMEN

CARRERA DE INGENIERÍA EN SOFTWARE

Título del Trabajo de Titulación

Transfer Learning para la detección de *Pseudocercospora fijiensis* en la Granja Experimental ULEAM, extensión El Carmen

Modalidad:

Proyecto Integrador

Autor

Pita Cedeño Anthony Adrian

Tutor:

ING. CARLOS VINICIO LOPEZ RODRIGUEZ

Tribunal de Sustentación:

- **Presidente:** Ing. Mora Marcillo Alex Bladimir, Mg.
-
- **Miembro:** Ing. Mendoza Villamar Rocio Alexandra, Mg.
-
- **Miembro:** Ing. Arévalo Hermida Rómulo Danilo, Mg.

Fecha de Sustentación

26 de agosto 2026




UNIVERSIDAD LAICA "ELOY ALFARO" DE MANABÍ

EXTENSIÓN EN EL CARMEN



DECLARACIÓN DE AUTORÍA

La responsabilidad del contenido de este Trabajo de titulación, cuyo tema es: Transfer Learning para la detección de *Pseudocercospora fijiensis* en la Granja Experimental ULEAM, extensión El Carmen, corresponde exclusivamente a Pita Cedeño Anthony Adrian con CI 1313654806, y los derechos patrimoniales de la misma corresponden a la Universidad Laica "Eloy Alfaro" de Manabí.

Pita Cedeño Anthony Adrian

C.I 1313654806

DEDICATORIA

Dedico este trabajo, en primer lugar, a **Dios**, quien ha sido un pilar fundamental durante todo el trayecto de mi carrera, brindándome fortaleza, sabiduría y perseverancia para superar cada dificultad y continuar avanzando hasta alcanzar esta meta.

A mis **abuelos**, quienes han sido como mis padres y han estado presentes en cada etapa de mi vida, ofreciéndome su amor, apoyo y enseñanzas, convirtiéndose en una parte esencial de la persona que soy hoy.

A mi **madre**, por estar siempre a mi lado, por brindarme su ayuda incondicional y por acompañarme durante todo este proceso académico.

A mi **padre**, por su apoyo, sus consejos y por motivarme constantemente a continuar estudiando y esforzándome para alcanzar mis objetivos.

Este logro también les pertenece, porque cada uno, de una manera especial, ha contribuido a que pueda culminar esta importante etapa de mi vida.

Anthony Adrian Pita Cedeño

AGRADECIMIENTO

Agradezco principalmente a Dios, por concederme la vida, la fortaleza y la sabiduría necesarias para afrontar cada uno de los desafíos que se presentaron durante mi formación universitaria. Su presencia y guía han sido fundamentales para mantenerme firme y continuar avanzando incluso en los momentos más difíciles.

Expreso mi agradecimiento a las autoridades de la Universidad Laica Eloy Alfaro de Manabí, Extensión El Carmen, y a la Carrera de Ingeniería en Software, por brindarme la oportunidad de formarme académica y profesionalmente dentro de esta institución.

De manera especial, agradezco a mi tutor, Ing. Carlos Vinicio Lopez Rodríguez, por su orientación, acompañamiento y conocimientos aportados durante el desarrollo de este trabajo de titulación. Asimismo, agradezco a los docentes que formaron parte de mi preparación universitaria, quienes mediante sus enseñanzas contribuyeron al desarrollo de los conocimientos y habilidades adquiridos a lo largo de la carrera.

Agradezco también a todas aquellas personas que, de una u otra manera, aportaron durante este proceso académico y contribuyeron a la culminación de esta etapa.

Finalmente, agradezco por cada experiencia vivida durante estos años de estudio, por los aprendizajes obtenidos y por permitirme alcanzar una meta que representa el resultado de esfuerzo, constancia y dedicación.

Anthony Adrian Pita Cedeño

ÍNDICE GENERAL

CERTIFICACIÓN DEL TUTOR	I
TRIBUNAL DE SUSTENTACIÓN	II
DECLARACIÓN DE AUTORÍA.....	III
DEDICATORIA	IV
AGRADECIMIENTO	V
ÍNDICE GENERAL	VI
RESUMEN	XVII
ABSTRACT.....	XVIII
1 CAPÍTULO I.....	18
1.1 Introducción	18
1.2 Presentación del tema.....	19
1.3 Contextualización de la problemática	20
1.4 Planteamiento del problema.....	20
1.4.1 Problematicación.....	20
1.4.2 Génesis del problema	21
1.4.3 Estado actual del problema	21
1.5 Diagrama causa – efecto del problema	22
1.6 Objetivos	22
1.6.1 Objetivo general.....	22
1.6.2 Objetivos específicos	23
1.7 Justificación	23
1.8 Impactos esperados	24

1.8.1 Impacto tecnológico	24
1.8.2 Impacto social	25
1.8.3 Impacto ecológico	26
2 CAPÍTULO II: MARCO TEÓRICO	27
2.1 Antecedentes históricos.....	27
2.1.1 Historia de las variables	27
2.1.2 Evolución de la inteligencia Artificial y el Aprendizaje por Transferencia....	27
2.1.3 Contexto histórico y manejo fitosanitario de la Sigatoka negra	27
2.2 Antecedentes de investigación	28
2.3 Definiciones conceptuales.....	29
2.3.1 Inteligencia Artificial y Aprendizaje Profundo.....	29
2.3.2 Redes Neuronales Convolucionales (CNN).....	30
2.3.3 Arquitecturas preentrenadas.....	31
2.3.4 Estrategias de transferencia.....	32
2.3.5 Técnicas de aumento de datos.....	33
2.3.6 Frameworks de Aprendizaje profundo.....	33
2.3.7 Pseudocercospora fijiensis	34
2.3.8 Taxonomía y patogénesis.....	34
2.3.9 Ciclo de vida y condiciones favorables.....	34
2.3.10 Sintomatología foliar.....	35
2.3.11 Métodos detección tradicionales	35
2.3.12 Características IA aplicada al análisis foliar	36
2.3.13 Impacto agronómico de la Sigatoka negra	36
2.3.14 Metodología de desarrollo	36

2.3.15 Prototipo Evolutivo en MLOps.....	37
2.4 Conclusiones del marco teórico	38
3 CAPÍTULO III: MARCO INVESTIGATIVO	39
3.1 Introducción.....	39
3.2 Tipos y métodos de investigación.....	39
3.2.1 Investigación Aplicada.....	39
3.2.2 Investigación no Experimental.....	40
3.2.3 Investigación Mixta.....	40
3.2.4 Método Analítico	41
3.2.5 Método deductivo	41
3.3 Fuentes de información de datos.....	42
3.3.1 Encuestas.....	42
3.3.2 Entrevista.....	42
3.4 Estrategia operacional para la recolección de datos	43
3.4.1 Población.....	43
3.4.2 Muestra	43
3.4.3 Análisis de las herramientas de recolección de datos a utilizar	44
3.4.4 Plan de recolección de datos	46
3.5 Análisis y presentación de resultados	46
3.5.2 Informe final del análisis de los datos.....	54
4 CAPÍTULO IV: MARCO PROPOSITIVO	55
4.1 Introducción	55
4.2 Descripción de la propuesta	56
4.3 Determinación de recursos.....	57

4.3.1 Humanos	57
4.3.2 Tecnológicos	58
4.3.3 Económicos.....	59
sprint 4.4 Desarrollo del modelo mediante Prototipo Evolutivo en MLOps organizado por	60
4.4.1 Descripción del Producto	60
4.4.2 Historias de Usuarios	63
4.4.3 Diseño del sistema / Descripción técnica.....	66
4.4.4 Descripción Técnica/ Arquitectura del sistema.....	74
4.4.5 Roles y Responsabilidades.....	78
4.4.6 Planificación del Sprint	79
4.4.7 Backlog del Producto	82
4.4.8 Desarrollo de los sprints.....	85
4.4.9 Resultado técnico del modelo entrenado	89
4.4.10 Exportación del modelo a TensorFlow Lite.....	90
4.4.11 Validación preliminar del prototipo	91
5 CAPÍTULO V: EVALUACIÓN DE RESULTADOS	93
5.1 Introducción	93
5.2 Rendimiento del modelo de aprendizaje por transferencia	93
5.3 Análisis de métricas de formación y validación	94
5.4 Probando el modelo optimizado con TensorFlow Lite	94
5.5 Pruebas funcionales del prototipo de detección	95
5.5.1 Matriz de requisitos y pruebas funcionales.....	96
5.6 Análisis del cumplimiento de los objetivos de investigación	98
5.7 Resumen de los resultados obtenidos.....	98

6 CAPÍTULO VI: CONCLUSIONES Y RECOMENDACIONES	100
6.1 Conclusiones	100
6.2 Recomendaciones.....	101
7 Bibliografía.....	102
8 ANEXOS.....	105
9 GLOSARIO.....	113

ÍNDICE DE TABLAS

Tabla 1: Tabla de recolección de datos.....	46
Tabla 2: Análisis de Encuestas	46
Tabla 3: Análisis de entrevista.....	51
Tabla 4: Recursos Humanos	57
Tabla 5: Recursos Tecnológicos	58
Tabla 6: Recursos Económicos.....	59
Tabla 7 Historia de usuario1 Captura de imagen de hoja de plátano.....	63
Tabla 8 Historia de usuario2 Selección de imagen desde la galería	63
Tabla 9 Historia de usuario 3 Análisis de imagen mediante el modelo de Transfer Learning	64
Tabla 10 Historia de usuario 4 Visualización del resultado de detección	64
Tabla 11 Historia de usuario 5 Registro y consulta del historial de análisis	65
Tabla 12 Captura de imagen	66
Tabla 13 Roles y Responsabilidades.....	78
Tabla 14 Preparación y configuración	79
Tabla 15 Entrenamiento inicial del modelo	80
Tabla 16 Evaluación y mejora del modelo	81
Tabla 17 Exportación del modelo y prototipo de prueba.....	81
Tabla 18 Backlog del Producto.....	82
Tabla 19 Preparación del entorno y dataset	83
Tabla 20 Entrenamiento inicial del modelo	84
Tabla 21 Evaluación y ajuste del modelo	84
Tabla 22 Exportación y validación del modelo	85
Tabla 23 Matriz de requisitos y pruebas funcionales.....	96

INDICE DE ANEXOS

ANEXOS A fotografías	106
ANEXO B : Estructura de la entrevista y encuesta	107
ANEXO C: Reporte del sistema antiplagio	112
ANEXO D: Asignación de tutor	114

ÍNDICE DE ILUSTRACION

Ilustración 1 Diagrama de caso de uso: Captura de imagen	66
Ilustración 2 Selección de imagen desde galería	67
Ilustración 3 Diagrama de secuencia	70
Ilustración 4 Diagrama de secuencia de visualización del resultado	70
Ilustración 5 Diagrama de secuencia del proceso de análisis	71
Ilustración 6 Diagrama de Estado	72
Ilustración 7 Diagrama de estado.....	73
Ilustración 8 Mapa del sistema	74
Ilustración 9 Preparación del entorno	86
Ilustración 10 Dataset	86
Ilustración 11 Entrenamiento inicial del modelo en Google Colab	87
Ilustración 12 Conversión al formato TensorFlow Lite.....	88
Ilustración 13 Exportación del modelo y validador de hojas.....	89
Ilustración 14 conversión a TensorFlow Lite	91
Ilustración 15 Archivo. tflite guarda en drive	91
Ilustración 16 Modelo exportable	95
Ilustración 17 Prueba del prototipo.....	96
Ilustración 18 Entrevista al profesional en el área.....	105
Ilustración 19 Compra de las donaciones	105
Ilustración 20 estructura de la encuesta	106
Ilustración 21 estructura de la encuesta	107
Ilustración 22 estructura de la encuesta	108

Ilustración 23 estructura de la encuesta	109
Ilustración 24 Reporte antiplagio.....	110
Ilustración 25 Reporte antiplagio.....	111
Ilustración 26 Designación de tutor	112

RESUMEN

La Sigatoka negra, causada por *Pseudocercospora fijiensis*, es una enfermedad foliar que afecta el cultivo de plátano y reduce el área útil de las hojas en la Granja Experimental ULEAM, las hojas se evalúan mediante observación directa por lo que el resultado depende en gran medida de la experiencia del personal encargado, el procedimiento puede generar dudas al diferenciar una afectación moderada de una severa; por esta razón, el estudio propone implementar un modelo de aprendizaje por transferencia que apoyara la clasificación de imágenes de hojas plátano.

La investigación tuvo un diseño no experimental y un enfoque mixto con predominio cuantitativo, el componente cualitativo permitió conocer las necesidades del entorno mediante encuesta, entrevista y observación. El componente cuantitativo se aplicó al entrenamiento y evaluación de los modelos. El conjunto de datos final estuvo formado por 141 imágenes organizadas en tres clases: sana, Sigatoka moderada y Sigatoka severa. Se destinaron 87 imágenes al entrenamiento, 24 a la validación y 30 a la prueba. La separación se realizó por grupos de captura para evitar que fotografías de una misma secuencia aparecieran en subconjuntos diferentes.

Se evaluaron las arquitecturas MobileNetV2, EfficientNetB0 y ResNet50V2 utilizando la misma distribución de imágenes. Después de comparar los resultados, MobileNetV2 con ajuste fino mostró la mejor relación entre rendimiento y costo computacional. Este modelo obtuvo una exactitud de validación del 83,33 %, una exactitud balanceada del 87,78 %, un F1 macro del 81,35 % y una pérdida de 0,5395, las pruebas del modelo alcanzó una exactitud del 90 %, se convirtió al formato TensorFlow Lite y se incorporó en una aplicación desarrollada con Flutter, desde la cual el usuario puede tomar una fotografía o seleccionar una imagen guardada en la galería, antes de realizar la clasificación y un validador analiza que la imagen contenga una hoja de plátano. Los resultados obtenidos muestran su eficiencia como herramienta de apoyo, sin embargo, será necesario incorporar más fotografías para evaluar y mejorar su desempeño ante imágenes diferentes a las utilizadas en el estudio.

Palabras clave: aprendizaje por transferencia, MobileNetV2, Sigatoka negra, visión por computador, TensorFlow Lite.

ABSTRACT

Black Sigatoka, caused by *Pseudocercospora fijiensis*, is a foliar disease that affects plantain crops and reduces the useful leaf area. At the ULEAM Experimental Farm, leaves are evaluated through direct observation; therefore, the result depends largely on the experience of the personnel in charge. This procedure may generate uncertainty when distinguishing moderate from severe levels of infection. For this reason, the study proposes the implementation of a transfer learning model to support the classification of plantain leaf images.

The research followed a non-experimental design and a mixed-method approach with quantitative predominance. The qualitative component made it possible to identify the needs of the environment through surveys, interviews, and observation. The quantitative component was applied to the training and evaluation of the models. The final dataset consisted of 141 images organized into three classes: healthy, moderate Black Sigatoka, and severe Black Sigatoka. A total of 87 images were used for training, 24 for validation, and 30 for testing. The data split was performed by capture groups to prevent photographs from the same sequence from appearing in different subsets.

The MobileNetV2, EfficientNetB0, and ResNet50V2 architectures were evaluated using the same image distribution. After comparing the results, fine-tuned MobileNetV2 showed the best balance between performance and computational cost. This model achieved a validation accuracy of 83.33%, a balanced accuracy of 87.78%, a macro F1-score of 81.35%, and a validation loss of 0.5395. In the test phase, the model achieved an accuracy of 90%. It was converted to TensorFlow Lite format and integrated into an application developed with Flutter, through which the user can take a photograph or select an image stored in the gallery. Before classification, a validator checks whether the image contains a plantain leaf. The results obtained show its usefulness as a support tool; however, additional photographs will be required to evaluate and improve its performance with images different from those used in the study.

Keywords: transfer learning, MobileNetV2, Black Sigatoka, computer vision, TensorFlow Lite.

1 CAPÍTULO I

1.1 Introducción

El cultivo de plátano constituye una actividad agrícola importante para la provincia de Manabí y, particularmente, para el cantón El Carmen. Sin embargo, su producción puede verse afectada por enfermedades foliares como la Sigatoka negra, causada por *Pseudocercospora fijiensis*. Esta enfermedad reduce progresivamente el área fotosintética de las hojas y puede afectar el desarrollo del cultivo cuando no se identifica y controla de manera oportuna. En la Granja Experimental ULEAM, la revisión de las hojas es principalmente mediante la observación directa y el conocimiento adquirido por el personal durante sus labores agrícolas.

La necesidad de la investigación planteó el desarrollo y la evaluación, de un modelo de aprendizaje por transferencia para clasificar fotografías de hojas de plátano como sanas, con Sigatoka moderada o con Sigatoka severa, la herramienta no busca reemplazar la valoración de un profesional agrícola, sino ofrecer un primer análisis que facilite el monitoreo visual y permita organizar mejor la revisión de las plantas.

En el marco teórico se analizaron conceptos relacionados con inteligencia artificial, redes neuronales convolucionales, aprendizaje por transferencia, aumento de datos, ajuste fino y características de la Sigatoka negra. Posteriormente, el marco investigativo describió el enfoque metodológico, los instrumentos utilizados para conocer las necesidades del entorno y el procedimiento aplicado para organizar y evaluar el conjunto de imágenes.

El conjunto de datos final estuvo conformado por 141 imágenes de hojas de plátano, distribuidas en las categorías sana, Sigatoka moderada y Sigatoka severa. Para evitar que fotografías pertenecientes a una misma secuencia aparecieran en diferentes subconjuntos, las imágenes fueron separadas por grupos de captura. La distribución quedó conformada por 87 imágenes para entrenamiento, 24 para validación y 30 para prueba.

Durante el desarrollo de la propuesta se compararon las arquitecturas MobileNetV2, EfficientNetB0 y ResNet50V2. MobileNetV2 con ajuste fino presentó el mejor equilibrio entre rendimiento y costo computacional, alcanzando una exactitud de validación del 83,33 %, una exactitud balanceada del 87,78 %, un F1 macro del 81,35 % y una pérdida de validación de

0,5395. Posteriormente, el modelo fue convertido al formato TensorFlow Lite y se comprobó preliminarmente su funcionamiento en un prototipo móvil.

Finalmente, la evaluación permitió identificar tanto la viabilidad técnica de la propuesta como sus principales limitaciones. Los resultados obtenidos constituyen una primera aproximación funcional y muestran que el aprendizaje por transferencia puede emplearse como herramienta de apoyo para el monitoreo fitosanitario. No obstante, será necesario ampliar y equilibrar el conjunto de imágenes para mejorar la capacidad de generalización del modelo en condiciones reales de campo.

1.2 Presentación del tema

La presente investigación se orientó al desarrollo de una solución basada en aprendizaje por transferencia para apoyar la clasificación visual de hojas de plátano asociadas con *Pseudocercospora fijiensis* en la Granja Experimental ULEAM, Extensión El Carmen. El problema se abordó desde la visión por computador, considerando que la evaluación visual de las hojas puede presentar dificultades al diferenciar distintos niveles de afectación.

Para el desarrollo del clasificador se evaluaron las arquitecturas MobileNetV2, EfficientNetB0 y ResNet50V2 utilizando el mismo conjunto de imágenes y condiciones de evaluación. A partir de la comparación de sus resultados se seleccionó MobileNetV2 como arquitectura principal y posteriormente se convirtió el modelo al formato TensorFlow Lite para su integración en una aplicación móvil.

El producto desarrollado permite capturar una fotografía mediante la cámara o seleccionar una imagen desde la galería, validar previamente que corresponda a una hoja de plátano y, cuando la entrada es aceptada, clasificarla como sana, con Sigatoka moderada o con Sigatoka severa. La aplicación presenta la categoría estimada y el porcentaje de confianza, conserva un historial de los análisis y ejecuta el procesamiento directamente en el dispositivo móvil. Su propósito es funcionar como una herramienta de apoyo al monitoreo y no sustituir el criterio técnico agronómico.

1.3 Contextualización de la problemática

La Granja Experimental ULEAM, Extensión El Carmen, constituyó el espacio de referencia para la recopilación de información y fotografías utilizadas en esta investigación. En este entorno se desarrollan actividades académicas, prácticas e investigaciones relacionadas con el sector agropecuario, entre ellas la observación de problemas fitosanitarios presentes en los cultivos de plátano.

Dentro de este contexto, la Sigatoka negra, causada por *Pseudocercospora fijiensis*, representa una enfermedad foliar de interés para el monitoreo de las plantas. La identificación de sus manifestaciones visuales se realiza principalmente mediante la observación de las hojas, por lo que pueden presentarse dificultades al diferenciar distintos niveles de afectación, especialmente cuando existen variaciones de iluminación, posición de la hoja o similitud entre los síntomas observados.

Antes del desarrollo de este proyecto no se disponía, dentro del contexto estudiado, de una aplicación móvil basada en un modelo entrenado con fotografías locales que permitiera apoyar la clasificación visual de las hojas. Por esta razón, se desarrolló una solución capaz de analizar imágenes desde la cámara o la galería, ejecutar el procesamiento directamente en el dispositivo y conservar un historial de los resultados obtenidos. La información generada por la aplicación se plantea como apoyo al monitoreo y no como sustituto de la valoración realizada por profesionales del área agronómica.

1.4 Planteamiento del problema

1.4.1 Problematización

El monitoreo de la Sigatoka negra en la Granja Experimental ULEAM, presenta dificultades porque la apariencia de los síntomas cambia conforme avanza la enfermedad, la inspección visual permite reconocer los casos más evidentes, pero distinguir entre un nivel moderado y uno severo resulta más complicado cuando las hojas también muestran daños producidos por otras causas.

El problema no se limita a reconocer una mancha. En condiciones de campo cambian la luz, la distancia, el enfoque y el fondo de la fotografía. Además, una misma hoja puede mostrar lesiones de distinta intensidad. Estas variaciones aumentan la posibilidad de

clasificaciones diferentes entre observadores y justifican la evaluación de una herramienta que ayude a organizar la inspección visual.

A partir de esta situación se formuló la siguiente pregunta: ¿de qué manera un modelo de aprendizaje por transferencia, integrado en una aplicación móvil, puede apoyar la clasificación de hojas de plátano con síntomas visuales asociados a *Pseudocercospora fijiensis* en la Granja Experimental ULEAM, Extensión El Carmen

1.4.2 Génesis del problema

El problema abordado en esta investigación surge de la combinación de factores fitosanitarios, operativos y tecnológicos presentes en el monitoreo de la Sigatoka negra en la Granja Experimental ULEAM, Extensión El Carmen. La presencia de síntomas visuales asociados con *Pseudocercospora fijiensis* requiere una observación constante de las hojas de plátano para reconocer su estado y diferenciar los distintos niveles de afectación.

En el ámbito operativo, la evaluación de las hojas se ha realizado principalmente mediante inspección visual. Este procedimiento depende de la experiencia y del criterio del observador, por lo que pueden presentarse dificultades al diferenciar hojas sanas de aquellas con síntomas moderados o severos, especialmente cuando las características visuales entre categorías son similares.

Desde la perspectiva tecnológica, se identificó la necesidad de contar con una herramienta que apoye este proceso mediante el análisis automatizado de fotografías. En respuesta a esta necesidad, el proyecto plantea el uso del aprendizaje por transferencia y la integración de un modelo de clasificación en una aplicación móvil, con el propósito de proporcionar una estimación visual complementaria al monitoreo realizado en campo, sin sustituir el criterio técnico agronómico.

1.4.3 Estado actual del problema


En la Granja Experimental ULEAM, Extensión El Carmen, el monitoreo de la Sigatoka negra se realiza principalmente mediante la observación directa de las hojas. Este procedimiento permite identificar los síntomas visibles de la enfermedad; sin embargo, la

valoración puede variar de acuerdo con la experiencia de la persona que realiza la inspección y con las condiciones en las que se observa la planta.

Una de las principales dificultades se presenta al diferenciar niveles de afectación que visualmente pueden resultar similares, especialmente entre los estados moderado y severo. A esto se suman factores propios del trabajo en campo, como los cambios de iluminación, la distancia de observación, el estado general de la hoja y la presencia de otros daños que pueden confundirse con los síntomas de la enfermedad.

Actualmente, la granja no dispone de una herramienta móvil basada en inteligencia artificial que permita analizar una fotografía de la hoja y generar una clasificación automática como apoyo a la inspección. Por esta razón, el proyecto plantea el uso de aprendizaje por transferencia y visión por computador para complementar el monitoreo existente. La herramienta propuesta no busca reemplazar el criterio del personal técnico, sino proporcionar una referencia adicional que facilite la clasificación de las hojas y permita registrar los resultados obtenidos durante las inspecciones.

1.5 Diagrama causa – efecto del problema



1.6 Objetivos

1.6.1 Objetivo general

Desarrollar y evaluar una solución basada en aprendizaje por transferencia para clasificar imágenes de hojas de plátano en las categorías sana, Sigatoka moderada y Sigatoka

severa, e integrarla en una aplicación móvil como herramienta de apoyo al monitoreo de *Pseudocercospora fijiensis* en la Granja Experimental ULEAM, Extensión El Carmen.

1.6.2 Objetivos específicos

Identificar, mediante la aplicación de una encuesta y una entrevista, las prácticas relacionadas con el monitoreo visual de la Sigatoka negra y las necesidades del contexto para el uso de una aplicación móvil como herramienta de apoyo.

Analizar los fundamentos de las redes neuronales convolucionales y del aprendizaje por transferencia aplicados a la clasificación de imágenes de enfermedades foliares.

Depurar y organizar un conjunto local de fotografías, separándolas según sus grupos de captura y aplicando el aumento de datos únicamente durante el entrenamiento.

Comparar el desempeño de las arquitecturas MobileNetV2, EfficientNetB0 y ResNet50V2 mediante métricas de exactitud, exactitud balanceada, precisión, sensibilidad, F1 macro y pérdida de validación, con el propósito de seleccionar el modelo más adecuado para su integración en la aplicación móvil.

Convertir el modelo seleccionado al formato TensorFlow Lite e integrarlo en una aplicación móvil desarrollada con Flutter, que permita capturar o seleccionar imágenes, realizar una validación previa y mostrar la categoría de clasificación junto con su porcentaje de confianza.

Evaluar el funcionamiento de la aplicación móvil mediante pruebas funcionales y la verificación del cumplimiento de los requisitos establecidos, considerando la captura y selección de imágenes, validación previa, clasificación, presentación de resultados y almacenamiento del historial

1.7 Justificación

La presente investigación se justifica por la necesidad de incorporar herramientas tecnológicas que apoyen el monitoreo visual de la Sigatoka negra en hojas de plátano dentro de la Granja Experimental ULEAM, Extensión El Carmen. La inspección de las hojas depende del criterio y la experiencia del observador, por lo que una herramienta complementaria basada

en visión por computador puede contribuir a disponer de una segunda referencia durante el proceso de revisión.

Desde el punto de vista tecnológico, el aprendizaje por transferencia permite adaptar modelos preentrenados a un conjunto de imágenes específico sin necesidad de desarrollar una red neuronal desde cero. En este proyecto se evaluaron MobileNetV2, EfficientNetB0 y ResNet50V2 con fotografías locales, utilizando métricas de rendimiento para seleccionar la arquitectura más adecuada para su posterior integración en una aplicación móvil.

La investigación también permitió organizar un conjunto de fotografías de hojas de plátano obtenidas en el contexto de estudio, manteniendo separados los grupos de captura durante las etapas de entrenamiento, validación y prueba. Este procedimiento aporta una base técnica que puede utilizarse en futuras investigaciones orientadas a ampliar el número y la diversidad de imágenes disponibles.

Finalmente, la conversión del modelo seleccionado a TensorFlow Lite y su integración en Flutter permiten ejecutar la clasificación directamente en el dispositivo móvil. La aplicación fue concebida como una herramienta de apoyo al monitoreo fitosanitario y no como un sustituto del diagnóstico agronómico ni como un mecanismo automático para determinar tratamientos agrícolas.

1.8 Impactos esperados

La implementación de un modelo de aprendizaje por transferencia para detectar *Pseudocercospora fijiensis* podría aportar beneficios tecnológicos, sociales y ambientales tanto en la Granja Experimental ULEAM como en el sector platanero de Manabí.

1.8.1 Impacto tecnológico

El impacto tecnológico de la propuesta se relaciona con la integración de modelos de inteligencia artificial en una aplicación móvil desarrollada con Flutter. El sistema incorpora un modelo encargado de validar previamente la imagen y un clasificador basado en MobileNetV2 convertido al formato TensorFlow Lite, que permite clasificar las hojas como sanas, con Sigatoka moderada o con Sigatoka severa.

La aplicación permite utilizar fotografías obtenidas mediante la cámara o seleccionadas desde la galería, presentar la categoría estimada junto con su porcentaje de confianza y conservar los resultados en un historial local. El procesamiento se ejecuta directamente en el dispositivo móvil, por lo que la funcionalidad principal no depende de un servidor externo para realizar la inferencia.

Además, el proyecto permitió organizar un conjunto local de imágenes de hojas de plátano y establecer un procedimiento de preparación, entrenamiento, evaluación y despliegue del modelo. Tanto la aplicación como el proceso desarrollado pueden servir como referencia para futuras investigaciones orientadas al uso de visión por computador y aprendizaje por transferencia en contextos agrícolas.

1.8.2 Impacto social

El impacto social esperado de la propuesta se relaciona con la disponibilidad de una herramienta móvil de apoyo que puede utilizarse durante la revisión visual de hojas de plátano. El usuario puede capturar o seleccionar una fotografía, consultar la clasificación estimada y conservar el resultado en el historial para revisarlo posteriormente. La aplicación presenta la información de manera comprensible y establece que sus resultados constituyen una referencia complementaria, por lo que no sustituyen la valoración de un profesional del área agronómica.

La herramienta también puede utilizarse con fines académicos en demostraciones, prácticas de campo y actividades relacionadas con el uso de inteligencia artificial aplicada al sector agropecuario. Sin embargo, esta investigación no evaluó cambios en la rentabilidad, productividad, calidad de vida ni otros indicadores socioeconómicos de los usuarios, por lo que dichos efectos deberán analizarse en estudios posteriores.

Como parte de una posible adopción institucional, se recomienda realizar actividades de capacitación dirigidas a estudiantes y personal relacionado con la Granja Experimental, enfocadas en el uso adecuado de la aplicación, la correcta captura de fotografías y la interpretación responsable de los resultados generados por el modelo.

1.8.3 Impacto ecológico

El aporte ecológico esperado de la propuesta se relaciona con el uso de información visual como apoyo al monitoreo fitosanitario de las hojas de plátano. La aplicación permite registrar y consultar resultados de clasificación obtenidos a partir de fotografías, lo que puede facilitar un seguimiento más organizado del estado visual de las plantas.

Sin embargo, esta investigación no evaluó directamente cambios en el uso de fungicidas, dosis de agroquímicos ni efectos ambientales derivados de la utilización de la aplicación. Por esta razón, no es posible afirmar que el prototipo reduzca la frecuencia de tratamientos o genere un impacto ecológico cuantificable.

En futuras investigaciones, el historial generado por la aplicación podría relacionarse con registros agronómicos, frecuencia de tratamientos y evolución de los síntomas, con el propósito de analizar si su utilización puede contribuir a decisiones de manejo más informadas y a prácticas de monitoreo más sostenibles.

2 CAPÍTULO II: MARCO TEÓRICO

2.1 Antecedentes históricos

2.1.1 Historia de las variables

El desarrollo de esta investigación se apoya en dos ejes principales. El primero corresponde al aprendizaje por transferencia y su aplicación en el análisis de imágenes mediante redes neuronales convolucionales. El segundo se relaciona con la Sigatoka negra, causada por *Pseudocercospora fijiensis*, y con la necesidad de mejorar las formas de observación y seguimiento de sus síntomas en las hojas de plátano.

En el campo tecnológico, la evolución de la inteligencia artificial y de la visión por computador permitió pasar de métodos basados en características definidas manualmente a modelos capaces de aprender patrones directamente de las imágenes. Dentro de este proceso, el aprendizaje por transferencia adquirió importancia porque permite reutilizar el conocimiento de modelos previamente entrenados y adaptarlos a nuevos problemas cuando no se dispone de grandes cantidades de datos. Esta característica resulta especialmente útil en investigaciones agrícolas que trabajan con conjuntos locales de imágenes.

2.1.2 Evolución de la inteligencia Artificial y el Aprendizaje por Transferencia

La agricultura de precisión ha estado estrechamente ligado a la evolución de la Inteligencia Artificial (IA), específicamente del Machine Learning (Aprendizaje Automático), un subcampo que permite a los sistemas aprender patrones a partir de datos sin ser programados explícitamente. Dentro de este ámbito, las Redes Neuronales Convolucionales (CNN) revolucionaron la visión por computadora al permitir la extracción automática de características jerárquicas en imágenes. Desde la aparición de arquitecturas profundas como AlexNet, el aprendizaje por transferencia se ha utilizado en diferentes problemas de visión por computador. (Group, 2023).

2.1.3 Contexto histórico y manejo fitosanitario de la Sigatoka negra

Pseudocercospora fijiensis es el agente causal de la Sigatoka negra. Su manejo ha sido estudiado desde perspectivas químicas, genéticas y biológicas. Las investigaciones recientes muestran que el control es complejo por la capacidad de dispersión del patógeno, las condiciones húmedas y la aparición de resistencia a determinados tratamientos. Estos

antecedentes explican el interés por incorporar herramientas de observación y análisis de imágenes como complemento del monitoreo (Coronel Pocasangre, 2024).

2.2 Antecedentes de investigación

En el ámbito de la clasificación de patologías foliares Suhanya y Natesan (2024), desarrollaron la arquitectura PDDNet. Este modelo funciona como un ensamble que integra nueve redes neuronales convolucionales preentrenadas, tales como MobileNetV2 y DenseNet, utilizando la técnica de *Transfer Learning*. Al aplicar este enfoque sobre el conjunto de datos PlantVillage, el cual cuenta con más de 54,000 imágenes, el estudio reportó una exactitud del 97.79% en la identificación de quince clases de enfermedades. Los resultados demostraron que la extracción de características profundas supera el rendimiento de arquitecturas simples, lo que sugiere su viabilidad para escenarios agrícolas donde la cantidad de datos es restringida.

Un estudio recién publicado por Kumar (2025), evaluó la eficacia del *Transfer Learning* mediante las arquitecturas VGG16, MobileNetV2, Xception e InceptionV3. La investigación se centró en el conjunto de imágenes Plant_doc para diagnosticar anomalías en cultivos frutales como manzanas, cerezas y uvas. Los hallazgos indicaron que la red Xception logró niveles de confianza óptimos gracias al uso de convoluciones separables, en tanto que MobileNetV2 mantuvo una precisión superior al 99.9% en la detección de zonas necróticas. Este trabajo validó la capacidad computacional de estos modelos para operar en dispositivos móviles, una característica fundamental para el monitoreo de patógenos en entornos tropicales.

Xu, Yoon, Jeong, y Park (2022), propusieron un esquema de aprendizaje por transferencia dual fundamentado en la arquitectura *Vision Transformers* (ViT). La metodología fue evaluada con el conjunto de datos PlantCLEF2022 y obtuvo una exactitud del 86,29 %, aun cuando se utilizó una cantidad reducida de muestras para el entrenamiento. El resultado fue superior al alcanzado por los modelos base tradicionales y mostró que el preentrenamiento autosupervisado puede ser una alternativa útil en estudios fitopatológicos donde resulta difícil recopilar suficientes datos locales.

Valle-Medina et al (2025) evaluaron el uso de Transformadores de Visión (ViT) para la clasificación de enfermedades en hojas de papa. El estudio trabajó con tres categorías: hojas saludables, tizón temprano y tizón tardío, utilizando técnicas de aumento de datos, aprendizaje

por transferencia y ajuste fino. El modelo ViT alcanzó una exactitud de 99,18 % en el conjunto de prueba y un F1 de 98,7 %. Los autores también compararon su desempeño con arquitecturas convolucionales como InceptionV3, ResNet50, VGG16 y VGG19, obteniendo mejores resultados con el modelo basado en transformadores. Este antecedente resulta relevante para la presente investigación porque demuestra que el aprendizaje por transferencia puede utilizarse para clasificar enfermedades foliares a partir de imágenes y confirma la importancia de comparar diferentes arquitecturas antes de seleccionar un modelo para su implementación.

Los estudios revisados señalan que el aprendizaje por transferencia constituye una alternativa adecuada cuando se dispone de una cantidad limitada de imágenes. La diferencia de este proyecto está en el uso de fotografías locales, tomadas en condiciones reales de la Granja Experimental ULEAM, y en la evaluación de un despliegue sin conexión mediante TensorFlow Lite. Esta característica permitió pasar del entrenamiento en Colab a una aplicación móvil funcional.

2.3 Definiciones conceptuales

2.3.1 Inteligencia Artificial y Aprendizaje Profundo

La inteligencia artificial reúne métodos que permiten a un sistema realizar tareas como reconocer patrones o clasificar información. Dentro de este campo, el aprendizaje automático utiliza datos para ajustar un modelo, en lugar de depender únicamente de reglas programadas. Durante el entrenamiento, el algoritmo compara sus predicciones con las etiquetas reales y modifica sus parámetros para reducir el error (Géron, 2023).

Por su parte, el Deep Learning (DL) o Aprendizaje Profundo representa una evolución especializada del ML que utiliza arquitecturas de redes neuronales artificiales compuestas por múltiples capas de procesamiento interconectadas de forma jerárquica. Una de las principales ventajas del aprendizaje profundo es que el modelo puede reconocer por sí mismo las características presentes en una imagen. Durante este proceso, las primeras capas de la red identifican elementos sencillos, como bordes, colores y texturas, que luego son combinados por las capas posteriores para interpretar patrones visuales de mayor complejidad Sarker (2021), de esta manera los especialistas no necesitan definir manualmente cada característica que debe buscarse, porque la red aprende cuáles son las más relevantes a partir de las imágenes proporcionadas.

En la fitosanidad computacional y el monitoreo automatizado de cultivos, el aprendizaje profundo se utiliza para analizar enfermedades vegetales en condiciones reales. Estos modelos pueden trabajar con datos de teledetección y fotografías detalladas de las plantas para reconocer de manera temprana alteraciones en las hojas causadas por hongos. De esta forma, sirven como apoyo a la inspección visual tradicional y ayudan a reducir las diferencias que pueden surgir entre las evaluaciones realizadas por distintas personas (Alruwaili, 2025). Esta capacidad de procesamiento robusto es clave para mitigar las variaciones críticas de iluminación, ruido de fondo y oclusión geométrica que caracterizan a los cultivos agrícolas tropicales en la región litoral ecuatoriana.

2.3.2 Redes Neuronales Convolucionales (CNN)

Las Redes Neuronales Convolucionales representan la arquitectura de Aprendizaje Profundo predominante para el procesamiento de datos con arreglos topológicos bidimensionales, tales como las imágenes digitales. La operación matemática central en estas estructuras es la convolución discreta, la cual consiste en el desplazamiento sistemático de una matriz de pesos de dimensiones reducidas denominada filtro o kernel sobre la imagen de entrada para calcular un producto punto local; este procedimiento genera mapas de características que preservan las propiedades de adyacencia espacial de los datos originales (Alzubaidi, 2021).

El aprendizaje dentro de una CNN ocurre de forma gradual. En las primeras capas se detectan bordes, contrastes y cambios de textura. Las capas intermedias combinan esas señales para formar patrones locales, como manchas o halos. Las capas profundas integran la información y la utilizan para separar las categorías aprendidas (Guo, 2024).

Las CNN comparten los mismos filtros en distintas zonas de la imagen, lo que reduce el número de parámetros y permite reconocer un patrón, aunque cambie de posición. Las operaciones de agrupación disminuyen el tamaño de los mapas y conservan las respuestas más relevantes. Estas propiedades ayudan a trabajar con variaciones moderadas de encuadre, aunque no eliminan la necesidad de fotografías claras (Chollet, 2021).

Para el problema de detección automatizada de la Sigatoka negra, estas características de diseño resultan indispensables. La invarianza traslacional asegura que las estructuras biológicas del hongo *Pseudocercospora fijiensis* sean identificadas con precisión sin importar

el encuadre o la posición de la hoja en la toma del dispositivo móvil. Asimismo, la forma en que las redes neuronales convolucionales procesan las imágenes permite diferenciar los primeros síntomas de la enfermedad, como pequeñas estrías cloróticas y puntos amarillentos, de los daños más avanzados, entre ellos el deterioro celular y las zonas necróticas consideradas en las escalas internacionales de severidad. Así, las CNN reducen la dependencia de métodos manuales basados únicamente en la separación de colores y aprenden patrones visuales que pueden ajustarse mejor a las variaciones de las plantas y a las condiciones agrícolas del Ecuador.

2.3.3 Arquitecturas preentrenadas

Las arquitecturas preentrenadas son redes neuronales que han aprendido previamente características visuales a partir de conjuntos de imágenes de gran tamaño. Posteriormente, este conocimiento puede reutilizarse en una nueva tarea mediante aprendizaje por transferencia, evitando que el entrenamiento tenga que comenzar completamente desde cero. Esta alternativa resulta especialmente conveniente cuando se dispone de una cantidad limitada de imágenes para el problema específico.

MobileNetV2 fue diseñada específicamente para mantener un buen desempeño en dispositivos con recursos limitados. Su arquitectura utiliza bloques residuales invertidos y convoluciones separables en profundidad, con el propósito de reducir la cantidad de operaciones requeridas durante el procesamiento de las imágenes (Sandler, 2022). Esta característica resulta importante para la presente investigación debido a que el modelo final debía integrarse en una aplicación móvil y ejecutarse directamente en un teléfono.

EfficientNet propone una estrategia diferente basada en el escalamiento conjunto de la profundidad, anchura y resolución de la red. Tan y Le (2022), plantean que el equilibrio de estas tres dimensiones permite mejorar la eficiencia del modelo sin aumentar de manera desproporcionada el costo computacional. Por esta razón, EfficientNetB0 fue considerada como una alternativa para comparar su comportamiento frente a MobileNetV2.

Por otra parte, las redes residuales utilizan conexiones de identidad que facilitan el flujo de información y el entrenamiento de arquitecturas profundas. He et al. (2018) demostraron que este tipo de conexiones permite mejorar la propagación de la información y facilita el entrenamiento de redes con una gran cantidad de capas. En este proyecto se utilizó ResNet50V2

como una tercera arquitectura de comparación debido a su mayor capacidad de representación frente a modelos más ligeros.

La selección de una arquitectura no debe basarse únicamente en la profundidad o el tamaño de la red. También es necesario considerar las características del conjunto de datos y el entorno donde se utilizará el modelo. En esta investigación se trabajó con un conjunto reducido de imágenes y se requería que el modelo seleccionado pudiera convertirse posteriormente a TensorFlow Lite para funcionar en un dispositivo móvil. Por esta razón, MobileNetV2, EfficientNetB0 y ResNet50V2 fueron evaluadas bajo la misma distribución de datos antes de seleccionar el modelo final.

Los resultados obtenidos durante el entrenamiento mostraron que MobileNetV2 con ajuste fino ofreció el equilibrio más adecuado entre rendimiento y costo computacional para las condiciones del proyecto. Por lo tanto, la selección final no se realizó únicamente por las características teóricas de la arquitectura, sino también por el comportamiento observado durante la validación y por los requisitos de implementación de la aplicación móvil.

2.3.4 Estrategias de transferencia

Un modelo preentrenado ya cuenta con pesos aprendidos a partir de un conjunto grande de imágenes. Al retirar su clasificador original, puede utilizarse como base para una nueva tarea. MobileNetV2 prioriza la eficiencia, EfficientNetB0 busca equilibrar profundidad y costo computacional, mientras que ResNet50V2 tiene una arquitectura de mayor tamaño. Estas diferencias justificaron su comparación en el proyecto (Sarkar, 2023).

Por su parte, el ajuste fino constituye una estrategia de adaptación más profunda. En este esquema, en lugar de mantener la red base totalmente estática, se procede al descongelamiento selectivo de los últimos bloques convolucionales junto con las nuevas capas de clasificación añadidas. El proceso de entrenamiento se ejecuta de extremo a extremo a lo largo de estas capas seleccionadas utilizando una tasa de aprendizaje sumamente baja. Esta técnica resulta altamente efectiva cuando el nuevo conjunto de datos es de tamaño moderado y comparte similitudes con el dominio original, permitiendo que los filtros de la red adapten sus coeficientes matemáticos a las particularidades geométricas y texturas específicas de las nuevas muestras foliares.

2.3.5 Técnicas de aumento de datos

Las técnicas de aumento de datos consisten en expandir artificialmente los conjuntos de datos limitados mediante la aplicación sistemática de transformaciones geométricas y alteraciones espectrales, en el ámbito geométrico, se emplean operaciones algorítmicas como rotaciones, inversiones espaciales, escalados y deformaciones por sesgo. Por otro lado, las alteraciones espectrales incluyen ajustes dinámicos de iluminación, contraste, saturación cromática y la adición controlada de ruido. El objetivo fundamental de estas operaciones es simular la variabilidad óptica y ambiental que ocurre naturalmente durante la captura de fotografías en el campo, preservando en todo momento la semántica y la integridad visual de la imagen foliar. Esta expansión sintética de la información permite equilibrar la representación de clases minoritarias, como las etapas iniciales de la Sigatoka negra, y resulta indispensable para prevenir el sobreajuste durante el entrenamiento de redes neuronales convolucionales que disponen de un volumen reducido de muestras locales (Martínez & Gómez, 2023).

2.3.6 Frameworks de Aprendizaje profundo

El flujo teórico del framework exige la integración de un mecanismo de reducción dimensional y regularización antes de la clasificación final. El uso de capas de agrupación global promedio minimiza la varianza espacial y el número de parámetros antes de conectar los mapas de características a capas densas con funciones de activación de rectificación lineal. Asimismo, la inclusión de capas de exclusión probabilística mitiga el riesgo de sobreajuste al desactivar un porcentaje de neuronas durante el entrenamiento, mejorando la capacidad de generalización del modelo al evaluar datos foliares en entornos reales (Chollet, 2021).

El proceso teórico de optimización dentro de estos Frameworks se apoya en políticas de regularización dinámica y técnicas de aumento de datos. El aumento de datos aplica transformaciones geométricas y espaciales pseudoaleatorias (rotación, traslación y zoom) sobre las imágenes originales para simular variaciones de iluminación y perspectiva en el campo. El proceso concluye con un control de convergencia mediante detención temprana, deteniendo el entrenamiento cuando la pérdida de validación deja de disminuir, garantizando así un modelo robusto y matemáticamente estable.

2.3.7 *Pseudocercospora fijiensis*

Pseudocercospora fijiensis Morelet cuyo estado reproductivo sexual (teleomorfo) se conoce como *Mycosphaerella fijiensis*, es un ascomiceto folívoro de comportamiento hemibiotrófico que afecta de manera exclusiva a las plantas del género *Musa* (tales como el plátano y el banano Cavendish), siendo el agente biológico causante de la Sigatoka negra. Su ciclo de vida es de naturaleza policíclica y posee una alta capacidad de propagación mediante dispersión anemófila, permitiendo que sus conidios cilíndricos sean arrastrados por corrientes de viento a distancias de hasta tres kilómetros. Al depositarse sobre el tejido vegetal, y bajo condiciones climáticas óptimas de temperatura (entre 27 °C y 30 °C) y alta humedad relativa (85% a 100%), las esporas germinan en un lapso de 12 a 24 horas. Posteriormente, el patógeno penetra de forma mecánica a través de las estomas de la hoja, instaurando una fase necrotrófica donde la liberación de toxinas destruye activamente las células de la planta (Chang, 2021).

2.3.8 Taxonomía y patogénesis

Pseudocercospora fijiensis, cuyo teleomorfo ha sido referido como *Mycosphaerella fijiensis*, pertenece al reino Fungi, filo Ascomycota, clase Dothideomycetes, orden Capnodiales y familia Mycosphaerellaceae, este hongo constituye el agente causal de la Sigatoka negra, una enfermedad foliar de alta relevancia en musáceas debido a su capacidad de reducir el área fotosintéticamente activa de la hoja y afectar el desarrollo normal del cultivo.

Las esporas pueden desplazarse por acción del viento y contribuir a la propagación dentro del cultivo. En ambientes húmedos y cálidos se producen varios ciclos durante un mismo periodo, lo que aumenta la presión de la enfermedad y hace necesario un monitoreo continuo. Este comportamiento epidemiológico favorece un ciclo policíclico, especialmente en ambientes tropicales con alta humedad relativa y temperaturas cercanas a los 28 °C (Stover R. S., 2022).

2.3.9 Ciclo de vida y condiciones favorables

El ciclo de vida de *Pseudocercospora fijiensis* es policíclico, lo que implica la ocurrencia de múltiples ciclos de infección durante un mismo periodo productivo bajo condiciones ambientales favorables. Este proceso inicia con la presencia de conidios

obclavados, generalmente septados, los cuales germinan sobre la superficie foliar cuando existe una humedad relativa superior al 95 %.

La producción de nuevas esporas permite repetir el proceso de infección durante el mismo ciclo productivo. La duración de cada etapa varía con la temperatura, la humedad, la variedad y el manejo del cultivo. Por esta razón, los tiempos descritos en la literatura deben utilizarse como referencia y no como un valor fijo para todas las parcelas (Gilberto, 2022).

2.3.10 Sintomatología foliar

La sintomatología suele describirse mediante una secuencia de estados. Al inicio aparecen puntos o estrías pequeñas y claras; luego las lesiones se alargan y toman tonos marrones. En estados avanzados se forman manchas oscuras con tejido necrótico y varias lesiones pueden unirse. La clasificación utilizada en este proyecto resume esa progresión en tres categorías visuales: sana, moderada y severa (FAO, 2021).

2.3.11 Métodos detección tradicionales

La detección convencional de *Pseudocercospora fijiensis* en campo se sustenta en protocolos de muestreo visual cuantitativo que consisten en el recorrido de transectos diagonales sobre parcelas de una hectárea, evaluando un mínimo de 26 plantas con 20 hojas por sitio de muestreo, específicamente en los sitios foliares 3 y 4, considerados los más representativos del estado sanitario del cultivo. La severidad de la enfermedad se determina mediante la escala de Stover modificada por Gauhl, que asigna valores entre 0 y 7, la valoración se complementa con la revisión de plantas que han florecido recientemente, se calcula el promedio de severidad de las hojas 1 a 5 en grupos de 30 plantas por cada unidad de muestreo, si la inspección visual no permite confirmar el diagnóstico, se realizan pruebas de laboratorio. Una de ellas es la observación con microscopio óptico a 400 aumentos, mediante la cual se pueden reconocer los conidios obclavados de cuatro septos propios del patógeno, el ensayo inmunoenzimático ELISA, con un umbral de densidad óptica de 0,6 a 450 nm, y la técnica de reacción en cadena de la polimerasa convencional con los cebadores ITS1/ITS4, con una sensibilidad de detección de 100 esporas por gramo de tejido foliar, constituyen las herramientas moleculares de mayor precisión diagnóstica disponibles actualmente (Agrosavia, 2023) .

2.3.12 Características IA aplicada al análisis foliar

Las características empleadas por la inteligencia artificial en el análisis de imágenes foliares permiten representar de forma computacional los cambios visuales asociados a la presencia de enfermedades. En este contexto, el procesamiento de color mediante la conversión de espacios RGB a HSV facilita la identificación de variaciones de tonalidad, saturación e intensidad relacionadas con manchas, clorosis y necrosis. Asimismo, índices de vegetación como EXG permiten resaltar la presencia de clorofila y separar áreas sanas de zonas afectadas, mientras que descriptores de textura como GLCM contribuyen a caracterizar patrones de contraste, homogeneidad, entropía y bordes irregulares presentes en lesiones foliares. Sin embargo, en enfoques modernos de visión computacional, las redes neuronales convolucionales reducen la dependencia de una selección manual de características, debido a que aprenden automáticamente representaciones relevantes mediante filtros convolucionales, comúnmente de tamaño 3x3 o 5x5, esta capacidad resulta especialmente útil para la detección de *Pseudocercospora fijiensis*, ya que permite identificar variaciones sutiles en color, forma y textura de las hojas a partir de imágenes capturadas en campo (Guadalima-Inga, 2021).

2.3.13 Impacto agronómico de la Sigatoka negra

La Sigatoka negra disminuye la superficie de la hoja que puede realizar la fotosíntesis, sobre todo cuando las lesiones crecen y terminan uniéndose. Su impacto en el rendimiento varía según el nivel de afectación, la etapa de desarrollo del cultivo y las medidas de manejo utilizadas. Por esta razón, el monitoreo procura identificar los síntomas antes de que una parte considerable de la hoja deje de cumplir su función. Además de afectar las hojas, el manejo de la enfermedad genera gastos relacionados con las actividades de inspección y las medidas necesarias para controlarla. La frecuencia de las aplicaciones varía entre zonas y sistemas productivos, por lo que no es adecuado atribuir una reducción específica de costos a la aplicación sin realizar una evaluación agronómica y económica. El aporte de este proyecto se limita al apoyo visual y al registro de resultados (Stover R. , 2022).

2.3.14 Metodología de desarrollo

El desarrollo de una solución basada en aprendizaje automático requiere un proceso diferente al de una aplicación tradicional, debido a que el comportamiento final del sistema no depende únicamente del código implementado, sino también de la calidad de los datos, el

entrenamiento del modelo y los resultados obtenidos durante su evaluación. Por esta razón, el desarrollo suele realizarse de forma iterativa, permitiendo revisar los resultados y realizar ajustes conforme avanza el proyecto.

En esta investigación, este enfoque permitió organizar el trabajo en etapas relacionadas con la preparación del conjunto de imágenes, el entrenamiento de diferentes arquitecturas preentrenadas, la comparación de sus métricas, el ajuste fino del modelo con mejor comportamiento y su posterior conversión a TensorFlow Lite. Finalmente, el modelo seleccionado fue integrado en una aplicación móvil desarrollada con Flutter para comprobar su funcionamiento en un dispositivo Android.

2.3.15 Prototipo Evolutivo en MLOps

Autores clásicos como Pressman (2010) definieron el prototipado evolutivo como la creación de versiones incrementales que se refinan con el usuario, la literatura moderna redefine este concepto para redes neuronales. Huyen (2022), en su obra *Designing Machine Learning Systems*, establece que el desarrollo de modelos de Deep Learning no es lineal, sino un proceso iterativo continuo donde cada versión del modelo(prototipo)se entrena, evalúa y refina basándose en métricas de error.

Siguiendo la metodología descrita por Géron (2023)para proyectos con TensorFlow/Keras, el desarrollo se estructurará en ciclos iterativos de mejora del modelo MobileNetV2: Prototipo Base (MVP): Implementación de Transfer Learning congelando todas las capas excepto la última, utilizando pesos de imageNet. El primer prototipo se desarrolló para comprobar si era técnicamente posible clasificar las hojas en dos categorías: sanas y enfermas. Posteriormente, se aplicó un ajuste fino o *fine-tuning*. En esta etapa, considerada por Chollet (2021) como importante para especializar el modelo, se descongelaron los últimos bloques convolucionales con el fin de adaptar la red a las texturas características de *Mycosphaerella fijiensis*. Finalmente, se realizaron ajustes progresivos en hiperparámetros como la tasa de aprendizaje y el tamaño del lote (*batch size*), tomando como referencia los resultados de la matriz de confusión para reducir la cantidad de falsos negativos.

2.4 Conclusiones del marco teórico

La revisión realizada permitió establecer que el aprendizaje por transferencia representa una alternativa adecuada para la clasificación de imágenes cuando se dispone de un conjunto de datos reducido. Este enfoque facilita aprovechar modelos previamente entrenados y adaptarlos a nuevas tareas, disminuyendo la necesidad de desarrollar una red neuronal desde cero.

En cuanto a *Pseudocercospora fijiensis*, se identificó que la Sigatoka negra presenta cambios visibles en las hojas a medida que avanza su nivel de afectación. Estas variaciones permiten diferenciar estados como sano, moderado y severo, los cuales pueden ser utilizados como referencia para el análisis de imágenes mediante técnicas de visión por computador.

También se determinó que la identificación tradicional de la enfermedad depende principalmente de la inspección visual y de la experiencia de quien realiza la evaluación. Debido a esto, las herramientas basadas en inteligencia artificial pueden utilizarse como un apoyo adicional durante el monitoreo, sin reemplazar el criterio de un profesional del área agronómica.

Finalmente, la metodología basada en un Prototipo Evolutivo dentro de un proceso MLOps permitió organizar el desarrollo en etapas sucesivas de preparación de datos, entrenamiento, evaluación y ajuste. Este enfoque resultó apropiado para el proyecto, ya que permitió revisar progresivamente el comportamiento del modelo antes de su integración en la aplicación móvil.

3 CAPÍTULO III: MARCO INVESTIGATIVO

3.1 Introducción

Este capítulo describe la metodología empleada para el desarrollo y evaluación de un modelo basado en aprendizaje por transferencia orientado a la clasificación de imágenes de hojas de plátano en las categorías sana, Sigatoka moderada y Sigatoka severa. Asimismo, se presentan los tipos y métodos de investigación, las fuentes de información, la población seleccionada y los instrumentos utilizados para la recolección de datos.

La investigación fue de tipo aplicada, con un diseño no experimental y un enfoque mixto en el que predominó el componente cuantitativo. Durante el estudio no se aplicaron fungicidas, fertilizantes ni otros tratamientos destinados a modificar el estado de las plantas. Los ajustes realizados en la tasa de aprendizaje, el número de épocas y las capas entrenables correspondieron exclusivamente al proceso de entrenamiento de los modelos.

El componente cualitativo permitió recopilar información relacionada con las actividades de monitoreo y las necesidades identificadas para la herramienta tecnológica. Por su parte, el componente cuantitativo comprendió la organización del conjunto de imágenes, el entrenamiento de los modelos y la evaluación de su desempeño mediante las métricas establecidas en el estudio. Ambos componentes permitieron relacionar el desarrollo técnico de la solución con el contexto en el que fue planteada.

3.2 Tipos y métodos de investigación

3.2.1 Investigación Aplicada

Según Baena Paz (2021), la investigación aplicada se enfoca en usar los conocimientos teóricos que ya existen para resolver problemas prácticos de la vida real, la finalidad no es plantear nuevas teorías, sino aplicar los conocimientos y las tecnologías disponibles para mejorar procesos o atender necesidades concretas de un sector, buscando que los resultados obtenidos tengan una utilidad para la sociedad.

En este proyecto se aplicaron conocimientos relacionados con el aprendizaje por transferencia y otras técnicas de inteligencia artificial para abordar un problema fitosanitario específico: la clasificación de imágenes de hojas de plátano según su nivel de afectación por *Pseudocercospora fijiensis*. En lugar de desarrollar una red neuronal desde cero, se adaptaron

arquitecturas preentrenadas a las características del conjunto de imágenes recopilado. Este enfoque permitió desarrollar una solución tecnológica orientada al contexto de la Granja Experimental ULEAM.

3.2.2 Investigación no Experimental

De acuerdo con Arias-González (2023), la investigación no experimental se caracteriza por estudiar los fenómenos en su contexto natural, sin manipular deliberadamente las variables de investigación. Bajo este enfoque, la información se observa, recopila y analiza sin aplicar tratamientos o intervenciones controladas sobre el objeto de estudio.

En esta investigación no se modificaron las condiciones de las plantas ni se aplicaron fungicidas, fertilizantes u otros tratamientos con el propósito de alterar el desarrollo de la enfermedad. Las hojas fueron fotografiadas en las condiciones en las que se encontraban durante la recolección de las imágenes. Los ajustes realizados en los hiperparámetros, como la tasa de aprendizaje, el número de épocas y las capas entrenables, correspondieron exclusivamente al proceso de entrenamiento de los modelos y no constituyeron una manipulación experimental de las variables agrícolas.

3.2.3 Investigación Mixta

La investigación mixta integra componentes cuantitativos y cualitativos con el propósito de analizar un fenómeno desde diferentes perspectivas. El componente cuantitativo permite trabajar con datos numéricos y métricas, mientras que el componente cualitativo facilita la comprensión de percepciones, experiencias y características relacionadas con el contexto de estudio. De acuerdo con Hernández Sampieri y Mendoza Torres (2023), la integración de ambos enfoques permite complementar los resultados cuantificables con información contextual relevante para la investigación.

En este proyecto se aplicó un enfoque mixto con predominio cuantitativo. El componente cuantitativo comprendió la organización del conjunto de imágenes, el entrenamiento, la validación y la evaluación de MobileNetV2, EfficientNetB0 y ResNet50V2. El desempeño de los modelos se analizó mediante métricas como exactitud, exactitud balanceada, precisión, sensibilidad, F1 macro y pérdida de validación, además de la matriz de confusión.

El componente cualitativo se desarrolló mediante la entrevista realizada al profesional del área agronómica, cuya información permitió conocer aspectos relacionados con el monitoreo de las hojas y las características esperadas para una herramienta móvil de apoyo. De esta manera, ambos componentes se utilizaron de forma complementaria para relacionar los resultados técnicos del modelo con el contexto de aplicación.

3.2.4 Método Analítico

Según Albornoz Zamora (2023) , el método analítico permite estudiar un fenómeno mediante la separación de sus componentes, con el propósito de examinar sus características y posteriormente relacionarlas para comprender el objeto de estudio de manera integral.

En esta investigación se empleó el método analítico para examinar por separado los principales componentes involucrados en el desarrollo del modelo, entre ellos el conjunto de datos, el preprocesamiento de las imágenes, las arquitecturas evaluadas, el proceso de entrenamiento, la validación y la conversión a TensorFlow Lite. Este análisis permitió identificar las fortalezas y limitaciones observadas en cada etapa y realizar los ajustes necesarios durante el desarrollo de la solución.

Asimismo, se estudiaron individualmente las métricas obtenidas por cada arquitectura, entre ellas la exactitud, exactitud balanceada, precisión, sensibilidad, F1 macro y pérdida de validación. Este análisis permitió comparar el comportamiento de los modelos y sustentar la selección de MobileNetV2 para su posterior conversión a TensorFlow Lite e integración en la aplicación móvil.

3.2.5 Método deductivo

Según Sampieri y Torres (2023), el método deductivo parte de principios y conocimientos generales para aplicarlos al análisis de situaciones específicas. Este razonamiento permite utilizar fundamentos teóricos previamente establecidos como base para estudiar un problema particular y contrastarlos con los resultados obtenidos durante la investigación.

En este proyecto, el método deductivo se aplicó al partir de los fundamentos generales del aprendizaje profundo, las redes neuronales convolucionales y el aprendizaje por

transferencia para abordar un problema específico de clasificación de imágenes de hojas de plátano. A partir de estos principios se seleccionaron las arquitecturas MobileNetV2, EfficientNetB0 y ResNet50V2 para su entrenamiento y evaluación con el conjunto de imágenes recopilado.

Posteriormente, los resultados obtenidos mediante las métricas establecidas permitieron comparar el desempeño de las tres arquitecturas y seleccionar MobileNetV2 para su conversión a TensorFlow Lite e integración en la aplicación móvil.

3.3 Fuentes de información de datos

3.3.1 Encuestas

La encuesta es una técnica de recolección de datos que permite obtener información de un grupo de participantes mediante un cuestionario estructurado. Su aplicación facilita la organización y el análisis de las respuestas obtenidas, especialmente cuando se utilizan preguntas cerradas y escalas previamente definidas (Blanco, 2024).

En esta investigación, la encuesta se aplicó a 25 estudiantes de la carrera de Agropecuaria de la ULEAM, Extensión El Carmen. El instrumento estuvo compuesto por 10 preguntas cerradas orientadas a conocer aspectos relacionados con el monitoreo de las hojas de plátano, la identificación visual de la Sigatoka negra, las dificultades percibidas durante la observación de síntomas y la aceptación de herramientas tecnológicas como apoyo a estas actividades.

Las preguntas utilizaron opciones de respuesta cerrada, escalas de frecuencia, escalas tipo Likert y alternativas de sí o no. La información obtenida se utilizó para describir las percepciones de los participantes y complementar la definición de las características funcionales de la aplicación móvil.

3.3.2 Entrevista

La entrevista es una técnica de recolección de datos que permite obtener información directa de un participante mediante una interacción guiada por preguntas previamente establecidas. Su utilización en investigaciones con componente cualitativo facilita la

recopilación de experiencias, percepciones y conocimientos relacionados con el contexto estudiado (Huamán Flores, 2023).

En esta investigación se realizó una entrevista semiestructurada al Ing. Agrónomo Paul Gonzáles el 10 de junio de 2026. La selección del entrevistado respondió a su conocimiento del área agronómica y de las actividades relacionadas con el monitoreo fitosanitario de los cultivos.

La guía estuvo compuesta por cinco preguntas abiertas orientadas a conocer las prácticas utilizadas para observar las hojas de plátano, las dificultades encontradas durante la identificación visual de la Sigatoka negra y las características consideradas relevantes para una herramienta tecnológica de apoyo. La información obtenida se utilizó como componente cualitativo para complementar los resultados de la encuesta y contribuir a la definición de requerimientos de la aplicación móvil.

3.4 Estrategia operacional para la recolección de datos

3.4.1 Población

La población corresponde al conjunto de personas que poseen las características relacionadas con el objeto de estudio y sobre las cuales se obtiene la información necesaria para la investigación. Su delimitación debe considerar criterios vinculados con el contexto, las características de los participantes y su relación con el problema estudiado (Hernández Sampieri R. F., 2021).

Para la aplicación de la encuesta, la población estuvo conformada por 25 estudiantes de la carrera de Agropecuaria de la ULEAM, Extensión El Carmen, que realizan actividades académicas y prácticas relacionadas con el área agrícola. Se consideró a este grupo debido a su contacto con las actividades desarrolladas en la Granja Experimental y a su posibilidad de utilizar herramientas tecnológicas como apoyo durante las prácticas de campo.

3.4.2 Muestra

La muestra es un subconjunto representativo de la población seleccionado mediante técnicas estadísticas que permiten inferir características del universo total. El muestreo probabilístico garantiza representatividad mediante selección al azar, mientras que el no

probabilístico que es el que usaremos por las limitaciones prácticas. Controlar el error muestral menor al 5% y alinear el tipo de muestreo con los objetivos de investigación. (Capa Santos, 2021).

En esta investigación se utilizó un muestreo no probabilístico intencional. La muestra estuvo conformada por 25 estudiantes de la carrera de Agropecuaria de la ULEAM, Extensión El Carmen, seleccionados por su relación con las actividades académicas y prácticas del área agrícola y por su disponibilidad para participar en la aplicación de la encuesta.

La selección de los participantes respondió al interés de obtener información sobre el uso de herramientas tecnológicas, las dificultades percibidas durante el monitoreo visual de enfermedades foliares y la aceptación de una aplicación móvil como herramienta de apoyo. Debido a que se utilizó un muestreo no probabilístico, no se estableció un margen de error estadístico ni se aplicó una fórmula probabilística para determinar el tamaño de la muestra.

3.4.3 Análisis de las herramientas de recolección de datos a utilizar

3.4.3.1 Encuesta

La encuesta se dirigió a los estudiantes de la carrera de Agropecuaria de la ULEAM, Extensión El Carmen, que mantienen relación con las actividades académicas y prácticas desarrolladas en el área agrícola. El instrumento tuvo como finalidad conocer su percepción sobre las prácticas de monitoreo fitosanitario y el posible uso de una aplicación móvil como herramienta de apoyo.

El cuestionario estuvo conformado por diez preguntas cerradas, organizadas en cuatro dimensiones: uso de tecnología, percepción de la agricultura de precisión, limitaciones de la inspección visual y aceptación de una aplicación móvil. Para las respuestas se utilizaron opciones de selección única, escalas de valoración y alternativas de tipo sí/no, de acuerdo con la naturaleza de cada pregunta.

La información recopilada permitió realizar un análisis descriptivo de las respuestas e identificar aspectos relacionados con el uso de herramientas digitales, las dificultades percibidas durante la observación de síntomas de la Sigatoka negra y la aceptación de una solución tecnológica que apoye el monitoreo de las hojas de plátano.

3.4.3.2 Entrevista

La entrevista semiestructurada estuvo dirigida al Ing. Agrónomo Paul Gonzáles con el propósito de recopilar información relacionada con el monitoreo fitosanitario de las hojas de plátano y conocer su criterio profesional respecto al uso de una herramienta tecnológica de apoyo.

El instrumento estuvo compuesto por cinco preguntas abiertas. Estas abordaron aspectos relacionados con la presencia de la Sigatoka negra, la valoración visual de los niveles de afectación, la influencia de las condiciones de campo, la posible utilidad de la inteligencia artificial y las características que debería considerar una aplicación móvil para ser utilizada como herramienta complementaria durante el monitoreo.

La información obtenida permitió complementar los resultados de la encuesta y aportar criterios del contexto agronómico para la definición de requerimientos de la aplicación. La entrevista no se utilizó para medir el rendimiento del modelo, sino como fuente cualitativa de información para comprender las necesidades del entorno de aplicación.

3.4.3.3 Estructura de los instrumentos de recolección de datos aplicados

La encuesta estuvo estructurada por diez preguntas cerradas orientadas a cuatro dimensiones: uso de tecnología, percepción de la agricultura de precisión, limitaciones de la evaluación visual y aceptación de una aplicación móvil. Las opciones de respuesta incluyeron escalas de frecuencia, escalas tipo Likert y alternativas de sí o no, lo que permitió realizar un análisis descriptivo de las respuestas obtenidas.

La entrevista semiestructurada estuvo conformada por cinco preguntas abiertas dirigidas al Ing. Agrónomo Paul Gonzáles. Estas preguntas abordaron aspectos relacionados con la presencia de la Sigatoka negra, la valoración visual de los niveles de afectación, las condiciones del trabajo de campo, la utilidad esperada de una herramienta basada en inteligencia artificial y las características consideradas necesarias para el uso de la aplicación móvil.


3.4.4 Plan de recolección de datos


Tabla 1: Tabla de recolección de datos

ACTIVIDAD	RESPONSABLES	FECHA
Entrevista al Coordinador del Vivero Lastenia	Anthony Pita Diego Pilataxi Jean Zambrano	10/06/2026
Encuesta a los estudiantes de Agropecuaria de la Uleam extensión El Carmen	Anthony Pita Diego Pilataxi Jean Zambrano	20/05/2026


3.5 Análisis y presentación de resultados

Tabla 2: Resultado de la encuesta

PREGUNTA	GRAFICOS	INTERPRETACION
1. ¿Cómo califica el nivel de integración de herramientas digitales en las prácticas agrícolas actuales de la Extensión El Carmen?	 ● Muy avanzado 5 ● Adecuado 14 ● Insuficiente 6 ● Inexistente 0	Los resultados evidencian un escenario de transición y una clara ventana de oportunidad en la Extensión El Carmen, aunque la percepción general tiende a considerar que las herramientas digitales vigentes, cumplen con un rol básico aceptable, existe un sector crítico que identifica una insuficiencia o ausencia total de estas tecnologías en la cotidianidad del campo.

PREGUNTA	GRAFICOS	INTERPRETACION
2. ¿Qué importancia tiene para su formación profesional, el aprendizaje de soluciones basadas en Agricultura de Precisión?	● Crucial para el mercado laboral 8 ● Importante para la especializa... 16 ● Complementaria, pero no ese... 1 ● Irrelevante para mi perfil 0 	Existe una marcada conciencia estudiantil y profesional respecto a las demandas del entorno laboral moderno, la comunidad académica no percibe a la Agricultura de Precisión como un complemento aislado o secundario, sino como un eje estratégico fundamental para su especialización y competitividad en el mercado.
3. ¿Cuál considera que es la principal ventaja de utilizar aplicaciones con Inteligencia Artificial para el monitoreo de cultivos?	● Reducción del margen de erro... 7 ● Optimización del tiempo en pr... 12 ● Acceso a diagnósticos técnico... 6 ● Registro digital de datos histór... 0 	Las opiniones de los participantes indican que el ahorro de tiempo es una necesidad durante las jornadas de campo. En este contexto, la inteligencia artificial puede apoyar el monitoreo, agilizar la revisión de las hojas y reducir la carga de trabajo.
4. Ante el desarrollo de una herramienta tecnológica, ¿cuál considera que es el mayor reto para su adopción entre los estudiantes?	● Limitaciones de hardware (telé... 10 ● Falta de capacitación técnica e... 7 ● Dificultad de acceso a internet... 7 ● Resistencia al reemplazo de m... 1 	Este resultado aporta un criterio metodológico importante para definir la arquitectura del software. El reconocimiento de que el hardware local está limitado por teléfonos de gama baja, sumado a las dificultades de conectividad e infraestructura en las

PREGUNTA	GRAFICOS	INTERPRETACION
		zonas de práctica, impone restricción técnica insoslayable.
5. ¿Qué función considera más útil en una aplicación móvil destinada al trabajo diario en la Granja Experimental?	● Interfaz intuitiva y de rápida n... 8 ● Capacidad de funcionamiento... 11 ● Alta precisión en la identificaci... 6 ● Generación de reportes autom... 0 	Las respuestas de los usuarios muestran que la aplicación debe funcionar de manera autónoma durante las actividades de campo. Debido a que la conexión a internet puede ser limitada en la Granja Experimental, se considera necesario que el análisis se realice directamente en el dispositivo. También se requiere una interfaz sencilla y ágil, que permita trasladar la herramienta entre los lotes y obtener la clasificación en poco tiempo mientras se inspeccionan los cultivos
6. ¿Cree usted que la universidad debería priorizar el desarrollo de software propio, para la gestión de sus procesos agropecuarios?	● Totalmente de acuerdo 17 ● De acuerdo 6 ● En desacuerdo 2 ● Totalmente en desacuerdo 0	Las respuestas obtenidas reflejan una percepción favorable entre los participantes hacia el desarrollo de software propio para apoyar los procesos agropecuarios de la Universidad Laica Eloy Alfaro de Manabí. Este resultado evidencia interés por fortalecer el uso de

PREGUNTA	GRAFICOS	INTERPRETACION
		soluciones tecnológicas desarrolladas dentro del contexto institucional.
7. ¿Cuál es su método principal para identificar la Sigatoka Negra (<i>Pseudocercospora fijiensis</i>) en las hojas de plátano?	● Inspección visual basada en la ... 16 ● Comparación con guías y atla... 4 ● Consulta directa con docentes... 4 ● Aún no logra identificarla con ... 1 	El análisis del estado actual del monitoreo fitosanitario revela una alta vulnerabilidad operativa. La dependencia casi exclusiva de la inspección visual basada únicamente en la experiencia empírica del observador confirma que el diagnóstico actual de la <i>Pseudocercospora fijiensis</i> es altamente subjetivo. Al no estar estandarizado ni apoyado de forma masiva en herramientas técnicas o consultas constantes, el cultivo queda expuesto a interpretaciones erróneas que varían entre cada evaluador.
8. En sus prácticas de campo, ¿qué nivel de dificultad encuentra para diferenciar visualmente la Sigatoka temprana de una deficiencia nutricional?	● Dificultad muy alta 5 ● Dificultad moderada 13 ● Dificultad baja 4 ● Ninguna dificultad 3 	Esta respuesta expone la limitación real del ojo humano frente a la patología y valida el núcleo técnico de la tesis. La manifestación de una recurrente dificultad (moderada a alta) para distinguir los estadios iniciales de la enfermedad de un problema de nutrición

PREGUNTA	GRAFICOS	INTERPRETACION
		foliar demuestra que el método visual empírico es propenso a fallar cuando el hongo recién ataca. Aquí es donde se justifica plenamente el uso de redes neuronales convolucionales como MobileNetV2, cuya capacidad de extracción de características profundas puede detectar patrones imperceptibles para el estudiante o técnico en el campo.
9. ¿Cuál considera que es el factor determinante para que esta enfermedad cause pérdidas económicas tan severas en la región?	● Diagnóstico tardío por método... 13 ● Condiciones climáticas extrem... 9 ● Resistencia del hongo a los fungicidas... 1 ● Falta de protocolos de monitoreo... 2 	El problema económico de la zona está directamente ligado a una brecha temporal en el diagnóstico, los usuarios identifican con claridad que las pérdidas severas no se deben únicamente al clima o a la agresividad del hongo, sino al retraso crítico provocado por los métodos manuales actuales.
10. ¿Estaría dispuesto a validar su criterio técnico, comparándolo con el diagnóstico sugerido por una Inteligencia Artificial?	● Totalmente dispuesto 9 ● Muy dispuesto 9 ● Poco dispuesto 7 ● Nada dispuesto 0	El cierre del análisis demuestra una excelente viabilidad de implantación y una bajísima resistencia al cambio tecnológico. Existe una confianza y apertura previa por parte de los operadores para adoptar la Inteligencia Artificial como un asistente de

PREGUNTA	GRAFICOS	INTERPRETACION
		validación técnica en sus decisiones de campo. Esto asegura que la solución basada en <i>Transfer Learning</i> no solo atacará una problemática real y urgente, será recibida con entusiasmo por los usuarios que interactuarán directamente con el sistema en la Granja Experimental.

3.5.1.1 Análisis de entrevista realizada al ingeniero Paul Gonzáles

Tabla 3: Análisis de entrevista

PREGUNTA	RESPUESTA	INTERPRETACIÓN
¿Cuál es el estado actual de la incidencia de la Sigatoka negra (<i>Pseudocercospora fijiensis</i>) en los lotes de plátano de la Granja Experimental, y qué estrategias de control (químicas, biológicas o culturales) se aplican actualmente para mitigar su impacto?	La incidencia en los lotes de la Granja Experimental es continua, ya que las condiciones endémicas de la zona costera favorecen la propagación del hongo. Actualmente, dependemos de un monitoreo netamente visual. Como estrategias de control, aplicamos un manejo cultural estricto mediante el deshoje sanitario o cirugías en las hojas para bajar la carga de inóculo, acompañado de control de malezas.	La respuesta del Ingeniero evidencia que, aunque existen protocolos de manejo integrado establecidos, los métodos tradicionales de inspección visual carecen de la agilidad necesaria y representan una carga operativa significativa, lo que fundamenta metodológicamente la urgencia de implementar un sistema computacional basado en visión artificial que permita estandarizar la evaluación, minimizando la subjetividad humana y reduciendo el tiempo de

PREGUNTA	RESPUESTA	INTERPRETACIÓN
		respuesta en las parcelas agrícolas.
Durante el monitoreo diario, ¿cómo determinan visualmente la severidad de la enfermedad? Por ejemplo, ¿qué hojas revisan con mayor frecuencia y cuáles estadios de las escalas de Stover o Fouré son más difíciles de reconocer oportunamente?	Durante las inspecciones de campo se revisan principalmente las hojas más funcionales de la planta, que suelen corresponder a las posiciones 3, 4 y 5 de la escala de Stover modificada. La identificación se vuelve más complicada en los estadios 1 y 2, porque los primeros síntomas apenas se observan como pequeños puntos o estrías en la hoja. Si estos primeros síntomas no se identifican a tiempo y la enfermedad alcanza los niveles 4 o 5, la hoja ya presenta necrosis avanzada y una pérdida considerable del área fotosintética.	De acuerdo con la información agronómica proporcionada, la incapacidad fisiológica del ojo humano para discriminar de forma consistente los estadios tempranos de la enfermedad genera un impacto económico directo. Esta limitación justifica plenamente la utilización de arquitecturas de aprendizaje profundo (<i>Deep Learning</i>), las cuales poseen la capacidad matemática de extraer descriptores visuales de nivel microscópico, garantizando una detección preventiva oportuna.
Considerando el clima húmedo de El Carmen y las variaciones en el manejo del cultivo (como deficiencias nutricionales de magnesio o presencia de polvo y luz solar directa), ¿de qué manera alteran estos factores la apariencia de las hojas de plátano y cómo podrían confundir a un observador o a un sistema de visión artificial?	Las condiciones climáticas y las prácticas de manejo en El Carmen pueden provocar alteraciones visuales que dificultan la evaluación de las plantas, por ejemplo, la falta de magnesio produce clorosis o amarillamiento en los bordes de las hojas, un síntoma que puede confundirse con el halo inicial de la Sigatoka. Durante la época seca, la acumulación de polvo y las quemaduras ocasionadas por la exposición directa al sol también pueden generar manchas que no	La identificación de estos factores ambientales disruptivos, subraya la complejidad geométrica y cromática que enfrentará el modelo predictivo, esto valida de manera técnica la inclusión de metodologías de aumento de datos durante el entrenamiento de la red neuronal convolucional.

PREGUNTA	RESPUESTA	INTERPRETACIÓN
	corresponden a la enfermedad.	
Para validar la precisión del modelo de Transfer Learning, ¿de qué manera considera viable que colaboremos en la granja para comparar el diagnóstico generado por la IA frente a su criterio como experto fitopatólogo en tiempo real?	Una forma práctica de validar la aplicación sería seleccionar un lote de la granja y evaluar las mismas plantas mediante dos procedimientos. Primero, yo revisaría visualmente cada hoja y registraría su estado de acuerdo con la escala de severidad; al mismo tiempo, usted tomaría las fotografías y las procesaría con la aplicación móvil. Luego compararíamos los resultados para determinar cuánto coinciden las clasificaciones del modelo con mi valoración técnica, sobre todo en las hojas cuyos síntomas iniciales todavía no se observan con claridad.	Este trabajo conjunto permitiría probar el prototipo de forma controlada utilizando información recopilada directamente en la plantación. La valoración del especialista se tomaría como referencia para revisar la exactitud, la precisión y la sensibilidad alcanzadas por el modelo. Con esta comparación sería posible conocer mejor su desempeño y determinar si está preparado para evaluarse posteriormente con una mayor cantidad de plantas.
Si implementáramos este modelo en una aplicación móvil para el monitoreo de la Sigatoka negra, ¿qué requisitos de facilidad de uso, velocidad de diagnóstico y tipo de recomendaciones técnicas consideraría indispensables para que la herramienta sea realmente útil y adoptada por el personal de la ULEAM y los productores de la zona?	Para que una herramienta tecnológica sea realmente útil durante el trabajo agrícola, debe ser sencilla y responder con rapidez, el usuario debería tomar la fotografía y recibir el resultado en pocos segundos, acompañado de una indicación visual fácil de comprender, la aplicación necesita funcionar sin conexión a internet, ya que en varias zonas rurales de Manabí la cobertura es inestable o inexistente. Si cada imagen tuviera que enviarse a un servidor	Las exigencias operativas señaladas por el profesional refuerzan y justifican de forma contundente la decisión arquitectónica central del sistema: la optimización del modelo hacia el formato TensorFlow Lite. Al asegurar que la inferencia de la red neuronal se ejecute de manera autónoma y local (<i>offline</i>) en el hardware del teléfono móvil, la aplicación supera las barreras de infraestructura de telecomunicaciones, garantizando su escalabilidad y uso real

PREGUNTA	RESPUESTA	INTERPRETACIÓN
	para ser procesada, su uso en el campo sería muy limitado.	entre los productores plataneros de la región.

3.5.2 Informe final del análisis de los datos

Los resultados obtenidos mediante la encuesta y la entrevista permitieron identificar que la revisión de las hojas en el contexto estudiado se apoya principalmente en la observación visual y en la experiencia de las personas relacionadas con las actividades agrícolas. Esta situación se evidenció en la pregunta 7 de la encuesta, relacionada con el método principal utilizado para identificar la Sigatoka negra, y en la pregunta 8, orientada a conocer el nivel de dificultad para diferenciar visualmente síntomas de Sigatoka de una deficiencia nutricional. En la entrevista, este aspecto también se evidenció en las preguntas 1 y 2, en las que el Ing. Agrónomo Paul Gonzáles indicó que el monitoreo realizado en la granja es principalmente visual y explicó las dificultades para reconocer determinados niveles de afectación.

Asimismo, se identificó una disposición favorable hacia el uso de herramientas tecnológicas como apoyo durante las actividades de monitoreo. Este aspecto se relacionó con la pregunta 3 de la encuesta, referente a las ventajas del uso de aplicaciones con inteligencia artificial; la pregunta 5, sobre las funciones consideradas más útiles en una aplicación móvil; y la pregunta 10, relacionada con la disposición para comparar el criterio técnico con el resultado sugerido por una herramienta de inteligencia artificial. Este resultado se complementó con la pregunta 5 de la entrevista, en la que se señalaron como características importantes que la aplicación fuera sencilla, rápida y presentara resultados fáciles de comprender. Estos hallazgos respaldaron el desarrollo de la aplicación móvil como herramienta complementaria a la inspección visual.

La necesidad de utilizar la aplicación en condiciones donde la conectividad puede ser limitada se evidenció principalmente en las preguntas 4 y 5 de la encuesta, relacionadas con las dificultades para la adopción de herramientas tecnológicas y con las funciones requeridas para el trabajo en la Granja Experimental. De manera más específica, en la pregunta 5 de la entrevista, el profesional indicó que la aplicación debía funcionar sin conexión a internet debido a las limitaciones de cobertura presentes en determinadas zonas rurales. En respuesta a

este requerimiento, el modelo seleccionado fue convertido a TensorFlow Lite para permitir la ejecución de la inferencia directamente en el dispositivo móvil.

4 CAPÍTULO IV: MARCO PROPOSITIVO

4.1 Introducción

Este capítulo presenta la propuesta tecnológica desarrollada para apoyar la clasificación visual de hojas de plátano asociadas con *Pseudocercospora fijiensis* en la Granja Experimental ULEAM, Extensión El Carmen. La solución se diseñó como complemento del monitoreo realizado en campo, considerando que la valoración visual puede presentar dificultades al diferenciar estados de afectación con características semejantes.

El desarrollo se organizó mediante un enfoque de Prototipo Evolutivo en MLOps estructurado por sprints. Este proceso permitió preparar los datos, entrenar diferentes arquitecturas, evaluar su rendimiento y realizar ajustes progresivos a partir de las métricas obtenidas durante cada etapa.

Para el desarrollo del clasificador se evaluaron MobileNetV2, EfficientNetB0 y ResNet50V2 mediante aprendizaje por transferencia. Después de comparar su desempeño, MobileNetV2 fue seleccionada como arquitectura principal. Posteriormente, el modelo fue

convertido al formato TensorFlow Lite e integrado en una aplicación móvil desarrollada con Flutter.

En este capítulo se describen los recursos utilizados, las historias de usuario, la arquitectura del sistema, los requerimientos funcionales y no funcionales, las tecnologías empleadas y la planificación de los sprints. También se documentan las etapas relacionadas con la preparación de las imágenes, el entrenamiento, la evaluación y el despliegue del modelo en el dispositivo móvil.

4.2 Descripción de la propuesta

La propuesta consistió en el desarrollo de una solución basada en aprendizaje por transferencia para clasificar imágenes de hojas de plátano en tres categorías: sana, Sigatoka moderada y Sigatoka severa. Para determinar la arquitectura más adecuada se evaluaron MobileNetV2, EfficientNetB0 y ResNet50V2 bajo las mismas condiciones de entrenamiento y evaluación.

A partir de los resultados obtenidos se seleccionó MobileNetV2 como modelo principal. Posteriormente, el modelo fue convertido al formato TensorFlow Lite para integrarlo en una aplicación móvil desarrollada con Flutter. Durante este proceso se realizaron tareas de preparación y redimensionamiento de imágenes, aumento de datos, entrenamiento, validación y evaluación del modelo.

La aplicación permite capturar fotografías mediante la cámara o seleccionar imágenes desde la galería. Antes de ejecutar la clasificación se realiza una validación de la entrada para comprobar que la imagen corresponda a una hoja de plátano. Cuando la imagen es aceptada, el clasificador genera una de las tres categorías definidas y muestra al usuario el porcentaje de confianza asociado al resultado.

El sistema también permite almacenar localmente los resultados para consultar posteriormente el historial de análisis. Tanto la validación como la clasificación se ejecutan directamente en el dispositivo móvil mediante TensorFlow Lite. La herramienta fue desarrollada como apoyo al monitoreo visual de las hojas y no como sustituto de la evaluación realizada por un profesional del área agronómica.

4.3 Determinación de recursos

Para el desarrollo de la propuesta tecnológica fue necesario identificar los recursos humanos, tecnológicos y económicos que intervinieron en cada una de las etapas del proyecto. Estos recursos permitieron realizar la preparación de las imágenes, el entrenamiento y evaluación de los modelos, la selección de la arquitectura con mejor desempeño y su posterior integración en la aplicación móvil.

Desde el punto de vista técnico, se consideraron herramientas para el procesamiento de imágenes, el entrenamiento de redes neuronales convolucionales, la aplicación de aprendizaje por transferencia, la conversión del modelo a TensorFlow Lite y el desarrollo de la aplicación en Flutter. Cada recurso cumplió una función específica dentro del proceso de construcción y despliegue del sistema.

La planificación de estos recursos permitió organizar de manera estructurada las actividades necesarias para desarrollar el modelo de clasificación y la aplicación móvil. En los siguientes apartados se describen los recursos humanos, tecnológicos y económicos utilizados durante la ejecución de la propuesta.

4.3.1 Humanos

Tabla 4: Recursos Humanos

RECURSO	FUNCIÓN	ACTIVIDADES
Anthony Adrian Pita Cedeño	Desarrollador	Organizar el conjunto de imágenes, preparación de datos, entrenamiento del modelo basado en MobileNetV2, evaluación de resultados, optimización con TensorFlow Lite.
Ing. Carlos López	Tutor académico	Responsable de orientar el desarrollo metodológico y técnico del proyecto, revisar los avances presentados, emitir observaciones académicas

		y acompañar el proceso de construcción de la propuesta conforme a los objetivos de la investigación.
--	--	--

4.3.2 Tecnológicos

Tabla 5: Recursos Tecnológicos

RECURSOS	DESCRIPCIÓN
Computadora	procesador AMD Ryzen 7 7445HS, memoria RAM de 16 GB, tarjeta gráfica NVIDIA GeForce RTX 4050 Laptop y sistema operativo Windows 11 Home de 64 bits
Dispositivo Android	Teléfono utilizado para probar cámara, galería, inferencia local e historial de la aplicación.
Google colab	Entorno utilizado para auditar las imágenes, entrenar los modelos, comparar arquitecturas y convertirlos a TensorFlow Lite.
Python.	Lenguaje de programación empleado para el desarrollo del modelo de inteligencia artificial, procesamiento de imágenes, entrenamiento, validación y generación de resultados.
TensorFlow.	Biblioteca principal de aprendizaje automático utilizada para implementar el modelo basado en Transfer Learning y realizar el entrenamiento de la red neuronal convolucional.
Keras.	Interfaz integrada con TensorFlow que facilita la construcción, configuración y entrenamiento del modelo.
MobileNetV2.	Arquitectura convolucional preentrenada que se utilizó como base del modelo por su capacidad para reconocer características visuales importantes en las imágenes.
TensorFlow Lite.	Formato empleado para ejecutar directamente en dispositivos Android tanto el validador de hojas como el

RECURSOS	DESCRIPCIÓN
	modelo encargado de clasificar la Sigatoka.
Flutter	Herramienta empleada para crear la aplicación móvil y mantener todo su desarrollo en una sola base de código.
Dart.	Lenguaje de programación utilizado para construir la interfaz, integrar la ejecución de los modelos y administrar la información almacenada en el dispositivo.
Matplotlib.	Herramienta empleada para representar los resultados mediante gráficas y examinar el desempeño del modelo durante el entrenamiento y la evaluación.
conjunto de imágenes de hojas de plátano.	Conjunto final de 141 imágenes para sano, Sigatoka moderada y Sigatoka severa, separado por grupos de captura.
Google drive.	Almacenamiento utilizado para organizar imágenes, divisiones, modelos, métricas y archivos exportados.

4.3.3 Económicos

Tabla 6: Recursos Económicos

Cantidad	Recursos	Precio unitario	Subtotal
1	Computadora	\$700	\$700
1	Smartphone	\$250	\$250
8 meses	Conexión a Internet	\$20	\$160
1	Recolección base de datos	\$500	\$500
320	Horas de trabajo	\$4	\$1,280
TOTAL:			2,440

4.4 Desarrollo del modelo mediante Prototipo Evolutivo en MLOps organizado por sprint

Se implementaron sprints para desarrollar el modelo de forma incremental y refinarlo en cada iteración. Este enfoque permitió probar y evaluar el comportamiento del modelo de manera progresiva, facilitando la identificación de ajustes necesarios durante el proceso de desarrollo.

En cada sprint se realizaron actividades específicas relacionadas con la preparación de las imágenes, la construcción del modelo base, el entrenamiento, la modificación de parámetros, la evaluación de métricas y la optimización del modelo. De esta manera, fue posible observar la evolución de los resultados hasta obtener una versión final acorde con los objetivos planteados en la investigación.

4.4.1 Descripción del Producto

4.4.1.1 Propósito del Producto

El producto desarrollado es una aplicación móvil para Android construida con Flutter, cuyo propósito es apoyar la clasificación visual de fotografías de hojas de plátano. La aplicación utiliza dos modelos en formato TensorFlow Lite que se ejecutan de manera consecutiva.

En primer lugar, la imagen seleccionada o capturada es sometida a una validación previa para comprobar que corresponda a una hoja de plátano. Cuando la imagen es aceptada, se ejecuta el modelo basado en MobileNetV2, que la clasifica en una de las tres categorías establecidas: sana, Sigatoka moderada o Sigatoka severa.

Finalmente, la aplicación presenta al usuario la categoría estimada, el porcentaje de confianza correspondiente y un mensaje orientativo para facilitar la interpretación del resultado. La información generada funciona como apoyo al monitoreo visual y no sustituye la valoración de un profesional del área agronómica.

4.4.1.2 Funcionalidades Claves

- Capturar fotografías de hojas de plátano mediante la cámara del dispositivo.
- Seleccionar fotografías almacenadas en la galería del dispositivo.
- Validar previamente la imagen para comprobar que corresponda a una hoja de plátano antes de ejecutar la clasificación.
- Procesar las imágenes mediante el modelo MobileNetV2 integrado en formato TensorFlow Lite.
- Clasificar las imágenes aceptadas en tres categorías: sana, Sigatoka moderada y Sigatoka severa.
- Mostrar al usuario la categoría estimada y el porcentaje de confianza correspondiente.
- Presentar mensajes orientativos para facilitar la interpretación del resultado.
- Ejecutar la validación y la clasificación directamente en el dispositivo móvil, sin depender de una conexión permanente a internet.
- Almacenar localmente los resultados de los análisis realizados.
- Permitir la consulta del historial con información como la fotografía, la fecha, la categoría obtenida y el porcentaje de confianza.
- Mantener una interfaz sencilla para facilitar su utilización durante las actividades de campo.

4.4.1.3 Usuarios y Objetivos

Tipo de usuario	Principales funcionalidades
Estudiante o investigador vinculado al área agrícola	Utilizar la aplicación durante actividades académicas o investigativas para capturar o seleccionar fotografías de hojas de plátano, ejecutar su clasificación y consultar la categoría estimada y el porcentaje de confianza.
Personal técnico de la Granja Experimental ULEAM	Utilizar la aplicación como herramienta de apoyo durante la revisión visual de las hojas, registrar los resultados obtenidos y consultar posteriormente el historial de análisis.

Docente tutor o evaluador académico.	Comprobar el funcionamiento de la aplicación, revisar la integración del modelo de clasificación y verificar los resultados obtenidos durante las pruebas realizadas.
Usuario general con interés en el cultivo de plátano.	Analizar fotografías de hojas de plátano mediante una interfaz sencilla y consultar la clasificación estimada como información de referencia, sin sustituir la valoración de un profesional del área agronómica.

4.4.1.4 Condiciones de éxito del producto:

- Permitir al usuario capturar una fotografía mediante la cámara o seleccionar una imagen almacenada en la galería.
- Validar previamente la imagen antes de ejecutar el modelo de clasificación.
- Rechazar las imágenes que no correspondan a una hoja de plátano y presentar un mensaje informativo al usuario.
- Clasificar las imágenes aceptadas en una de las tres categorías definidas: sana, Sigatoka moderada o Sigatoka severa.
- Mostrar de manera clara la categoría estimada y el porcentaje de confianza asociado.
- Ejecutar la validación y la clasificación directamente en el dispositivo móvil mediante los modelos integrados en TensorFlow Lite.
- Permitir el funcionamiento de las funciones principales sin depender de una conexión permanente a internet.
- Guardar localmente los resultados de los análisis realizados.
- Mostrar en el historial la fotografía analizada, la fecha, la categoría obtenida y el porcentaje de confianza.
- Proporcionar mensajes que orienten al usuario durante la captura, selección, validación y análisis de las imágenes.
- Mantener una interfaz sencilla y comprensible para los usuarios de la aplicación.
- Presentar los resultados como información de apoyo al monitoreo visual, sin sustituir la valoración de un profesional del área agronómica.

4.4.2 Historias de Usuarios

4.4.2.1 Historia de usuario 1: Captura de imagen de hoja de plátano

Tabla 7 Historia de usuario1 Captura de imagen de hoja de plátano

HISTORIA DE USUARIO 1			
Id de historia	HU-01	Título:	Captura de imagen de hoja de plátano
Prioridad:	Alta	Usuario:	Usuario del sistema
Riesgo de desarrollo:	Medio	Tamaño de la tarea:	Medio
Como:	usuario del sistema		
Quiero:	capturar una fotografía de una hoja de plátano mediante la cámara del dispositivo móvil.		
Para:	utilizar la imagen como entrada del proceso de validación y clasificación realizado por la aplicación.		
Criterios de aceptación:	La aplicación debe permitir acceder a la cámara del dispositivo, capturar una fotografía y mostrarla en la interfaz antes de iniciar su procesamiento. La imagen capturada debe quedar disponible para continuar con el proceso de validación y, cuando corresponda, con la clasificación mediante el modelo integrado.		
Dependencias:	Permisos de acceso a la cámara, disponibilidad de la cámara del dispositivo y funcionamiento del módulo de procesamiento de imágenes.		

4.4.2.2 Historia de usuario 2: Selección de imagen desde la galería

Tabla 8 Historia de usuario2 Selección de imagen desde la galería

HISTORIA DE USUARIO			
Id de historia	HU-02	Título:	Selección de imagen desde la galería
Prioridad:	Alta	Usuario:	Usuario del sistema
Riesgo de desarrollo:	Bajo	Tamaño de la tarea:	Medio
Como:	usuario del sistema		
Quiero:	seleccionar una fotografía de una hoja de plátano almacenada en la galería del dispositivo.		
Para:	utilizarla como entrada del proceso de validación y clasificación de la aplicación.		

HISTORIA DE USUARIO	
Criterios de aceptación:	La aplicación debe permitir acceder a la galería del dispositivo, seleccionar una imagen y mostrarla en la interfaz antes de iniciar su procesamiento. La imagen seleccionada debe quedar disponible para continuar con la validación previa y, cuando sea aceptada, con el proceso de clasificación.
Dependencias:	Permisos necesarios para acceder a la galería, disponibilidad de imágenes almacenadas y funcionamiento del módulo de carga y procesamiento de imágenes.

4.4.2.3 Historia de usuario 3: Análisis de imagen mediante el modelo de Transfer Learning

Tabla 9 Historia de usuario 3 Análisis de imagen mediante el modelo de Transfer Learning

HISTORIA DE USUARIO			
Id de historia	HU-03	Título:	Análisis de imagen mediante el modelo de Transfer Learning
Prioridad:	Alta	Usuario:	Usuario del sistema
Riesgo de desarrollo:	Alto	Tamaño de la tarea:	Grande
Como:	usuario del sistema		
Quiero:	que la aplicación procese la imagen seleccionada o capturada mediante el modelo de clasificación basado en aprendizaje por transferencia.		
Para:	obtener una clasificación de la hoja de plátano en una de las tres categorías definidas: sana, Sigatoka moderada o Sigatoka severa.		
Criterios de aceptación:	La aplicación debe recibir la imagen previamente validada, redimensionarla y adecuarla al formato requerido por el modelo. Posteriormente, debe ejecutar el modelo basado en MobileNetV2 y generar una clasificación entre las tres categorías establecidas, junto con el porcentaje de confianza correspondiente.		
Dependencias:	Modelo MobileNetV2 entrenado, archivo TensorFlow Lite integrado en la aplicación, librerías de procesamiento de imágenes y correcta comunicación entre el módulo de análisis y la interfaz móvil.		

4.4.2.4 Historia de usuario 4: Visualización del resultado de detección

Tabla 10 Historia de usuario 4 Visualización del resultado de detección

HISTORIA DE USUARIO			
Id de historia	HU-04	Título:	Visualización del resultado de detección
Prioridad:	Alta	Usuario:	Usuario del sistema
Riesgo de desarrollo:	Medio	Tamaño de la tarea:	Medio
Como:	usuario del sistema		
Quiero:	visualizar de forma clara el resultado generado por la aplicación.		
Para:	conocer la categoría asignada a la fotografía de la hoja de plátano y el porcentaje de confianza correspondiente.		
Criterios de aceptación:	La aplicación debe mostrar de manera comprensible la categoría obtenida por el modelo: sana, Sigatoka moderada o Sigatoka severa. Además, debe presentar el porcentaje de confianza asociado a la clasificación y un mensaje orientativo que facilite la interpretación del resultado.		
Dependencias:	Funcionamiento correcto del modelo de clasificación, disponibilidad del resultado generado y comunicación adecuada entre el módulo de análisis y la interfaz de resultados.		

4.4.2.5 Historia de usuario5: Registro y consulta del historial de análisis


Tabla 11 Historia de usuario 5 Registro y consulta del historial de análisis

HISTORIA DE USUARIO			
Id de historia	HU-05	Título:	Registro y consulta del historial de análisis
Prioridad:	Media	Usuario:	Usuario del sistema
Riesgo de desarrollo:	Medio	Tamaño de la tarea:	Medio
Como:	Usuario de la aplicación móvil		
Quiero:	Que los resultados de los análisis realizados se almacenen y puedan consultarse posteriormente.		
Para:	Revisar la imagen analizada, la fecha, la clasificación obtenida y el porcentaje de confianza.		
Criterios de aceptación:	La aplicación debe guardar localmente cada análisis y permitir consultar posteriormente la fotografía, fecha, categoría y porcentaje de confianza, incluso sin conexión a internet.		
Dependencias:	Módulo de clasificación, pantalla de resultados y almacenamiento local.		

4.4.3 Diseño del sistema / Descripción técnica

4.4.3.1 Caso de uso: Captura de imagen

Ilustración 1 Diagrama de caso de uso: Captura de imagen



4.4.3.1.1 Caso de uso: Captura de imagen


Tabla 12 Captura de imagen

Documentación del caso de uso: Captura de imagen	
Caso de uso N.º: 001	Nombre del caso de uso: Captura de imagen
Fecha:	Elaborado por:
Actores	Usuario
Objetivo:	Permitir que el usuario capture una fotografía mediante la cámara del dispositivo móvil para utilizarla como entrada del proceso de validación y clasificación de la aplicación.
Precondiciones:	El dispositivo debe contar con una cámara disponible y la aplicación debe disponer de los permisos necesarios para acceder a ella. El usuario debe encontrarse en la pantalla desde la cual puede iniciar un nuevo análisis.
Postcondiciones	La fotografía capturada se muestra en la interfaz y queda disponible para continuar con el proceso de validación

	de la imagen y, cuando corresponda, con su clasificación.
Medios para realizar detección:	Aplicación móvil, cámara del dispositivo y módulo de procesamiento de imágenes.
Pasos	
El usuario inicia un nuevo análisis. El sistema muestra la opción para capturar una fotografía. El usuario selecciona la opción de cámara. El sistema verifica los permisos correspondientes. Se activa la cámara del dispositivo. El usuario captura la fotografía. La aplicación muestra la imagen capturada. La imagen queda disponible para continuar con el proceso de validación y análisis.	
Documentación del caso de uso	
Este caso de uso permite obtener una fotografía mediante la cámara del dispositivo móvil. La imagen capturada constituye la entrada para las etapas posteriores del sistema, por lo que la aplicación verifica los permisos de acceso, activa la cámara, muestra la fotografía obtenida y permite continuar con su procesamiento.	
Situaciones excepcionales:	
La aplicación no puede acceder a la cámara debido a la falta de permisos. La cámara del dispositivo no se encuentra disponible. Se produce un error durante la captura o carga de la imagen. La imagen no supera posteriormente el proceso de validación establecido por la aplicación.	

4.4.3.2 Caso de uso: Selección de imagen desde galería

Ilustración 2 Selección de imagen desde galería



4.4.3.2.1 Caso de uso: Selección de imagen desde galería

Documentación del caso de uso: Selección de imagen desde galería	
Caso de uso N.º: 002	Nombre del caso de uso: Selección de imagen desde la galería
Fecha:	Elaborado por:
Actores	Usuario del sistema
Objetivo:	Permitir que el usuario seleccione una fotografía almacenada en la galería del dispositivo para utilizarla como entrada del proceso de validación y clasificación de la aplicación.
Precondiciones:	El dispositivo debe contener imágenes almacenadas y la aplicación debe disponer de los permisos necesarios para acceder a la galería. El usuario debe encontrarse en la pantalla desde la cual puede iniciar un nuevo análisis.

Postcondiciones	La imagen seleccionada se muestra en la interfaz y queda disponible para continuar con el proceso de validación y, cuando corresponda, con su clasificación.
Medios para realizar detección:	Aplicación móvil, galería del dispositivo, almacenamiento local y módulo de procesamiento de imágenes
Pasos	
El usuario inicia un nuevo análisis. El sistema muestra la opción para seleccionar una imagen desde la galería. El usuario selecciona dicha opción. El sistema verifica los permisos necesarios. Se abre la galería del dispositivo. El usuario selecciona una imagen. La aplicación carga y muestra la imagen seleccionada. La imagen queda disponible para continuar con el proceso de validación y análisis.	
Documentación del caso de uso	
Este caso de uso permite utilizar fotografías almacenadas previamente en el dispositivo. La funcionalidad ofrece una alternativa a la captura directa mediante la cámara y permite que la imagen seleccionada sea cargada en la aplicación para continuar con las etapas de validación y clasificación.	
Situaciones excepcionales:	
El usuario no concede los permisos necesarios para acceder a la galería. No existen imágenes disponibles en el dispositivo. Se produce un error durante la selección o carga del archivo. La imagen no supera posteriormente el proceso de validación establecido por la aplicación.	

4.4.3.2 Diagrama de secuencia




Ilustración 3 Diagrama de secuencia

4.4.3.2.3 Diagrama de secuencia




Ilustración 4 Diagrama de secuencia de visualización del resultado

4.4.3.2.4 Diagrama de secuencia:




Ilustración 5 Diagrama de secuencia del proceso de análisis

4.4.3.2.5 Diagrama de Estado:




Ilustración 6 Diagrama de Estado

4.4.3.2.6 Diagrama de Estado:




Ilustración 7 Diagrama de estado

4.4.4 Descripción Técnica/ Arquitectura del sistema

4.4.4.1 Arquitectura del Sistema

La arquitectura se organizó en módulos para separar la interfaz, la captura de imágenes, la validación, la clasificación y el almacenamiento local. El usuario tiene la opción de fotografiar una hoja con la cámara del dispositivo o utilizar una imagen guardada en la galería. Una vez seleccionada, la aplicación corrige su orientación, modifica su tamaño y la prepara de acuerdo con el formato requerido por los modelos para realizar el análisis.

El análisis comienza con el modelo `validador_hoja.tflite`, encargado de revisar si la fotografía contiene una hoja de plátano. Cuando el nivel de confianza no alcanza el valor establecido, la aplicación interrumpe el proceso y muestra el mensaje «Formato no válido». Cuando la imagen supera esta validación, se ejecuta el modelo `modelo_sigatoka.tflite` para clasificar el estado de la hoja. La interfaz muestra la categoría, la confianza, una recomendación y guarda el resultado en el historial.

4.4.4.1.1 Mapa del sistema




Ilustración 8 Mapa del sistema

4.4.4.1.2 Tecnologías Utilizadas:

➤ Android Studio

IDE utilizado como entorno de desarrollo para construir, organizar, probar e integrar los componentes de la aplicación móvil destinada a la clasificación de imágenes de hojas de plátano.

➤ Flutter

Framework utilizado para construir la interfaz y la lógica de la aplicación desde una sola base de código. En el proyecto gestiona la navegación, la cámara, la galería, el historial y la presentación de resultados.

➤ Dart

Lenguaje de programación utilizado para implementar los servicios de inferencia, validación de imágenes, almacenamiento local y componentes de la interfaz Flutter.

➤ TensorFlow

Biblioteca utilizada en Google Colab para entrenar, validar y convertir los modelos de aprendizaje por transferencia

➤ Keras

Interfaz de alto nivel de TensorFlow empleada para definir las arquitecturas, los callbacks y las fases de entrenamiento y ajuste fino.

➤ MobileNetV2

Arquitectura ligera seleccionada para determinar el nivel de severidad, ya que ofrece un desempeño adecuado, ocupa poco espacio y puede ejecutarse en dispositivos móviles.

➤ TensorFlow Lite

Formato que permite ejecutar los dos modelos directamente en el dispositivo Android, sin depender de una conexión con un servidor externo.

➤ Librerías de procesamiento de imágenes

Estas bibliotecas preparan las imágenes tomadas con la cámara o elegidas desde la galería, de modo que cumplan con el formato requerido antes de ser clasificadas.

4.4.4.1.3 Requerimientos funcionales

Capturar una fotografía desde la cámara del dispositivo.

Solicitar y gestionar el permiso de cámara.

Seleccionar una imagen almacenada en la galería.

Solicitar el permiso de acceso a fotografías cuando corresponda.

Mostrar una vista previa antes de iniciar el análisis.

Comprobar que el archivo pueda abrirse y que la imagen tenga condiciones técnicas mínimas.

Ajustar la orientación de la imagen y organizar correctamente sus canales RGB.

Ejecutar el proceso mediante el validador de hojas integrado en la aplicación.

Analizar y mostrar el mensaje «Formato no válido» cuando la fotografía no contenga una hoja de plátano.

Ejecutar el modelo MobileNetV2 únicamente después de que la imagen supere la validación inicial.

Clasificar la hoja como sana, con Sigatoka moderada o con Sigatoka severa.

Presentar el porcentaje de confianza y una indicación que facilite la comprensión del resultado.

Permitir que el usuario repita el proceso utilizando una fotografía diferente.

Almacenar los modelos y sus respectivos archivos de etiquetas dentro de los recursos de la aplicación.

Guardar en el dispositivo la información generada después de cada análisis.

Conservar en el historial la fecha, la ubicación de la fotografía, la categoría asignada y su porcentaje de confianza.

Obtener los modelos TensorFlow Lite desde la carpeta de recursos internos al iniciar el servicio de inferencia.

Ejecutar todo el procesamiento en el teléfono para que la aplicación pueda funcionar sin conexión a internet.

4.4.4.1.4 Requerimientos no funcionales

Garantizar el funcionamiento de la aplicación en los dispositivos Android que dispongan de la versión mínima requerida.

Mantener separados los servicios encargados de validar las imágenes y efectuar la clasificación, con el fin de facilitar las pruebas y futuras modificaciones.

Ejecutar correctamente en `pubspec.yaml` los cinco archivos necesarios para el funcionamiento de los modelos de inteligencia artificial.

Permitir distinguir una hoja; las imágenes muy oscuras, quemadas o ilegibles deben generar una advertencia.

El preprocesamiento utilizado en Flutter debe coincidir con el aplicado durante la conversión de los modelos.

Mantener en los modelos el mismo orden de categorías establecido en los archivos `labels.txt` y `labels_validador.txt`.

Ejecutar el proceso de inferencia directamente en el dispositivo mediante `tflite-flutter`.

Mantener los modelos con un tamaño que permita instalarlos y ejecutarlos en teléfonos con recursos limitados.

Procurar que el procesamiento de cada imagen termine en un tiempo de espera razonable para el usuario.

Distribuir los archivos del proyecto en carpetas específicas para modelos, servicios, pantallas, utilidades y componentes visuales.

Guardar el historial en el dispositivo y permitir la consulta de los análisis realizados anteriormente.

Preparar la arquitectura para que, en futuras versiones, puedan sustituirse los modelos o incorporarse nuevas categorías.

Mostrar las clasificaciones únicamente como información de apoyo, sin presentarlas como un diagnóstico agronómico definitivo.

Añadir al repositorio las instrucciones necesarias para instalar las dependencias y poner en funcionamiento el proyecto.

Documentar el tamaño de entrada de las imágenes, el tipo de dato utilizado, el orden de las etiquetas y los umbrales establecidos para el validador.

La versión publicada debe incluir el código fuente, los modelos, las etiquetas y la configuración necesaria para reproducir la aplicación.

4.4.5 Roles y Responsabilidades

Tabla 13 Roles y Responsabilidades

Tipo de Usuario	Rol	Descripción
Anthony Adrian Pita Cedeño / Estudiante tesista	Investigador del sistema	Encargado de organizar el desarrollo del proyecto, definir las actividades relacionadas con el entrenamiento del modelo, preparar el conjunto de datos, ejecutar las pruebas y documentar los resultados obtenidos durante el proceso de investigación.
Anthony Adrian Pita Cedeño / Estudiante tesista	Desarrollador del modelo	Responsable de implementar el modelo de Transfer Learning basado en MobileNetV2, configurar el entorno de entrenamiento, ajustar los parámetros necesarios, registrar las métricas de rendimiento y exportar los pesos del modelo para su posterior optimización.
Anthony Adrian Pita Cedeño / Estudiante tesista	Encargado de validación y documentación	Responsable de revisar los resultados generados por el modelo, interpretar las métricas de entrenamiento y validación, elaborar la documentación técnica correspondiente y

		organizar las evidencias del proceso desarrollado.
Tutor académico	Revisor metodológico y técnico	Encargado de revisar los avances del proyecto de titulación, realizar observaciones sobre la estructura, redacción, metodología y coherencia técnica del trabajo, además de orientar al estudiante tesista en el cumplimiento de los objetivos planteados.

4.4.6 Planificación del Sprint

4.4.6.1 Sprint 0: Preparación y configuración

Tabla 14 Preparación y configuración

SPRINT 0: Preparación y configuración			
Duración:	1 semana (06/03/2026 – 12/03/2026)	Prioridad:	Alta
Objetivo:	Preparar el entorno de trabajo, organizar el conjunto de datos y configurar las herramientas necesarias para iniciar el entrenamiento del modelo de Transfer Learning.		
Historias de usuario:	HU-03, HU-05		
Tareas de desarrollo:	- Preparar en Google Colab el entorno donde se realizará el entrenamiento. - Vincular Google Colab con Google Drive para acceder a los archivos del proyecto. - Distribuir las imágenes entre las tres categorías establecidas: sana, Sigatoka moderada y Sigatoka severa. - Comprobar que cada carpeta contenga las imágenes correspondientes y conserve la estructura definida. - Cargar las bibliotecas necesarias para procesar los datos y entrenar el modelo.		
Plan de entrega:	- Dejar listo el entorno de entrenamiento en Google Colab. - Cargar el conjunto de datos desde Google Drive y distribuir las imágenes en sus respectivas categorías. - Verificar que las bibliotecas principales se hayan importado correctamente. - Preparar la configuración inicial necesaria para comenzar el entrenamiento del modelo		

4.4.6.2 Sprint 1:

Tabla 15 Entrenamiento inicial del modelo

SPRINT 1: Entrenamiento inicial del modelo			
Duración:	1 semana (14/04/2026 – 19/04/2026)	Prioridad:	Alta
Objetivo:	Realizar el entrenamiento inicial del modelo mediante aprendizaje por transferencia, utilizando MobileNetV2 como arquitectura principal para clasificar fotografías de hojas de plátano.		
Historias de usuario:	HU-03		
Tareas de desarrollo:	• Cargar en el entorno de trabajo el conjunto de datos en Google Drive. • Preparar las imágenes mediante el ajuste de sus dimensiones y la normalización de sus valores. • Organizar los datos en dos grupos: uno destinado al entrenamiento y otro a la validación. • Adaptar MobileNetV2 al propósito del proyecto y añadir las capas necesarias para clasificar las imágenes. • Definir la configuración que se empleara durante el proceso de entrenamiento. • Ejecutar una primera sesión de entrenamiento para conocer el comportamiento inicial del modelo • Guardar los resultados de las métricas de exactitud (<i>accuracy</i>) y pérdida (<i>loss</i>).		
Plan de entrega:	• Obtener una primera versión funcional del modelo entrenado. • Registrar las métricas iniciales correspondientes al entrenamiento y la validación. • Alcanzar una exactitud aproximada del 60 % como resultado preliminar. • Reconocer los ajustes que podrían aplicarse para mejorar el desempeño del modelo.		

4.4.6.3 Sprint 2:

SPRINT 2: Evaluación y mejora del modelo			
Duración:	4semana (09/05/2026 – 06/06/2026)	Prioridad:	Alta
Objetivo:	Analizar el desempeño del modelo entrenado y realizar los ajustes necesarios para mejorar la clasificación de las tres categorías del conjunto de datos.		
Historias de usuario:	HU-03, HU-05		
Tareas de desarrollo:	- Revisar los resultados obtenidos durante la primera etapa de entrenamiento. - Analizar cómo cambiaron la exactitud y la pérdida a lo largo de las épocas. - Revisar el comportamiento del modelo para detectar un rendimiento bajo o posibles señales de sobreajuste. - Modificar la configuración del entrenamiento según los resultados obtenidos. - Mejorar el procesamiento de las imágenes antes de utilizarlas como entrada del modelo. - Ejecutar nuevamente el entrenamiento después de aplicar los ajustes. - Contrastar las métricas de las distintas versiones y seleccionar la que muestre el desempeño más favorable.		
Plan de entrega:	- Guardar una versión ajustada del modelo mediante la aplicación progresiva de mejoras. - Comparación de métricas entre entrenamientos. - Registro de cambios aplicados al modelo. - Selección de la versión más adecuada para exportación.		

Tabla 16 Evaluación y mejora del modelo

4.4.6.4 Sprint 3:

Tabla 17 Exportación del modelo y prototipo de prueba

SPRINT 3: Exportación del modelo y prototipo de prueba			
Duración:	3semana (10/06/2026 – 01/07/2026)	Prioridad:	Alta
Objetivo:	Exportar el modelo entrenado y convertirlo a TensorFlow Lite para comprobar su funcionamiento en un prototipo básico de detección.		
Historias de usuario:	HU-04, HU-05		

SPRINT 3: Exportación del modelo y prototipo de prueba	
Tareas de desarrollo:	• Guardar y convertir el clasificador de Sigatoka seleccionado al formato TensorFlow Lite. • Incorporar el modelo binario encargado de validar si la imagen contiene una hoja de plátano. • Convertir e integrar el validador en formato TensorFlow Lite. • Incorporar los archivos de etiquetas correspondientes al clasificador y al validador. • Configurar el flujo de inferencia para ejecutar primero el validador y posteriormente MobileNetV2 únicamente cuando la imagen sea aceptada. • Integrar cámara, galería, historial y presentación del porcentaje de confianza. • Realizar pruebas funcionales con imágenes de hojas de plátano y con imágenes que no correspondan a hojas. • Verificar que las entradas no válidas detengan el proceso y generen el mensaje «Formato no válido».
Plan de entrega:	• Modelo exportado correctamente. • Archivo TensorFlow Lite generado. • Prototipo básico funcional. • Evidencias iniciales de prueba del modelo optimizado.

4.4.7 Backlog del Producto

4.4.7.1 Inicial de la lista de pendientes

Tabla 18 Backlog del Producto

Historia de usuario	Tarea	Duración estimada
HU-01	Configuración del módulo de captura de imagen mediante la cámara del dispositivo para obtener fotografías de hojas de plátano.	4 horas
HU-01	Comprobar los permisos de la cámara y verificar que la fotografía tomada se cargue correctamente en la aplicación	2 horas
HU-02	Permitir que el usuario acceda a la galería y seleccione una imagen almacenada en el dispositivo.	3 horas
HU-02	Analizar el formato de la imagen elegida y presentar una vista previa antes de iniciar el análisis.	2 horas
HU-03	Ordenar las imágenes en las tres categorías establecidas: sana, Sigatoka moderada y Sigatoka severa, y almacenarlas en Google Drive.	4 horas

HU-03	Preparar Google Colab con Google Drive para utilizar las imágenes durante el entrenamiento.	2 horas
HU-03	Comparar el tamaño y normalizar los valores de las imágenes de acuerdo con los requisitos de MobileNetV2.	5 horas
HU-03	Preparar el modelo de aprendizaje por transferencia tomando MobileNetV2 como arquitectura principal.	6 horas
HU-03	Realizar el entrenamiento inicial en Google Colab y guardar las primeras métricas obtenidas.	8 horas
HU-03	Analizar el desempeño inicial del modelo mediante las métricas de exactitud (<i>accuracy</i>) y pérdida (<i>loss</i>).	4 horas
HU-04	Preparar la pantalla donde el usuario podrá consultar la categoría asignada por el modelo.	3 horas
HU-04	Mostrar junto con la clasificación el porcentaje de confianza obtenido durante en análisis.	2 horas
HU-05	Almacenar los pesos generados durante el entrenamiento en un formato compatible con TensorFlow y Keras.	3 horas
HU-05	Generar un registro con los valores de pérdida y precisión alcanzados en cada época del entrenamiento	3 horas
HU-05	Conversión del modelo entrenado a formato TensorFlow Lite para su ejecución en un entorno más ligero.	4 horas
HU-05	Validación preliminar del archivo. tflite mediante un prototipo básico de prueba.	5 horas

4.4.7.2 Backlog del Sprint 0: Preparación del entorno y dataset

Tabla 19 Preparación del entorno y dataset

Historia de usuario	Tarea	Duración estimada
HU-03	Configurar el entorno de trabajo en Google Colab para el entrenamiento del modelo.	2 horas
HU-03	Habilitar el acceso desde Google Colab a los archivos del proyecto almacenados en Google Drive.	2 horas
HU-03	Ordenar las imágenes en Google Drive de acuerdo con las tres categorías definidas para el estudio: sana, Sigatoka moderada y Sigatoka severa.	4 horas
HU-03	Comprobar la organización y el acceso a cada una de las carpetas que conforman el conjunto de datos.	2 horas
HU-03	Incorporar al entorno las bibliotecas utilizadas para procesar las imágenes y entrenar la red neuronal.	2 horas
HU-03	Confirmar el funcionamiento de TensorFlow, Keras y las dependencias necesarias antes de iniciar el entrenamiento	2 horas

4.4.7.3 Backlog del Sprint 1: Entrenamiento inicial del modelo

Tabla 20 Entrenamiento inicial del modelo

Historia de usuario	Tarea	Duración estimada
HU-03	Incorporar al modelo la capa de salida requerida para distinguir las tres categorías establecidas: sana, Sigatoka moderada y Sigatoka severa.	2 horas
HU-03	Ajustar las dimensiones de las imágenes al tamaño de entrada utilizado por MobileNetV2.	3 horas
HU-03	Normalizar los valores de las imágenes para prepararlas antes del entrenamiento.	3 horas
HU-03	Separar el conjunto de datos en grupos de entrenamiento y validación.	2 horas
HU-03	Adaptar MobileNetV2 al conjunto de imágenes del proyecto mediante aprendizaje por transferencia.	4 horas
HU-03	Incorporar al modelo las capas de salida requeridas para distinguir las cuatro categorías establecidas.	3 horas
HU-03	Definir el número de épocas, el tamaño del lote y el optimizador que se utilizarán en la primera prueba.	2 horas
HU-03	Ejecutar en Google Colab la primera sesión de entrenamiento con la configuración seleccionada.	6 horas
HU-03	Registrar los valores de exactitud y pérdida obtenidos durante esta primera ejecución }.	2 horas

4.4.7.4 Backlog del Sprint 2: Evaluación y ajuste del modelo

Tabla 21 Evaluación y ajuste del modelo

Historia de usuario	Tarea	Duración estimada
HU-03	Analizar las métricas obtenidas durante el entrenamiento inicial del modelo.	3 horas
HU-03	Revisar el comportamiento de accuracy y loss en entrenamiento y validación.	3 horas
HU-03	Identificar posibles señales de bajo rendimiento, desbalance o sobreajuste del modelo.	3 horas
HU-03	Ajustar parámetros del entrenamiento, como número de épocas, optimizador o tamaño de lote.	4 horas
HU-03	Aplicar mejoras en el preprocesamiento de imágenes para fortalecer la entrada del modelo.	4 horas
HU-03	Ejecutar nuevas pruebas de entrenamiento con los ajustes realizados.	6 horas

HU-05	Comparar los resultados obtenidos entre la versión inicial y la versión ajustada del modelo.	3 horas
HU-05	Registrar las métricas de rendimiento generadas durante las nuevas ejecuciones.	2 horas

4.4.7.5 Backlog del Sprint 3: Exportación y validación del modelo

Tabla 22 Exportación y validación del modelo

Historia de usuario	Tarea	Duración estimada
HU-05	Guardar los pesos del modelo entrenado en un formato compatible con TensorFlow/Keras.	3 horas
HU-05	Exportar el modelo entrenado en formato .h5 o SavedModel.	3 horas
HU-05	Generar el archivo de métricas de entrenamiento con valores de accuracy y loss.	2 horas
HU-05	Convertir el modelo entrenado al formato TensorFlow Lite.	4 horas
HU-05	Verificar la correcta generación del archivo. tflite.	2 horas
HU-05	Realizar pruebas preliminares de inferencia con el modelo convertido.	4 horas
HU-04	Comprobar que el prototipo muestre la clasificación generada por el modelo.	3 horas
HU-04	Validar que el porcentaje de confianza se visualice correctamente en el prototipo.	2 horas
HU-05	Documentar los archivos exportados, métricas obtenidas y evidencias del prototipo.	3 horas

4.4.8 Desarrollo de los sprints

4.4.8.1 Desarrollo del Sprint 0: Preparación del entorno y dataset

Durante el Sprint 0 se configuró una cuenta gratuita de Google Colab y se vinculó Google Drive para acceder al repositorio de imágenes. Se utilizaron Python, TensorFlow, Keras, NumPy, Pandas, Pillow, Matplotlib, scikit-learn e ImageHash para la auditoría, el procesamiento y la evaluación.

La revisión permitió seleccionar 142 fotografías validas de hojas: 42 correspondían a hojas sanas, 73 presentaban Sigatoka moderada y 27 mostraban un nivel severo de la

enfermedad. Las imágenes de la carpeta `archiven/caltech-101` quedaron fuera del clasificador porque contenían objetos ajenos al estudio. También se encontró una fotografía duplicada, que fue retirada, por lo que el conjunto final quedó conformado por 141 imágenes.

Los nombres de los archivos y sus horas de capturar permitieron reunir las fotografías en 36 secuencias independencia, de las cuales 10 correspondían a hojas sanas, 19 a casos de afectación moderada y 7 a casos severos. La división se realizó por grupos, no por imágenes individuales, para evitar que fotografías de una misma hoja aparecieran simultáneamente en entrenamiento y evaluación.

```
( ) # PASO 1: Conectar con Google Drive
from google.colab import drive
drive.mount('/content/drive')

# Importar librerías necesarias
import os
import tensorflow as tf
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.applications import MobileNetV2
from tensorflow.keras import layers, models
import matplotlib.pyplot as plt

print(f"TensorFlow listo (Versión {tf.__version__})")

Mounted at /content/drive
TensorFlow listo (Versión 2.19.0)

( ) # PASO 2: Definir rutas (Asegúrate de que estas carpetas existan en tu Drive)
# Cambia 'Sigatoka Proyecto' si tu carpeta tiene otro nombre
RUTA_BASE = "/content/drive/MyDrive/Sigatoka Proyecto/fotos originales"

CLASES = ["sano", "sigatoka_temprana", "sigatoka_moderada", "sigatoka_severa"]
IMG_SIZE = 224
BATCH_SIZE = 16 # Usamos 16 porque tenemos pocas fotos, para que aprenda "despacio"

print(f"Configuración de rutas terminada")
```

Ilustración 9 Preparación del entorno




Ilustración 10 Dataset

4.4.8.2 Desarrollo del Sprint 1: Entrenamiento inicial del modelo

En el Sprint 1 se implementó la línea base con MobileNetV2 preentrenada en ImageNet. Las imágenes se redimensionaron a 224 por 224 píxeles y se aplicaron rotación, traslación, zoom, contraste y volteo horizontal únicamente al conjunto de entrenamiento. La división final

quedó conformada por 87 imágenes de entrenamiento, 24 de validación y 30 de prueba, manteniendo separados 23, 6 y 7 grupos de captura, respectivamente.

Para reducir el efecto del desbalance y de las ráfagas, cada imagen recibió un peso inversamente proporcional al tamaño de su grupo y a la cantidad de grupos de su clase. En la primera fase se congeló la base preentrenada y se optimizó la capa de clasificación. Posteriormente se efectuó el ajuste fino de las últimas capas con una tasa de aprendizaje reducida.

```
*** Epoch 1/25
S/S ----- 97s 10s/step - accuracy: 0.4174 - loss: 1.4242 - val_accuracy: 0.4444 - val_loss: 1.2288
Epoch 2/25
S/S ----- 19s 2s/step - accuracy: 0.4783 - loss: 1.1676 - val_accuracy: 0.4444 - val_loss: 1.2664
Epoch 3/25
S/S ----- 20s 3s/step - accuracy: 0.6174 - loss: 0.9415 - val_accuracy: 0.5125 - val_loss: 1.2079
Epoch 4/25
S/S ----- 19s 2s/step - accuracy: 0.7130 - loss: 0.6812 - val_accuracy: 0.4815 - val_loss: 1.1126
Epoch 5/25
S/S ----- 19s 3s/step - accuracy: 0.7130 - loss: 0.7429 - val_accuracy: 0.5556 - val_loss: 1.1195
Epoch 6/25
S/S ----- 20s 2s/step - accuracy: 0.7130 - loss: 0.7299 - val_accuracy: 0.4444 - val_loss: 1.1310
Epoch 7/25
S/S ----- 20s 3s/step - accuracy: 0.7813 - loss: 0.5815 - val_accuracy: 0.5926 - val_loss: 0.9640
Epoch 8/25
S/S ----- 21s 3s/step - accuracy: 0.7813 - loss: 0.5524 - val_accuracy: 0.5125 - val_loss: 1.2138
Epoch 9/25
S/S ----- 19s 3s/step - accuracy: 0.8261 - loss: 0.4527 - val_accuracy: 0.5556 - val_loss: 1.0445
Epoch 10/25
S/S ----- 19s 2s/step - accuracy: 0.7826 - loss: 0.4896 - val_accuracy: 0.4874 - val_loss: 0.9903
Epoch 11/25
S/S ----- 21s 3s/step - accuracy: 0.8000 - loss: 0.4825 - val_accuracy: 0.5556 - val_loss: 1.0503
Epoch 12/25
S/S ----- 20s 2s/step - accuracy: 0.7739 - loss: 0.4775 - val_accuracy: 0.5556 - val_loss: 1.0413
Epoch 13/25
S/S ----- 20s 3s/step - accuracy: 0.8957 - loss: 0.3274 - val_accuracy: 0.5556 - val_loss: 1.1302
Epoch 14/25
S/S ----- 19s 2s/step - accuracy: 0.8909 - loss: 0.4061 - val_accuracy: 0.5926 - val_loss: 1.0568
Epoch 15/25
S/S ----- 20s 3s/step - accuracy: 0.8522 - loss: 0.4172 - val_accuracy: 0.6250 - val_loss: 0.9480
Epoch 16/25
S/S ----- 20s 2s/step - accuracy: 0.8870 - loss: 0.3473 - val_accuracy: 0.5926 - val_loss: 1.1613
Epoch 17/25
S/S ----- 19s 2s/step - accuracy: 0.9043 - loss: 0.2987 - val_accuracy: 0.5556 - val_loss: 1.2475
Epoch 18/25
S/S ----- 20s 3s/step - accuracy: 0.8957 - loss: 0.2958 - val_accuracy: 0.5926 - val_loss: 1.2481
Epoch 19/25
S/S ----- 20s 3s/step - accuracy: 0.8174 - loss: 0.4137 - val_accuracy: 0.6667 - val_loss: 1.0083
Epoch 20/25
S/S ----- 20s 2s/step - accuracy: 0.8870 - loss: 0.3224 - val_accuracy: 0.5556 - val_loss: 1.1257
Epoch 21/25
S/S ----- 20s 2s/step - accuracy: 0.8806 - loss: 0.3771 - val_accuracy: 0.6667 - val_loss: 1.1575
Epoch 22/25
S/S ----- 19s 2s/step - accuracy: 0.8806 - loss: 0.3058 - val_accuracy: 0.5926 - val_loss: 0.9368
Epoch 23/25
S/S ----- 21s 3s/step - accuracy: 0.9217 - loss: 0.1962 - val_accuracy: 0.6667 - val_loss: 1.0520
Epoch 24/25
S/S ----- 18s 2s/step - accuracy: 0.8522 - loss: 0.3649 - val_accuracy: 0.6667 - val_loss: 0.9449
Epoch 25/25
S/S ----- 19s 2s/step - accuracy: 0.8957 - loss: 0.2884 - val_accuracy: 0.6250 - val_loss: 1.0157
```

Ilustración 11 Entrenamiento inicial del modelo en Google Colab

4.4.8.3 Desarrollo del Sprint 2: Verificación y perfeccionamiento del modelo

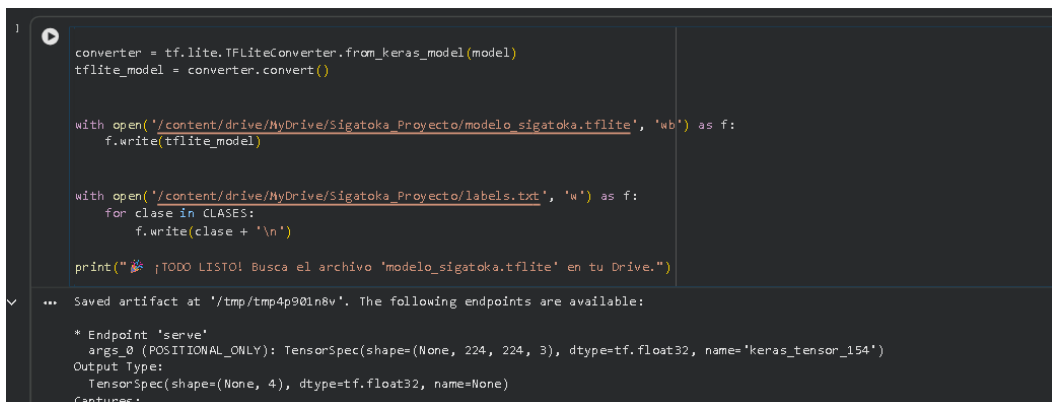
En el Sprint 2 se compararon MobileNetV2, EfficientNetB0 y ResNet50V2 bajo la misma separación de datos. La selección no se basó únicamente en la exactitud; también se analizaron la exactitud balanceada, el F1 macro, la sensibilidad por clase y la pérdida de validación.

MobileNetV2 con ajuste fino alcanzó 83,33 % de exactitud, 87,78 % de exactitud balanceada, 81,35 % de F1 macro y 0,5395 de pérdida de validación. ResNet50V2 sin ajuste fino obtuvo un F1 macro ligeramente mayor en validación, pero presentó menor exactitud balanceada, mayor pérdida y un costo computacional considerablemente superior. Por ello se seleccionó MobileNetV2 para el despliegue móvil.

4.4.8.4 Desarrollo del Sprint 3: Exportación y validación del modelo

Durante el Sprint 3 se convirtió el clasificador final basado en MobileNetV2 al formato TensorFlow Lite y se integró en la aplicación desarrollada con Flutter. Las primeras pruebas funcionales permitieron comprobar el funcionamiento de la cámara, la galería, la inferencia local, la presentación del porcentaje de confianza y el almacenamiento de los resultados en el historial.

Durante estas pruebas se identificó una limitación del clasificador de tres clases: al trabajar únicamente con las categorías sana, Sigatoka moderada y Sigatoka severa, una imagen que no correspondiera a una hoja podía recibir igualmente una de estas clasificaciones. Esta limitación también fue identificada durante la elaboración del artículo científico asociado al proyecto, donde se planteó como mejora la incorporación de un validador previo de hoja/no hoja.



```
converter = tf.lite.TFLiteConverter.from_keras_model(model)
tflite_model = converter.convert()

with open('/content/drive/MyDrive/Sigatoka_Proyecto/modelo_sigatoka.tflite', 'wb') as f:
    f.write(tflite_model)

with open('/content/drive/MyDrive/Sigatoka_Proyecto/labels.txt', 'w') as f:
    for clase in CLASES:
        f.write(clase + '\n')

print("🚀 ¡TODO LISTO! Busca el archivo 'modelo_sigatoka.tflite' en tu Drive.")

... Saved artifact at '/tmp/tmp4p90in8v'. The following endpoints are available:

* Endpoint 'serve'
  args_0 (POSITIONAL_ONLY): TensorSpec(shape=(None, 224, 224, 3), dtype=tf.float32, name='keras_tensor_154')
  Output Type:
    TensorSpec(shape=(None, 4), dtype=tf.float32, name=None)
  Captures:
```

Ilustración 12 Conversión al formato TensorFlow Lite

Posteriormente, durante la finalización de la aplicación, se incorporó el modelo auxiliar validador_hoja.tflite. Este componente se ejecuta antes del clasificador principal y permite comprobar si la fotografía ingresada corresponde a una hoja de plátano. Cuando la imagen no supera la validación, la aplicación detiene el proceso y presenta el mensaje «Formato no válido». Cuando la imagen es aceptada, se ejecuta modelo_sigatoka.tflite, basado en MobileNetV2, para clasificarla como sana, Sigatoka moderada o Sigatoka severa.

Finalmente, los dos modelos TensorFlow Lite y sus respectivos archivos de etiquetas fueron integrados en los recursos de la aplicación. Se realizaron pruebas funcionales con imágenes obtenidas desde la cámara y la galería, incluyendo fotografías que no correspondían a hojas, con el propósito de comprobar el funcionamiento del flujo completo de validación y clasificación.

Tipo	Personas	Modificado	Fuente
Nombre	Propietario		
fotos_originales	yo		
labels.txt	yo		
modelo_sigatoka.tflite	yo		

validador_hoja.tflite	Lo has abierto • 8 ago	modelos_...
labels_validador.txt	Lo has abierto • 8 ago	modelos_...
validador_config.json	Lo has abierto • 8 ago	modelos_...

Ilustración 13 Exportación del modelo y validador de hojas

4.4.9 Resultado técnico del modelo entrenado

El entrenamiento permitió comparar tres arquitecturas bajo la misma división de datos. Esta comparación fue un procedimiento técnico del desarrollo y no una manipulación experimental de las variables agrícolas. La selección del modelo consideró las métricas, el tamaño y la posibilidad de ejecución en un teléfono.

El conjunto de datos final estuvo conformado por 142 imágenes de hojas de plátano, distribuidas en tres categorías: 42 imágenes de hojas sanas, 73 imágenes con síntomas de Sigatoka moderada y 27 imágenes con síntomas de Sigatoka severa. Antes del entrenamiento se eliminó una imagen duplicada y se organizaron las fotografías en grupos de captura, evitando

que imágenes pertenecientes a una misma secuencia fueran utilizadas simultáneamente en entrenamiento, validación y prueba.

La división final quedó conformada por 87 imágenes para entrenamiento, 24 para validación y 30 para prueba. Las imágenes fueron redimensionadas a 224×224 píxeles y normalizadas de acuerdo con los requerimientos de las arquitecturas preentrenadas, en el entrenamiento se aplicaron técnicas de aumento de datos a las imágenes, entre ellas rotaciones, desplazamiento, acercamientos, variaciones de contraste y volteos horizontales, estas modificaciones no se utilizaron en los conjuntos de validación y prueba.

Al comparar los resultados de los modelos evaluados, se seleccionó MobileNetV2 con ajuste fino, ya que mostró un desempeño estable sin exigir demasiados recursos computacionales. En la etapa de validación alcanzó una exactitud del 83,33%, una exactitud balanceada del 87,78 % y un F1 macro del 81,35 %, mientras que la pérdida registrada fue de 0,5395.

Aunque ResNet50V2 obtuvo un resultado competitivo en algunas métricas, necesitó mayores recursos computacionales y mostró un comportamiento menos equilibrado entre las clases. Por esta razón, MobileNetV2 fue considerada la alternativa más apropiada para la conversión a TensorFlow Lite y su integración en el prototipo móvil.

El conjunto de prueba mostró 27 aciertos en 30 imágenes. Los tres errores ocurrieron entre moderada y severa; ninguna hoja enferma fue clasificada como sana, durante la evaluación por grupos de captura, el modelo identificó correctamente seis de los siete grupos estudiados, un resultado favorable para esta primera versión del prototipo, aunque todavía será necesario realizar pruebas con una cantidad mayor de grupos.

4.4.10 Exportación del modelo a TensorFlow Lite

Finalizado el entrenamiento el modelo se convirtió al formato TensorFlow Lite para reducir su tamaño y facilitar su ejecución en dispositivos móviles. De esta manera, el modelo creado en Google Colab se transformó en un archivo optimizado, capaz de utilizarse en un prototipo sin depender directamente del entorno donde fue entrenado.

La conversión a TensorFlow Lite representa una etapa importante dentro del proyecto, debido a que permite acercar el modelo de inteligencia artificial a un contexto práctico de uso. En entornos agrícolas, donde la conectividad puede ser limitada y los dispositivos disponibles no siempre cuentan con altos recursos computacionales, disponer de un archivo .tflite facilita la ejecución local del modelo. Además, se generó el archivo labels.txt, el cual contiene las clases utilizadas por el clasificador para interpretar las predicciones realizadas.

```

1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65
66
67
68
69
70
71
72
73
74
75
76
77
78
79
80
81
82
83
84
85
86
87
88
89
90
91
92
93
94
95
96
97
98
99
100
101
102
103
104
105
106
107
108
109
110
111
112
113
114
115
116
117
118
119
120
121
122
123
124
125
126
127
128
129
130
131
132
133
134
135
136
137
138
139
140
141
142
143
144
145
146
147
148
149
150
151
152
153
154
155
156
157
158
159
160
161
162
163
164
165
166
167
168
169
170
171
172
173
174
175
176
177
178
179
180
181
182
183
184
185
186
187
188
189
190
191
192
193
194
195
196
197
198
199
200
201
202
203
204
205
206
207
208
209
210
211
212
213
214
215
216
217
218
219
220
221
222
223
224
225
226
227
228
229
230
231
232
233
234
235
236
237
238
239
240
241
242
243
244
245
246
247
248
249
250
251
252
253
254
255
256
257
258
259
260
261
262
263
264
265
266
267
268
269
270
271
272
273
274
275
276
277
278
279
280
281
282
283
284
285
286
287
288
289
290
291
292
293
294
295
296
297
298
299
300
301
302
303
304
305
306
307
308
309
310
311
312
313
314
315
316
317
318
319
320
321
322
323
324
325
326
327
328
329
330
331
332
333
334
335
336
337
338
339
340
341
342
343
344
345
346
347
348
349
350
351
352
353
354
355
356
357
358
359
360
361
362
363
364
365
366
367
368
369
370
371
372
373
374
375
376
377
378
379
380
381
382
383
384
385
386
387
388
389
390
391
392
393
394
395
396
397
398
399
400
401
402
403
404
405
406
407
408
409
410
411
412
413
414
415
416
417
418
419
420
421
422
423
424
425
426
427
428
429
430
431
432
433
434
435
436
437
438
439
440
441
442
443
444
445
446
447
448
449
450
451
452
453
454
455
456
457
458
459
460
461
462
463
464
465
466
467
468
469
470
471
472
473
474
475
476
477
478
479
480
481
482
483
484
485
486
487
488
489
490
491
492
493
494
495
496
497
498
499
500
501
502
503
504
505
506
507
508
509
510
511
512
513
514
515
516
517
518
519
520
521
522
523
524
525
526
527
528
529
530
531
532
533
534
535
536
537
538
539
540
541
542
543
544
545
546
547
548
549
550
551
552
553
554
555
556
557
558
559
560
561
562
563
564
565
566
567
568
569
570
571
572
573
574
575
576
577
578
579
580
581
582
583
584
585
586
587
588
589
590
591
592
593
594
595
596
597
598
599
600
601
602
603
604
605
606
607
608
609
610
611
612
613
614
615
616
617
618
619
620
621
622
623
624
625
626
627
628
629
630
631
632
633
634
635
636
637
638
639
640
641
642
643
644
645
646
647
648
649
650
651
652
653
654
655
656
657
658
659
660
661
662
663
664
665
666
667
668
669
670
671
672
673
674
675
676
677
678
679
680
681
682
683
684
685
686
687
688
689
690
691
692
693
694
695
696
697
698
699
700
701
702
703
704
705
706
707
708
709
710
711
712
713
714
715
716
717
718
719
720
721
722
723
724
725
726
727
728
729
730
731
732
733
734
735
736
737
738
739
740
741
742
743
744
745
746
747
748
749
750
751
752
753
754
755
756
757
758
759
760
761
762
763
764
765
766
767
768
769
770
771
772
773
774
775
776
777
778
779
780
781
782
783
784
785
786
787
788
789
790
791
792
793
794
795
796
797
798
799
800
801
802
803
804
805
806
807
808
809
810
811
812
813
814
815
816
817
818
819
820
821
822
823
824
825
826
827
828
829
830
831
832
833
834
835
836
837
838
839
840
841
842
843
844
845
846
847
848
849
850
851
852
853
854
855
856
857
858
859
860
861
862
863
864
865
866
867
868
869
870
871
872
873
874
875
876
877
878
879
880
881
882
883
884
885
886
887
888
889
890
891
892
893
894
895
896
897
898
899
900
901
902
903
904
905
906
907
908
909
910
911
912
913
914
915
916
917
918
919
920
921
922
923
924
925
926
927
928
929
930
931
932
933
934
935
936
937
938
939
940
941
942
943
944
945
946
947
948
949
950
951
952
953
954
955
956
957
958
959
960
961
962
963
964
965
966
967
968
969
970
971
972
973
974
975
976
977
978
979
980
981
982
983
984
985
986
987
988
989
990
991
992
993
994
995
996
997
998
999
1000

```

Ilustración 14 conversión a TensorFlow Lite

Después de la conversión, los archivos obtenidos se guardaron en Google Drive junto con las etiquetas de las categorías utilizadas por el clasificador. Esto permitió conservar de forma ordenada la versión optimizada del modelo y dejarla disponible para nuevas pruebas, futuros ajustes o su integración en una aplicación móvil. Por lo tanto, el proyecto no se enfocó únicamente en entrenar la red neuronal, sino también en prepararla para su uso en un entorno práctico.

Tipo

Personas

Modificado

Fuente

Nombre

Propietario

fotos_originales

yo

labels.txt

yo

modelo_sigatoka.tflite

yo

Ilustración 15 Archivo. tflite guarda en drive

4.4.11 Validación preliminar del prototipo

La validación funcional se realizó con fotografías de cámara y galería. Se comprobó la carga de los modelos, el preprocesamiento, la presentación de la clase y el almacenamiento del

historial. También se ensayaron imágenes sin hojas para verificar el mensaje Formato no válido.

La aplicación quedó operativa como prototipo académico. Su salida debe interpretarse como una estimación visual. Ante una confianza baja, una fotografía borrosa o una diferencia dudosa entre moderada y severa, el usuario debe repetir la captura y consultar a un técnico.

5 CAPÍTULO V: EVALUACIÓN DE RESULTADOS

5.1 Introducción

Este capítulo está dedicado a la evaluación y análisis de los resultados obtenidos durante la creación del modelo de Aprendizaje por Transferencia para la detección de *Pseudocercospora fijiensis* en hojas de plátano, este capítulo profundizará en el rendimiento del modelo entrenado, las fases de entrenamiento y validación, y el prototipo optimizado logrado mediante TensorFlow Lite.

La evaluación de los resultados permitió comprender la capacidad de respuesta de la arquitectura MobileNetV2 cuando se aplica a la realidad agrícola de la Granja Experimental ULEAM, extensión El Carmen, y se analizaron métricas como precisión, pérdida, validación y rendimiento global del modelo con el conjunto de imágenes utilizado. Estas métricas no solo reflejaban el rendimiento técnico del clasificador, sino también los aspectos que influían en sus resultados, como el número de imágenes, la calidad visual del conjunto de datos y posibles mejoras en el proceso de entrenamiento, ya que son cruciales para determinar la efectividad del modelo.

Además, se evaluó la utilidad del modelo convertido a TensorFlow Lite, debido a que este formato permite ejecutar la inferencia en dispositivos con recursos limitados. Por tanto, los resultados no se analizaron únicamente a partir de las métricas del clasificador, sino también considerando su integración en una solución móvil funcional y susceptible de futuras mejoras para apoyar la clasificación visual de hojas de plátano.

5.2 Rendimiento del modelo de aprendizaje por transferencia

MobileNetV2 con ajuste fino alcanzó 83,33 % de exactitud en validación, 87,78 % de exactitud balanceada, 81,35 % de F1 macro y 0,5395 de pérdida. En prueba obtuvo 90 % de exactitud y 91,09 % de F1 macro. La matriz de confusión registró cinco hojas sanas correctas, quince moderadas correctas y siete severas correctas.

Transfer Learning permitió utilizar un modelo preentrenado existente y ajustarlo para los requisitos de la investigación, y esta decisión fue beneficiosa ya que desarrollar un modelo desde cero requeriría imágenes adicionales, tiempo de entrenamiento y recursos

computacionales. El uso de MobileNetV2 facilitó el desarrollo de un clasificador de línea base capaz de reconocer patrones visuales asociados a las clases dentro del conjunto de datos, asegurando así que nuestra metodología siguiera siendo técnica y adecuada para un proyecto de ingeniería de software aplicada en el campo de la visión por computador.

Al evaluar el modelo de manera integral, se observó que fue capaz de generar una respuesta de clasificación para las imágenes procesadas. Estos resultados muestran que la inteligencia artificial puede emplearse como herramienta de apoyo para reconocer patrones visuales asociados con el estado de las hojas de plátano dentro de las categorías definidas en esta investigación. No obstante, los resultados no permiten afirmar que el sistema realice una detección agronómica temprana, debido a que el estudio no evaluó temporalmente la aparición o progresión de los síntomas.

La evaluación por grupos promedió las probabilidades de las fotografías pertenecientes a una misma secuencia. Se clasificaron correctamente seis de siete grupos, con 85,71 % de exactitud, 88,89 % de exactitud balanceada y 84,13 % de F1 macro. Debido al número reducido de grupos, una sola equivocación modifica la métrica en 14,29 puntos porcentuales.

5.3 Análisis de métricas de formación y validación

Las curvas de entrenamiento mostraron que el ajuste fino mejoró MobileNetV2, pero también evidenciaron sobreajuste después de las primeras épocas. La detención temprana restauró los pesos de la mejor época. Por esta razón se utilizó el checkpoint con menor pérdida de validación y no el modelo de la última época.

Los resultados indican que el modelo aprendió rasgos útiles para separar las tres categorías del conjunto local. Sin embargo, no demuestran que mantendrá el mismo rendimiento en cualquier finca o dispositivo. La mayoría de las imágenes proceden de un entorno cercano y el conjunto severo es el más pequeño.

5.4 Probando el modelo optimizado con TensorFlow Lite

El archivo .tflite resultante mantiene el conocimiento de clasificación adquirido durante el entrenamiento y minimiza la necesidad de entornos informáticos de alto rendimiento, porque el cambio en la propuesta tecnológica nos acerca a una solución viable, móvil y compatible

para escenarios en los que se necesita la detección de la enfermedad de la hoja de plátano mediante visión por ordenador.

Tipo ▾ Personas ▾ Modificado ▾ Fuente ▾	
Nombre 	Propietario
 fotos_originales	 yo
 labels.txt	 yo
 modelo_sigatoka.tflite	 yo

Ilustración 16 Modelo exportable

Esta figura muestra el proceso de conversión del modelo, asegurando la versión optimizada lista para la fase de implementación, y este logro refuerza la viabilidad técnica de la propuesta al demostrar que el modelo puede prepararse para su integración en una aplicación o prototipo de detección.

5.5 Pruebas funcionales del prototipo de detección

Mediante pruebas funcionales, se validó la funcionalidad básica del prototipo al procesar una imagen y proporcionar una respuesta de clasificación, y durante esta fase se comprobó el flujo de trabajo principal del sistema funcionaba correctamente, desde la carga o captura de la imagen hasta la presentación del resultado producido por el modelo, durante las pruebas el prototipo logró procesar correctamente las imágenes y mostrar los resultados en la interfaz, lo que permitió comprobar que esta funcionaba de manera adecuada junto con el modelo optimizado. Si bien todavía es posible mejorar su desempeño mediante la incorporación de más fotografías y nuevos ciclos de entrenamiento, esta primera evaluación mostró que la herramienta puede utilizarse como apoyo para reconocer señales visuales asociadas con *Pseudocercospora fijiensis* en hojas de plátano



Ilustración 17 Prueba del prototipo

La ilustración muestra el resultado de una prueba funcional realizada con la aplicación móvil. Después de procesar la imagen, el modelo clasificó la fotografía como hoja sana y presentó al usuario el porcentaje de confianza correspondiente. La interfaz complementa el resultado mediante una interpretación textual y recomendaciones generales, con el propósito de facilitar la comprensión de la salida generada por el modelo.

Esta prueba permitió comprobar la integración entre el modelo MobileNetV2 convertido a TensorFlow Lite y la interfaz desarrollada en Flutter, así como la presentación del resultado de clasificación dentro del dispositivo móvil.

5.5.1 Matriz de requisitos y pruebas funcionales

Con el propósito de verificar el cumplimiento de las principales funcionalidades definidas para la aplicación, se relacionaron los requerimientos funcionales con las pruebas realizadas durante la integración del modelo y la aplicación móvil. La Tabla 23 resume los casos comprobados y el resultado obtenido durante las pruebas funcionales.

Tabla 23 Matriz de requisitos y pruebas funcionales

Código	Requisito funcional	Prueba realizada	Resultado esperado	Resultado obtenido	Estado
RF-01	Capturar una fotografía mediante la cámara del dispositivo.	Se utilizó la cámara desde la aplicación para obtener una imagen de una hoja de plátano.	La imagen debe cargarse correctamente para continuar con el análisis.	La fotografía fue capturada y cargada en la aplicación.	Cumple
RF-02	Seleccionar una imagen almacenada en la galería.	Se seleccionaron fotografías existentes desde la galería del dispositivo.	La aplicación debe cargar la imagen seleccionada y permitir su análisis.	La imagen fue seleccionada y procesada correctamente.	Cumple
RF-03	Validar que la imagen corresponda a una hoja de plátano.	Se probaron imágenes que no correspondían a hojas de plátano.	La aplicación debe detener el análisis cuando la entrada no sea válida.	El validador impidió continuar con la clasificación de la imagen no válida.	Cumple
RF-04	Mostrar una advertencia cuando la imagen no sea válida.	Se ingresó una fotografía que no correspondía a una hoja de plátano.	Debe mostrarse el mensaje «Formato no válido».	La aplicación mostró el mensaje establecido.	Cumple
RF-05	Clasificar las imágenes mediante MobileNetV2.	Se procesaron fotografías de hojas utilizando el modelo integrado en TensorFlow Lite.	El sistema debe devolver una de las tres categorías definidas: sana, Sigatoka moderada o Sigatoka severa.	El modelo generó una clasificación dentro de las tres categorías establecidas.	Cumple
RF-06	Presentar el porcentaje de confianza de la clasificación.	Se observó la pantalla de resultados después de procesar una fotografía.	La aplicación debe mostrar la categoría estimada y su porcentaje de confianza.	La interfaz presentó la clase obtenida y el porcentaje de confianza correspondiente.	Cumple
RF-07	Guardar los resultados de los análisis realizados.	Después de ejecutar una clasificación se revisó el	El resultado debe almacenarse para su	El análisis quedó registrado en el historial local.	Cumple

		historial de la aplicación.	consulta posterior.		
RF-08	Ejecutar el procesamiento localmente en el dispositivo.	Se ejecutó la inferencia con los modelos TensorFlow Lite integrados en la aplicación.	La clasificación debe realizarse en el teléfono sin depender de un servidor externo.	La inferencia se ejecutó localmente mediante TensorFlow Lite.	Cumple

5.6 Análisis del cumplimiento de los objetivos de investigación

El objetivo general de la investigación se logró creando un modelo basado en Aprendizaje por Transferencia para la detección de *Pseudocercospora fijiensis* en hojas de plátano, tomando como estudio de caso Granja Experimental ULEAM, extensión El Carmen, y la implementación de la arquitectura MobileNetV2 permitió la generación de un clasificador inicial capaz de identificar patrones visuales relacionados con la enfermedad. demostrando así la viabilidad de la inteligencia artificial en este escenario agrícola. En cuanto a objetivos específicos, se organizó y preparo la colección de imágenes utilizada para el entrenamiento, aplicar técnicas de preprocesamiento, entrenar el modelo usando TensorFlow y Keras, evaluar su rendimiento mediante métricas y generar una versión optimizada usando TensorFlow Lite.

Los resultados obtenidos demuestran que la tecnología propuesta responde al problema planteado, proporcionando una alternativa inicial para ayudar en la detección de enfermedades foliares mediante visión por ordenador; sin embargo, también se reconoce que el modelo podría mejorarse en futuras iteraciones ampliando el conjunto de datos, equilibrando clases y validando con nuevas imágenes capturadas en condiciones reales de campo.

5.7 Resumen de los resultados obtenidos

Los resultados obtenidos permiten afirmar que el uso de Transfer Learning con MobileNetV2 es una alternativa factible para desarrollar soluciones de detección visual aplicadas al sector agrícola, y el modelo generó una respuesta satisfactoria durante las pruebas realizadas, confirmando que la arquitectura seleccionada era adecuada para el propósito de la investigación. Además, la conversión del modelo a TensorFlow Lite representó un hito relevante porque preparó el clasificador para escenarios de despliegue más ligeros y móviles; por tanto, este resultado es coherente con el enfoque de ingeniería de software del proyecto, ya

que no solo se creó un modelo de inteligencia artificial, sino también una solución tecnológica con potencial de integración en un prototipo funcional.

En general, el Capítulo V muestra que la propuesta desarrollada cumple los objetivos establecidos y proporciona una base técnica para futuras mejoras, ya que la investigación no busca entregar un sistema terminado, sino un prototipo funcional e inicial que pueda perfeccionarse con datos adicionales, ajustes técnicos y validaciones adicionales en el entorno agrícola del ULEAM Experimental de Granja, extensión El Carmen.

6 CAPÍTULO VI: CONCLUSIONES Y RECOMENDACIONES

6.1 Conclusiones

El diagnóstico de las prácticas de monitoreo confirmó que la identificación visual de la Sigatoka negra depende de la experiencia del observador y presenta dificultades para diferenciar estados cercanos de severidad. La encuesta y la entrevista también evidenciaron la necesidad de una herramienta offline, sencilla y compatible con teléfonos de recursos limitados.

La revisión conceptual permitió sustentar el uso de redes neuronales convolucionales, aprendizaje por transferencia, aumento de datos y ajuste fino para el análisis de hojas. El estudio demostró que la arquitectura con mayor tamaño no necesariamente ofrece la mejor solución cuando el conjunto de datos local es reducido.

La preparación del conjunto de imágenes, junto con las etapas de entrenamiento, validación y análisis de métricas, permitió evaluar el comportamiento del modelo frente a los datos utilizados. Los resultados obtenidos evidenciaron un desempeño favorable y mostraron el potencial del modelo para futuras mejoras. No obstante, se identificó la necesidad de ampliar el número de imágenes, mejorar el equilibrio entre las clases e incorporar fotografías capturadas en condiciones reales de campo, con el fin de fortalecer su rendimiento en posteriores etapas de desarrollo.

La conversión de MobileNetV2 al formato TensorFlow Lite permitió integrar el clasificador en la aplicación desarrollada con Flutter y ejecutar la inferencia directamente en el dispositivo móvil. Las pruebas funcionales comprobaron el uso de imágenes provenientes de la cámara y la galería, la presentación de la categoría y del porcentaje de confianza, así como el almacenamiento de los resultados en un historial local sin depender de un servidor externo.

La aplicación incorporó una validación previa de la imagen para evitar que fotografías que no correspondieran a hojas de plátano fueran procesadas directamente por el clasificador de Sigatoka. De esta manera, el producto final funciona como una herramienta de apoyo para la clasificación visual de las hojas; sin embargo, sus resultados deben interpretarse como una estimación del modelo y no como un diagnóstico agronómico definitivo.

6.2 Recomendaciones

Ampliar el conjunto de datos mediante fotografías obtenidas en diferentes fincas y fechas, con distintas condiciones de iluminación, distancias de captura y modelos de teléfono. Durante la evaluación, las imágenes pertenecientes a una misma planta deben conservarse dentro del mismo grupo.

Mejorar el equilibrio entre las categorías, especialmente mediante la incorporación de más casos de Sigatoka severa. No es recomendable compensar la diferencia repitiendo varias veces las mismas fotografías, ya que resulta más conveniente recopilar imágenes de nuevas hojas y formar grupos de captura independientes.

A los estudiantes, se plantea realizar entrenamientos adicionales y ajustes finos del modelo, modificando parámetros como el número de épocas, la tasa de aprendizaje, el tamaño del lote y las estrategias de aumento de datos. Estas acciones podrían contribuir a optimizar el desempeño de MobileNetV2 y mejorar los resultados de clasificación obtenidos por la aplicación.

Para los agricultores, la aplicación debe considerarse una herramienta de apoyo durante la revisión de las hojas y no un sustituto del criterio agronómico. Cuando el porcentaje de confianza sea bajo o existan dudas entre las categorías moderada y severa, resulta conveniente repetir la fotografía y solicitar la valoración de un técnico.

A la Universidad Laica Eloy Alfaro de Manabí, Extensión El Carmen, se propone fomentar el uso progresivo de la aplicación en la Granja Experimental como herramienta complementaria para el monitoreo de hojas de plátano. Su incorporación puede acompañarse de una capacitación básica para estudiantes y personal relacionado con las prácticas agrícolas, orientada a la correcta captura de fotografías y a la interpretación de las categorías y porcentajes de confianza. Además, su utilización permitiría recopilar nuevas imágenes que puedan emplearse posteriormente para evaluar y fortalecer el comportamiento del modelo en distintas condiciones de campo.

7 Bibliografía

- Agrosavia. (2023). Manejo Integrado de Sigatoka Negra en Banano. En A. (. Agropecuaria), *Manejo Integrado de Sigatoka Negra en Banano* (págs. 25-38). Agrosavia.
- Albornoz Zamora, E. J. (2023). Metodología de la Investigación aplicada a las ciencias de la salud y la educación. En E. J. Albornoz Zamora, *Metodología de la Investigación aplicada a las ciencias de la salud y la educación* (págs. 89-97). Mawil Publicaciones de Ecuador.
- Alruwaili, M. e. (2025). Deep learning applications in smart agriculture and plant disease detection. *Artificial Intelligence Review*, 112-145.
- Alzubaidi, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 53.
- Arias-González, J. L. (2023). *Guía para la elaboración*. Independently Published.
- Baena Paz, G. (2021). *Metodología de la investigación*. Patria.
- Blanco, C. (2024). *Encuesta y estadística: métodos de investigación cuantitativa en ciencias sociales y comunicación*. Brujas .
- Capa Santos, H. (2021). *Investigación por muestreo: fundamentos y aplicaciones*. Escuela Politécnica Nacional (EPN), Quito, Ecuador.
- Chang, O. A. (2021). *Sigatoka negra (Mycosphaerella fijiensis) en banano, métodos de control y manejo: Revisión de literatura*. Escuela Agrícola Panamericana ZAMORANO. Obtenido de <https://bdigital.zamorano.edu/server/api/core/bitstreams/caa6d1dc-7f3e-48c8-b85e-2e534deba196/content>.
- Chávez Benavides, R. M. (2024). *Estadística aplicada: herramienta para la investigación, la educación y la toma de decisiones*. Agencia ISBN Ecuador.
- Chollet, F. (2021). *Deep Learning con Python*. Manning Publications.
- Coronel Pocasangre, L. E. (2024). *Manejo Integrado de Sigatoka Negra en Banano Cavendish: Biocontrol y Resistencia*. APS Press. APS Press. doi:10.1094/APSnet-2024-0012
- FAO. (2021). *La Sigatoka negra en plátano y banano*. doi:978-92-5-136248-4

- Gauhl, F. (1989). *Epidemiología y ecología de la Sigatoka negra (Mycosphaerella fijiensis Morelet) en plátano (Musa sp.) en Costa Rica*. Panamá: Unión de Países Exportadores de Banano (UPEB).
- Géron, A. (2023). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*. O'Reilly Media.
- Gilberto, M. S. (2022). Ciclo biológico del patógeno. En M. S. Gilberto, *Biología de Mycosphaerella fijiensis Morelet y su Interacción con el Banano* (págs. 45-68). CICY. doi:978-607-96046-0-3
- Group, T. &. (2023). *Learning Techniques: Transfer Learning Focus*. Elsevier Academic Press. doi:10.1201/9781003252306
- Guadalima-Inga, L. e. (2021). Técnicas de IA para diagnóstico foliar. En L. e. Guadalima-Inga, *Inteligencia Artificial en Sanidad Vegetal* (págs. 55-61). Universidad Nacional Autónoma de México (UNAM) - CEIAAIT.
- Guo, Y. (2024). Convolutional neural networks for agricultural computer vision: A state-of-the-art survey. *Computers and Electronics in Agriculture*, 108-129.
- Hassan, M. e. (2024). *"Deep Learning Applications in Plant Disease Detection: Transfer Learning Approaches"*. Springer Nature - Frontiers in Plant Science Series. doi:doi.org/10.3389/fpls.2024.10895770
- He, K. Z. (2018). Identity mappings in deep residual networks. *European Conference on Computer Vision*, 630-645.
- Hernández Sampieri, R. &. (2023). *Metodología de la investigación: Las rutas cuantitativa, cualitativa y mixta** (2ª ed.). McGraw-Hill Educación. doi:978-607-15-2031-9
- Hernández Sampieri, R. F. (2021). *Metodología de la investigación*. McGraw-Hill Education.
- hoaib, M., & al, e. (2023). An advanced deep learning models-based plant disease detection: A review of recent research. *Frontiers in Plant Science*.
- Huamán Flores, E. J. (2023). *Metodología de la investigación científica*. Universidad Autónoma de Cañete.
- Huyen, C. (2022). Designing Machine Learning Systems. En C. Huyen, *Designing Machine Learning Systems*. O'Reilly Media.
- Kumar, A., & al., e. (2025). Fruit Plant Disease Detection using Transfer Learning. *International Journal of Engineering Research & Technology (IJERT)*.
- Martínez, J. M., & Gómez, A. (2023). écnicas de Data Augmentation para la clasificación de patologías vegetales. *Revista de Inteligencia Artificial y Agricultura Computacional*.

- Pestana, Y. &. (2021). *Metodología para el estudio de instituciones educativas: Un constructo científico en desarrollo*. RedIPE. doi:978-9942-558-45-2
- Pressman, R. S. (2010). *Software Engineering: A Practitioner's Approach*. En R. S. Pressman, *Software Engineering: A Practitioner's Approach*. McGraw-Hill.
- Sampieri, R. H., & Torres, C. P. (2023). *Metodología de la investigación: Las rutas cuantitativa, cualitativa y mixta*. McGraw-Hill Interamericana de España / McGraw-Hill Educación.
- Sandler, M. H.-C. (2022). MobileNetV2: Inverted residuals and linear bottlenecks. *Proceedings of the IEEE/CVF*, 4510-4520.
- Sarkar, D. (2023). *Hands-On Transfer Learning with Python: Implement Advanced Deep Learning and Neural Network Model Fine-tuning*. Packt Publishing Limited. doi:9781801072245
- Sarker, I. H. (2021). Deep learning: a comprehensive overview on techniques, taxonomy, applications and research directions. *SN Computer Science*, 420.
- Stover, R. &. (2022). *Manual de enfermedades del banano y plátano en América Latina*. CABI Publishing. doi:978-1789243677.
- Stover, R. (2022). Pérdidas cuantificadas por región. En R. Stover, *Impacto Económico de la Sigatoka Negra en Plantaciones de Banano Cavendish* (págs. 145-162). CABI Bioscience.
- Suhanya, M., & Natesan, P. (2024). An approach to Plant Disease Detection using Deep Learning Techniques. *Revista Colombiana de Computación*, 16-25.
- Tan, M. &. (2022). EfficientNet: Rethinking model scaling for convolutional neural networks. *Proceedings of the 36th International Conference on Machine Learning*, 6105-6114.
- Valle-Medina, F. D.-H.-P. (2025). Clasificación de enfermedades en hojas de papa utilizando Transformadores de Visión. *SciELO*, 1(1), 142-160. doi:http://scielo.senescyt.gob.ec/scielo.php?script=sci_arttext&pid=S2631-26542025000100142
- Xu, M., Yoon, S., Jeong, Y., & Park, D. S. (2022). Transfer learning for versatile plant disease recognition with limited data. *Frontiers in Plant Science*.

8 ANEXOS

ANEXOS A fotografías



Ilustración 18 Entrevista al procesional en el área



Ilustración 19 Compra de las donaciones

ANEXO B : Estructura de la entrevista y encuesta

1. ¿Cómo califica el nivel de integración de herramientas digitales en las prácticas agrícolas actuales de la Extensión El Carmen?

- ☐ Muy avanzado
- ☐ Adecuado
- ☐ Insuficiente
- ☐ Inexistente



2. ¿Qué importancia tiene para su formación profesional el aprendizaje de soluciones basadas en Agricultura de Precisión?

- ☐ Crucial para el mercado laboral
- ☐ Importante para la especialización
- ☐ Complementaria, pero no esencial
- ☐ Irrelevante para mi perfil

Ilustración 20 estructura de la encuesta

3. ¿Cuál considera que es la principal ventaja de utilizar aplicaciones con Inteligencia Artificial para el monitoreo de cultivos?

- ☐ Reducción del margen de error humano
- ☐ Optimización del tiempo en prácticas de campo
- ☐ Acceso a diagnósticos técnicos en tiempo real
- ☐ Registro digital de datos históricos

4. Ante el desarrollo de una herramienta tecnológica, ¿cuál considera que es el mayor reto para su adopción entre los estudiantes?

- ☐ Limitaciones de hardware (teléfonos de gama baja)
- ☐ Falta de capacitación técnica especializada
- ☐ Dificultad de acceso a internet en áreas de práctica
- ☐ Resistencia al reemplazo de métodos tradicionales



5. ¿Qué funcionalidad valoraría más en una aplicación móvil diseñada para el entorno de la Granja Experimental?

- ☐ Interfaz intuitiva y de rápida navegación
- ☐ Capacidad de funcionamiento en modo offline
- ☐ Alta precisión en la identificación de patologías
- ☐ Generación de reportes automáticos en PDF

Ilustración 21 estructura de la encuesta

6. ¿Cree usted que la universidad debería priorizar el desarrollo de software propio para la gestión de sus procesos agropecuarios?

- ☐ Totalmente de acuerdo
- ☐ De acuerdo
- ☐ En desacuerdo
- ☐ Totalmente en desacuerdo

7. ¿Cuál es su método principal para identificar la Sigatoka Negra (*Pseudocercospora fijiensis*) en las hojas de plátano?

- ☐ Inspección visual basada en la experiencia
- ☐ Comparación con guías y atlas fitosanitarios
- ☐ Consulta directa con docentes o técnicos
- ☐ Aún no logra identificarla con certeza



8. En sus prácticas de campo, ¿qué nivel de dificultad encuentra para diferenciar visualmente la Sigatoka temprana de una deficiencia nutricional?

- ☐ Dificultad muy alta
- ☐ Dificultad moderada
- ☐ Dificultad baja
- ☐ Ninguna dificultad

Ilustración 22 estructura de la encuesta

9. ¿Cuál considera que es el factor determinante para que esta enfermedad cause pérdidas económicas tan severas en la región?

- ☐ Diagnóstico tardío por métodos manuales
- ☐ Condiciones climáticas extremas de la zona
- ☐ Resistencia del hongo a los fungicidas actuales
- ☐ Falta de protocolos de monitoreo constante

10. ¿Estaría dispuesto a validar su criterio técnico comparándolo con el diagnóstico sugerido por una Inteligencia Artificial?

- ☐ Totalmente dispuesto
- ☐ Muy dispuesto
- ☐ Poco dispuesto
- ☐ Nada dispuesto

Ilustración 23 estructura de la encuesta

ANEXO C: Reporte del sistema antiplagio

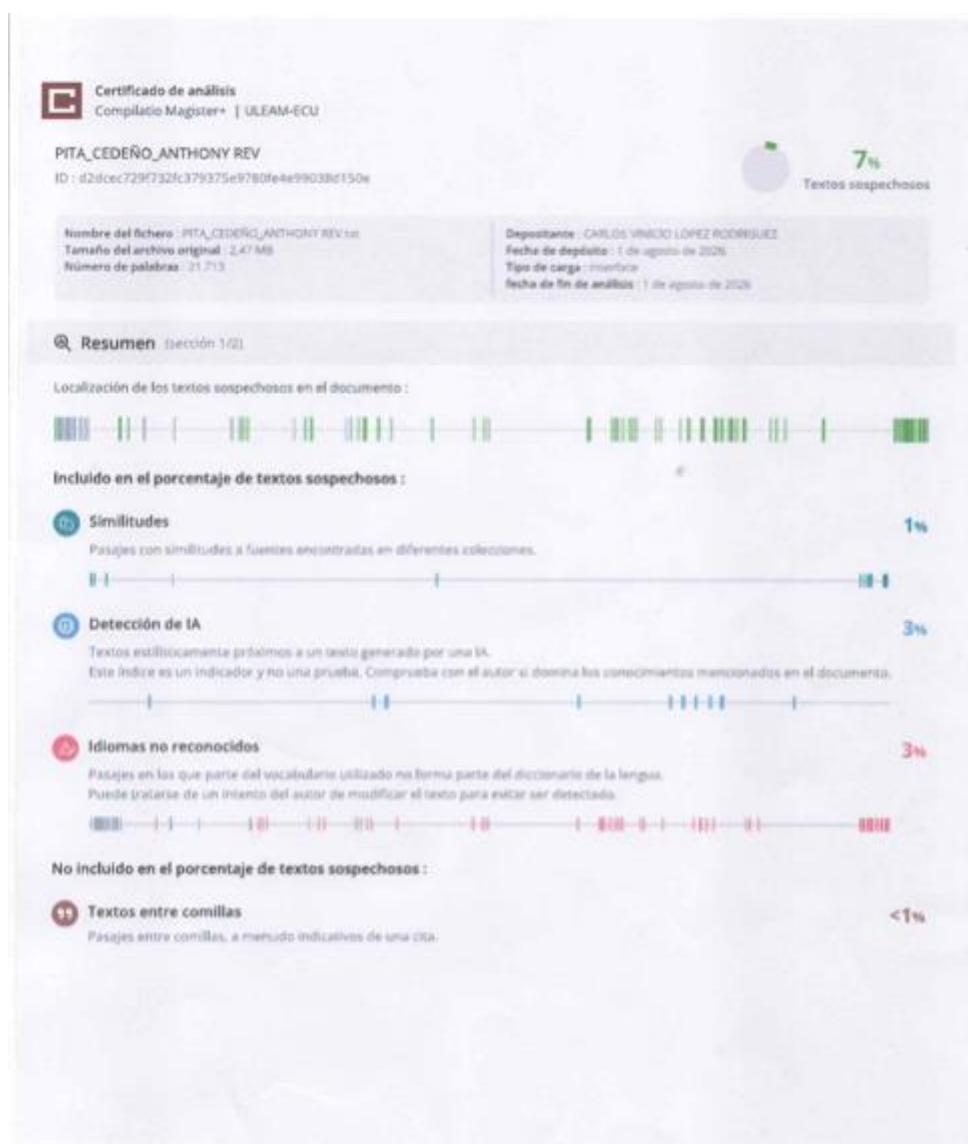


Ilustración 24 Reporte antiplagio

ANEXO D: Asignación de tutor



Universidad Laica Eloy Alfaro de Manabí

Periodo 2025-2 - Notificación de tutor asignado - SOFTWARE
2024 - NS - (EL CARMEN)

Estimad@
Docente y Estudiante
Uleam

En cumplimiento de lo establecido en la Ley, el Reglamento de Régimen Académico y las disposiciones estatutarias de la Uleam, por medio de la presente se oficializa la dirección y tutoría en el desarrollo del Trabajo de Integración curricular / Trabajo de Titulación del siguiente estudiante:

Nombre del estudiante: INFORMADO CON TRANSFER LEARNING PARA EL CONTROL DE PRESIONES CORPORALES EN LA GRAN INDUSTRIA DE LA ULEAM EL CARMEN

Estado de aprobación: Aprobado

Tipo de titulación: Trabajo de Integración Curricular

Tipo de proyecto: Trabajo de Integración Curricular / Trabajo de titulación se vincula con proyectos y programas de investigación.

Apellidos y nombres del tutor asignado: LOPEZ RODRIGUEZ CARLOS VINICIO

Apellidos y nombres del estudiante: PIZACEDON ANTHONY JORUN

Carrera: SOFTWARE 2024 - NS - (EL CARMEN)

Turno de indicación: Periodo 2025-2

Sírvase en cumplir con lo dispuesto en el Manual de Procedimientos de TITULACIÓN DE ESTUDIANTES DE GRADO: TRABAJO DE INTEGRACIÓN CURRICULAR Y UNIDAD DE TITULACIÓN

<https://departamentos.uleam.edu.ec/gestion/aseguramiento-calidad/files/2020/06/IST-04-Titulacion-de-Estudiantes-de-grado-UIC-y-UT.pdf>

Ilustración 26 Designación de tutor

9 GLOSARIO

Accuracy (exactitud): Métrica que indica la proporción de predicciones correctas realizadas por el modelo respecto al total de imágenes evaluadas.

Ajuste fino (Fine-tuning): Etapa del aprendizaje por transferencia en la que se descongelan algunas capas de una red preentrenada para adaptar sus características al nuevo conjunto de imágenes.

Aprendizaje automático (Machine Learning): Rama de la inteligencia artificial que permite a un sistema identificar patrones en los datos y realizar predicciones sin depender únicamente de reglas programadas de forma manual.

Aprendizaje profundo (Deep Learning): Área del aprendizaje automático basada en redes neuronales con múltiples capas, capaces de extraer características complejas de imágenes, sonidos o textos.

Aprendizaje por transferencia (Transfer Learning): Técnica que reutiliza el conocimiento adquirido por un modelo previamente entrenado en una gran base de datos y lo adapta a una tarea específica, como la clasificación de hojas de plátano.

Aumento de datos (Data Augmentation): Técnica que genera variaciones de las imágenes originales mediante rotaciones, desplazamientos, cambios de contraste, acercamientos u otras transformaciones, con el propósito de mejorar la capacidad de generalización del modelo.

Balanced Accuracy (exactitud balanceada): Métrica que calcula el promedio del nivel de acierto obtenido en cada clase. Es especialmente útil cuando las categorías no poseen la misma cantidad de imágenes.

Batch Size (tamaño de lote): Número de imágenes que el modelo procesa antes de actualizar sus pesos durante el entrenamiento.

Clasificación multiclase: Problema en el que el modelo debe seleccionar una categoría entre varias opciones. En este proyecto, las clases fueron: sana, Sigatoka moderada y Sigatoka severa.

Conjunto de datos (Dataset): Colección organizada de imágenes utilizada para entrenar, validar y evaluar los modelos de inteligencia artificial.

Conjunto de entrenamiento: Parte del conjunto de datos empleada para que el modelo aprenda los patrones visuales presentes en las imágenes.

Conjunto de prueba: Grupo de imágenes reservado para medir el rendimiento final del modelo después de seleccionar y ajustar la arquitectura.

Conjunto de validación: Parte de los datos utilizada durante el desarrollo para observar el comportamiento del modelo, ajustar hiperparámetros y seleccionar la mejor configuración.

Dart: Lenguaje de programación utilizado para desarrollar la lógica de la aplicación móvil creada con Flutter.

Detección de Sigatoka negra: Proceso mediante el cual el sistema analiza una fotografía de una hoja de plátano y estima su estado según los síntomas visuales asociados con la enfermedad.

Época (Epoch): Ciclo completo en el que el modelo procesa todas las imágenes disponibles en el conjunto de entrenamiento.

EfficientNetB0: Arquitectura de red neuronal convolucional preentrenada que busca mantener un equilibrio entre precisión, profundidad y costo computacional.

F1 Macro: Métrica que calcula el promedio del valor F1 de todas las clases, asignando la misma importancia a cada categoría, independientemente de su cantidad de imágenes.

Filtración de datos (Data Leakage): Situación en la que información del conjunto de entrenamiento aparece también en validación o prueba, lo que puede producir resultados artificialmente altos.

Flutter: Framework desarrollado por Google que permite crear aplicaciones móviles utilizando una sola base de código escrita en Dart.

Grupo de captura: Conjunto de fotografías tomadas en una misma secuencia, momento o sobre una misma hoja. En este proyecto, estos grupos se mantuvieron separados para reducir el riesgo de filtración de datos.

Hiperparámetro: Valor definido antes o durante el entrenamiento que controla el comportamiento del modelo, como la tasa de aprendizaje, el número de épocas o el tamaño del lote.

Imagen no válida: Fotografía que no contiene una hoja de plátano claramente identificable o que no reúne las condiciones mínimas para ejecutar el diagnóstico.

Inferencia: Proceso mediante el cual un modelo ya entrenado recibe una imagen nueva y genera una predicción.

Inteligencia artificial: Campo de la informática orientado al desarrollo de sistemas capaces de realizar tareas asociadas con el aprendizaje, el reconocimiento de patrones y la toma de decisiones.

Keras: Interfaz de alto nivel integrada con TensorFlow, utilizada para construir, entrenar y evaluar modelos de redes neuronales.

Matriz de confusión: Herramienta de evaluación que muestra la cantidad de predicciones correctas e incorrectas para cada clase, permitiendo identificar entre qué categorías se producen las confusiones.

MobileNetV2: Arquitectura de red neuronal convolucional optimizada para dispositivos con recursos limitados. Fue seleccionada como modelo principal de este proyecto por su equilibrio entre rendimiento y tamaño.

Modelo clasificador: Modelo de inteligencia artificial encargado de determinar si una hoja corresponde a la categoría sana, Sigatoka moderada o Sigatoka severa.

Modelo preentrenado: Red neuronal que ya ha aprendido características visuales generales a partir de un conjunto de datos amplio y que puede adaptarse posteriormente a una tarea específica.

Modelo validador de hoja: Modelo binario utilizado antes del clasificador de Sigatoka para comprobar si la fotografía contiene una hoja de plátano. Cuando no la detecta, la aplicación muestra el mensaje “Formato no válido”.

Normalización: Proceso de transformación de los valores de los píxeles a un rango adecuado para que puedan ser procesados correctamente por la red neuronal.

Pérdida (Loss): Valor numérico que representa la diferencia entre las predicciones del modelo y las etiquetas reales. Un valor menor suele indicar un mejor ajuste.

Precisión (Precision): Métrica que indica qué proporción de las imágenes asignadas a una clase realmente pertenecía a esa categoría.

***Pseudocercospora fijiensis*:** Hongo responsable de la Sigatoka negra, enfermedad que afecta las hojas de plantas del género *Musa*, entre ellas el plátano y el banano.

Preprocesamiento de imágenes: Conjunto de operaciones aplicadas antes de ingresar una imagen al modelo, como corrección de orientación, redimensionamiento, conversión de canales y preparación de los valores de los píxeles.

Red neuronal convolucional (CNN): Tipo de red neuronal diseñada para analizar imágenes mediante filtros que identifican bordes, colores, texturas, formas y otros patrones visuales.

ResNet50V2: Arquitectura de red neuronal profunda que utiliza conexiones residuales para facilitar el entrenamiento de múltiples capas. En este proyecto se empleó como modelo comparativo.

Sensibilidad (Recall): Métrica que indica la capacidad del modelo para identificar correctamente las imágenes que pertenecen a una clase determinada.

Sigatoka moderada: Categoría utilizada para representar hojas con síntomas visibles de la enfermedad, pero sin un nivel de afectación avanzado.

Sigatoka negra: Enfermedad foliar causada por *Pseudocercospora fijiensis*, caracterizada por la aparición progresiva de estrías, manchas, clorosis y áreas necróticas en las hojas.

Sigatoka severa: Categoría correspondiente a hojas con un nivel avanzado de afectación, presencia extensa de necrosis o pérdida considerable del tejido foliar funcional.

Softmax: Función utilizada en la capa de salida del modelo para convertir sus valores internos en probabilidades asociadas con cada categoría.

Sobreajuste (Overfitting): Situación en la que el modelo aprende con demasiado detalle las imágenes de entrenamiento y pierde capacidad para clasificar correctamente fotografías nuevas.

Tasa de aprendizaje (Learning Rate): Hiperparámetros que controla la magnitud de los cambios realizados en los pesos de la red durante el entrenamiento.

TensorFlow: Biblioteca de aprendizaje automático utilizada para construir, entrenar, evaluar y convertir los modelos desarrollados en la investigación.

TensorFlow Lite: Versión optimizada de TensorFlow orientada a la ejecución de modelos en dispositivos móviles y equipos con recursos computacionales limitados.

Umbral de confianza: Valor mínimo establecido para aceptar una predicción. Cuando la probabilidad obtenida es baja, la aplicación puede solicitar al usuario que tome otra fotografía.

Visión por computador: Área de la inteligencia artificial que permite a los sistemas analizar e interpretar información contenida en imágenes o videos.