



UNIVERSIDAD TÉCNICA ESTATAL DE QUEVEDO
FACULTAD DE CIENCIAS DE LA INGENIERÍA
CARRERA DE TELEMÁTICA

Trabajo de Integración Curricular
previa la obtención del Grado
Académico de Ingeniero en
Telemática.

PROYECTO DE INVESTIGACIÓN:

**“SISTEMA DE TELEDETECCIÓN UTILIZANDO DRONES PARA LA
IDENTIFICACIÓN DE ENFERMEDADES DE BANANO EN LA HACIENDA LA
LORENA”**

AUTOR:

KEVIN JOEL CEDEÑO CAMPOVERDE

DIRECTOR DEL PROYECTO DE INVESTIGACIÓN:

ING. CRISTIAN GABRIEL ZAMBRANO VEGA, Ph.D.

QUEVEDO – LOS RÍOS – ECUADOR

2024



DECLARACIÓN DE AUTORÍA Y CESIÓN DE DERECHOS

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

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




Kevin Joel Cedeño Campoverde

C.I: 1751559046



CERTIFICACIÓN DE CULMINACIÓN DEL PROYECTO DE INVESTIGACIÓN

El suscrito, **Ing. Cristian Gabriel Zambrano Vega, PhD.** Docente de la Universidad Técnica Estatal de Quevedo, certifica que el estudiante Kevin Joel Cedeño Campoverde, realizó el Anteproyecto de Investigación de grado titulado **“SISTEMA DE TELEDETECCIÓN UTILIZANDO DRONES PARA LA IDENTIFICACIÓN DE ENFERMEDADES DE BANANO EN LA HACIENDA LA LORENA”**, previo a la obtención del título de **Ingeniero en Telemática**, bajo mi dirección, habiendo cumplido con las disposiciones reglamentarias establecidas para el efecto.



Ing. Cristian Gabriel Zambrano Vega, Ph.D
DIRECTOR DEL PROYECTO DE INVESTIGACIÓN



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

El suscrito, **Ing. Cristian Gabriel Zambrano Vega, PhD**, mediante el presente cumpla en presentar a usted, el informe de proyecto de Investigación titulado “**SISTEMA DE TELEDETECCIÓN UTILIZANDO DRONES PARA LA IDENTIFICACIÓN DE ENFERMEDADES DE BANANO EN LA HACIENDA LA LORENA**” Presentado por el estudiante **Kevin Joel Cedeño Campoverde** egresado de la Carrera de **Ingeniería en Telemática**, que fue revisado bajo mi dirección según resolución del Consejo Directivo de la Facultad de Ciencias de la Ingeniería, que se ha desarrollado de acuerdo al Reglamento de la Unidad de Integración Curricular de la Universidad Técnica Estatal de Quevedo y cumple con el requerimiento de análisis de COMPILATIO el cual avala los niveles de originalidad en un 96% y similitud 4%, del trabajo investigativo. Valido este documento para que el estudiante siga con los trámites pertinentes, de acuerdo como lo estable el Reglamento.

Se adjunta imagen del sistema COMPILATIO.

CERTIFICADO DE ANÁLISIS
magister

Proyecto de Investigación (Revisión 12 nov2024)


4%
Textos
sospechosos

1%
Similitudes

Nombre del documento: Proyecto de Investigación (Revisión 12 nov2024).docx
ID del documento: 138f4c10b2c0d043dc50ab72515412a974cbe5
Tamaño del documento original: 11.96 MB
Autores: []

Depositar: CRISTIAN GABRIEL ZAMBRANO VEGA
Fecha de depósito: 13/11/2024
Tipo de carga: interfase
Fecha de fin de análisis: 13/11/2024

Número de palabras: 32.152
Número de caracteres: 214.812


Ing. Cristian Gabriel Zambrano Vega, PhD
DIRECTOR DEL PROYECTO DE INVESTIGACIÓN



UNIVERSIDAD TÉCNICA ESTATAL DE QUEVEDO
FACULTAD DE CIENCIAS DE LA INGENIERÍA
CARRERA DE INGENIERÍA EN TELEMÁTICA

PROYECTO DE INVESTIGACION

Título:

**“Sistema De Teledetección Utilizando Drones Para La Identificación De
Enfermedades De Banano En La Hacienda La Lorena”**

Presentado al Consejo Directivo de Facultad como requisito previo a la obtención del
título de Ingeniero en Telemática

Aprobado por:



PRESIDENTE DEL TRIBUNAL

(Ing. Byron Oviedo Bayas. Ph.D.)



MIEMBRO DEL TRIBUNAL

(Ing. Eduardo Samaniego Mena. M.Sc.)



MIEMBRO DEL TRIBUNAL

(Ing. Alex Fiallos Barrionuevo. M.Sc.)

QUEVEDO – LOS RIOS – ECUADOR

2024

AGRADECIMIENTOS

Deseo expresar mi más profundo agradecimiento a todas las personas que me acompañaron y apoyaron en la realización de este proyecto de investigación. En primer lugar, extendiendo mi gratitud al Ing. Cristian Gabriel Zambrano Vega, Ph.D., mi tutor de tesis, cuyo invaluable asesoramiento, paciencia y compromiso fueron fundamentales para el desarrollo de este proyecto. Sus conocimientos y dedicación no solo guiaron mi investigación, sino que también me inspiraron a superar cada desafío que enfrenté.

A la Universidad Técnica Estatal de Quevedo, mi segundo hogar, le agradezco por brindarme la oportunidad y los recursos necesarios para formarme como profesional. Agradezco también a cada profesor que, a lo largo de mi trayectoria académica, sembró en mí el interés por el conocimiento y el sentido de responsabilidad para con la sociedad.

A mis compañeros y amigos, quienes compartieron conmigo momentos de aprendizaje y esfuerzo, su apoyo y ánimo fueron un pilar importante en este camino. A mi familia, mis más sinceros agradecimientos por su amor y constante apoyo incondicional, ellos fueron y son mi motor para alcanzar cada meta que me propongo.

Finalmente, dedico este trabajo a todos aquellos que, de alguna manera, contribuyeron a que este sueño se haga realidad. A todos ustedes, gracias.

Kevin Joel Cedeño Campoverde

“La imaginación no es solo la capacidad humana única de imaginar lo que no es, y por lo tanto, la fuente de toda invención e innovación. En su capacidad posiblemente más transformadora y reveladora, es el poder que nos permite empatizar con los humanos cuyas experiencias nunca hemos compartido”

J.K. Rowling.

DEDICATORIA

Dedico este proyecto a cada una de las personas que de alguna u otra manera me han ayudado con el ánimo y las fuerzas cuando yo no las tuve.

Este proyecto de investigación va dedicado a Dios todo poderoso que hallo gracia en mí, brindándome las fuerzas necesarias, salud, y cuidándome ante cualquier adversidad del mundo. A mis padres que de una u otra manera buscaron la manera de sacarme adelante, a mi padre Danilo Cedeño que con su arduo esfuerzo y dedicación logro implantarme el sentido de responsabilidad y trabajo duro y honesto, a mi madre, Leonor Campoverde que con su amor, paciencia, y carácter logro formarme como persona de bien, siempre instruyéndome e impulsándome a ser mejor persona, a mi hermano Jostin Cedeño, llenándome de alegría, y logrando sacarme una sonrisa más de una vez en los momentos más difíciles, a la mami Yagua, que con su compañía, y cariño en esas largas noches de estudio, logro hacerme sentir acompañado. A mi novia Brumi Lara, que por más de 2 años ha estado a mi lado brindándome ese apoyo y amor desinteresado.

A mis amigos, Mathias Ortega, Jorge Aguirre, Arturo Marcillo, Donato Consuegra, Solange Villarroel, Wladimir Párraga, Jhon Flores, Julius Vinueza, Holger Centeno, que no solo fueron mis compañeros, fueron mi familia y mi apoyo innato ante las adversidades de la carrera, los días siempre fueron mejores cuando pasábamos juntos, ya sea jugando, estudiando o compartiendo un momento ameno.

Finalmente, dedico este esfuerzo a todas las personas del sector agrícola que, a través de su trabajo diario, contribuyen al bienestar y desarrollo de nuestra sociedad. Este proyecto es un homenaje a su labor y un compromiso hacia el futuro de una agricultura más eficiente y sostenible. Gracias a todos aquellos que creyeron en mí y aportaron, directa o indirectamente, a la realización de este sueño.

RESUMEN

Este proyecto de investigación desarrolla un sistema basado en visión por computadora y aprendizaje profundo para la detección automática de enfermedades en plantaciones de banano, enfocándose en Moko Bacteriano (*Pseudocercospora fijiensis* sp) y Sigatoka Negra (*Ralstonia solanacearum*, Raza 2 sp). El objetivo es proporcionar una herramienta eficaz para que agricultores y técnicos identifiquen y monitoreen estas enfermedades de forma precisa, optimizando la gestión de cultivos. La metodología incluyó la construcción de un conjunto de datos personalizado, con imágenes aéreas capturadas mediante drones, procesadas y etiquetadas manualmente para entrenar un modelo de detección de objetos. Este modelo fue ajustado para clasificar hojas sanas, Moko Bacteriano y Sigatoka Negra, logrando una alta precisión en la identificación. Además, se implementó una aplicación web para la carga y análisis de imágenes, con visualización georreferenciada de los resultados en un mapa interactivo, y capacidad para extraer o simular coordenadas GPS. La evaluación del sistema, a través de métricas como precisión, recall, F1-Score y mAP, demostró su eficacia en escenarios de detección en campo. Este sistema contribuye al monitoreo eficiente y la detección temprana de enfermedades, mejorando la productividad y sostenibilidad de los cultivos de banano, y ofreciendo a los usuarios una herramienta clave para la toma de decisiones en el manejo agrícola.

Palabras clave: Detección de enfermedades, visión por computadora, plantaciones de banano, Moko Bacteriano, Sigatoka Negra, georreferenciación, , agricultura de precisión.

ABSTRACT

This research project develops a system based on computer vision and deep learning for the automatic detection of diseases in banana plantations, focusing on Moko Bacteriano (*Pseudocercospora fijiensis* sp) and Black Sigatoka (*Ralstonia solanacearum*, Race 2 sp). The objective is to provide an effective tool for farmers and technicians to accurately identify and monitor these diseases, optimizing crop management. The methodology included the construction of a customized dataset, with aerial images captured by drones, processed, and manually labeled to train an object detection model. This model was adjusted to classify healthy leaves, Moko Bacteriano, and Black Sigatoka, achieving high accuracy in identification. Additionally, a web application was implemented to upload and analyze images, featuring georeferenced visualization of the results on an interactive map and the ability to extract or simulate GPS coordinates. The system evaluation, through metrics such as precision, recall, F1-Score, and mAP, demonstrated its effectiveness in field detection scenarios. This system contributes to efficient monitoring and early detection of diseases, improving the productivity and sustainability of banana crops, while offering users a key tool for decision-making in agricultural management.

Keywords: Disease detection, computer vision, banana plantations, Moko Bacteriano, Black Sigatoka, georeferencing, precision agriculture.

TABLA DE CONTENIDO

PORTADA	i
DECLARACIÓN DE AUTORIA Y CESIÓN DE DERECHO	ii
CERTIFICACIÓN DE CULMINACION DEL PROYECTO DE INVESTIGACIÓN	iii
CERTIFICADO DEL REPORTE DE LA HERRAMIENTA DE PREVENCIÓN DE COINCIDENCIA Y/O PLAGIO ACADÉMICO.....	iv
CERTIFICADO DE APROBACIÓN POR TRIBUNAL DE SUSTENTACIÓN	v
AGRADECIMIENTOS.....	vi
DEDICATORIA.....	vii
RESUMEN	viii
ABSTRACT	ix
CÓDIGO DUBLÍN.....	xx
INTRODUCCIÓN.....	1
CAPÍTULO I	2
CONTEXTUALIZACIÓN DE LA INVESTIGACIÓN	2
1.1. Problema de investigación	3
1.1.1. Planteamiento del problema	3
1.1.2. Formulación del problema	4
1.1.3. Sistematización del problema	4
1.2. Objetivos.....	5
1.2.1. Objetivo general.....	5
1.2.2. Objetivos específicos.....	5
1.3. Justificación	5
CAPÍTULO II.....	7
FUNDAMENTACIÓN TEÓRICA DE LA INVESTIGACIÓN.	7
2.1. Marco Referencial	8
2.1.1. Investigaciones Internacionales.....	8

2.1.1.1. Fuentes de Resistencia a <i>Pseudocercospora fijiensis</i> , la causa de la Sigatoka Negra en el banano. (Sources of resistance to <i>Pseudocercospora fijiensis</i> , the cause of black Sigatoka in banana).	8
2.1.1.2. Semi-automatic leaf disease detection and classification system for soybean culture	9
2.1.1.3. AI-powered banana diseases and pest detection.	10
2.1.1.4. A Review of the Challenges of Using Deep Learning Algorithms to Support Decision-Making in Agricultural Activities.....	11
2.1.1.5. Machine learning en la detección de enfermedades en plantas	12
2.1.1.6. Metodología Propuesta para Identificación del Huanglongbing (HLB) en Limón Persa Mediante una Red Neuronal Artificial.....	13
2.1.1.7. Desarrollo de algoritmos de procesamiento de imágenes agrícolas obtenidas por drones para la detección de plantas faltantes en cultivos de maíz.	13
2.1.1.8. Caracterización morfológica y bioquímica de <i>Ralstonia solanacearum</i> Raza 2, bacteria patógena en cultivos de banano y plátano en El Carmen, Manabí, Ecuador	14
2.1.1.9. Amenazas de las manchas foliares de Sigatoka (<i>Mycosphaerella</i> spp.) en la producción sostenible de banano en el Ecuador	15
2.1.1.10. Contribución al conocimiento de la problemática fitosanitaria cardinal del cultivo de banano y plátano	16
2.1.1.11. Applications of Remote Sensing in Precision Agriculture: A Review	17
2.1.1.12. A Review on Unmanned Aerial Vehicle Remote Sensing: Platforms, Sensors, Data Processing Methods, and Applications	17
2.1.1.13. An Overview of Drones in Agriculture	18
2.2. Marco Conceptual.....	18
2.2.1. Teledetección	18
2.2.2. Espectro electromagnético.....	18
2.2.3. Sensores	19
2.2.4. Tipos de Plataformas de Observación	19

2.2.5. Agricultura de Precisión	19
2.2.5.1. Big Data en la Agricultura.	19
2.2.5.2. Agricultura Inteligente.	20
2.2.6. Vehículos aéreos no tripulados (drones).	20
2.2.6.1. Procesamiento de Imágenes Aéreas	20
2.2.7. Redes neuronales convolucionales.	21
2.2.8. Visión Artificial	21
2.2.9. Object Detection	21
2.2.9.1. Deep Learning	22
2.3. Marco Legal.....	22
2.3.1. Constitución de la República del Ecuador	22
2.3.2. La Ley Orgánica del Régimen de Soberanía Alimentaria (2009)	22
2.3.3. Ley de Sanidad Agropecuaria	23
2.3.4. Reglamento a la Ley de Aviación Civil	23
2.3.5. Convenio Internacional de Protección Fitosanitaria (CIPF)	23
CAPITULO III.....	24
METODOLOGÍA DE LA INVESTIGACIÓN.....	24
3.1. Localización.....	25
3.2. Tipo de investigación.....	25
3.2.1. Investigación Descriptiva	25
3.2.2. Investigación Aplicada	26
3.2.3. Investigación Cuantitativa	26
3.3. Métodos de Investigación	26
3.3.1. Enfoque Cuantitativo	26
3.4. Fuentes de recopilación de información	27
3.4.1. Fuentes de Información	27
3.5 Procedimiento	28

3.5.1. Captura de Imágenes Aéreas	28
3.5.1.1. Criterios de Selección del Dron	28
3.5.1.2. Criterios de Selección del Dron la Plataforma de Planificación de Vuelo ...	29
3.5.2. Recolección de Datos y Etiquetado	30
3.5.2.1. Validación del Etiquetado	31
3.5.3. Desarrollo del Modelo Computacional	31
3.5.3.1. Preprocesamiento del Dataset	32
3.5.3.1. Entrenamiento del Modelo	32
3.5.3.1. Evaluación del Modelo	34
3.5.4. Implementación de la Aplicación Web	34
3.5.4.1. Integración del Modelo de Detección	35
3.5.4.2 Visualización de Resultados	35
CAPITULO IV	38
RESULTADOS Y DISCUSIÓN	38
4.1. Análisis de los dispositivos (drones) y plataformas digitales	39
4.1.1. Análisis y selección del dispositivo	39
4.1.1.1 Tabla comparativa de vehículos aéreos no tripulados	39
4.1.1.2. Selección del Dron	40
4.1.2. Evaluación de Plataformas Digitales para la Planificación de Vuelo	41
4.1.2.1. Tabla comparativa de plataformas digitales para planificación de vuelos autónomos.....	41
4.1.2. Discusión de los resultados del primer objetivo específico	45
4.2. Creación de la data set de imágenes aéreas que resalten las características visuales ..	46
4.2.1. Recolección de Imágenes	46
4.2.2. Análisis y selección de características visuales	47
4.2.3. Etiquetado de Imágenes con Label Studio	49
4.2.4. Evaluación del Data set	52

4.2.5. <i>Discusión de los resultados del segundo objetivo específico</i>	53
4.2.5.1. <i>Desafíos</i>	54
4.2.5.2. <i>Impacto y Relevancia</i>	54
4.3. <i>Construcción de un modelo basado en visión artificial y aprendizaje profundo para la detección automática para implementarlo en una App Web con georreferenciación</i>	54
4.3.1. <i>Descripción de los Modelos y Configuraciones de Entrenamiento</i>	55
4.3.1.1. <i>Entrenamiento del Modelo MobileNet usando el motor de Teachable Machine de Google</i>	55
4.3.1.2. <i>Entrenamiento del Modelo EfficientDet-Lite0 (TensorFlow)</i>	63
4.3.1.3 <i>Entrenamiento del Modelo YOLOv5</i>	82
4.3.2. <i>Reentrenamiento del Modelo Predictivo</i>	109
4.3.3. <i>Evaluación del Modelo</i>	109
4.3.3. <i>Implementación de la Plataforma Web</i>	112
4.3.3.1. <i>Arquitectura y Tecnologías Utilizadas</i>	112
4.3.3.2. <i>Proceso de Carga y Análisis de Imágenes</i>	113
4.3.3.3. <i>Funcionalidad de Descarga de Reportes</i>	113
4.3.3.4 . <i>Descripción del Código Fuente y Flujo de Trabajo</i>	114
4.3.3.5. <i>Diseño de la Interfaz y Experiencia del Usuario</i>	115
4.3.3.6. <i>Pruebas, Optimización y Validación de la Plataforma</i>	116
4.3.3.7. <i>Georreferenciación con Google Maps</i>	117
4.3.3.8. <i>Procesamiento de Imágenes con YOLOv5</i>	118
CAPITULO V.....	120
CONCLUSIONES Y RECOMENDACIONES.....	120
5.1. Conclusiones:.....	121
5.2. Recomendaciones:	122
CAPITULO V.....	123
BIBLIOGRAFIA.....	123

5.1. Referencias	124
CAPITULO VI	128
ANEXOS.....	128
6.1. Anexo 1: Cronograma de Actividades del Proyecto.....	129
6.2. Anexo 2: Preparación de equipo para la obtención del Data Set.....	129
6.3. Anexo 3: Prueba de vuelo sobre plantación	130
6.4. Anexo 4: Vuelo sobre plantación de Banano	130
6.5. Anexo 5: Zona sin plantación por causa del Moko Bacteriano	131
6.6. Anexo 6: Resultado de la detección con el modelo entrenado	131
6.7. Anexo 7: Certificado del Data Set.....	132

ÍNDICE DE TABLAS

Tabla 1. Tabla Comparativa de Vehículos Aéreos no Tripulados.....	39
Tabla 2. Comparativa de Plataformas Digitales para Planificación de Vuelos Autónomos	42
Tabla 3. Características Visuales de la Sigatoka Negra y el Moko Bacteriano en Hojas de Banano	47
Tabla 4. Características visuales para la Identificación de Enfermedades	48
Tabla 5. Precisión por clase usando MobileNet con 50 épocas.....	57
Tabla 6. Precisión por clase usando MobileNet con 150 épocas.....	59
Tabla 7. Precisión por clase usando MobileNet con 200 épocas.....	62
Tabla 8. Precisión por clase usando EfficientDet-Lite0 con 50 épocas.....	65
Tabla 9. Precisión por clase usando EfficientDet-Lite0 con 150 épocas.....	69
Tabla 10. Precisión por clase usando EfficientDet-Lite0 con 200 épocas.....	72
Tabla 11. Precisión por clase usando EfficientDet-Lite0 con 50 épocas.....	75
Tabla 12. Precisión por clase usando EfficientDet-Lite0 con 150 épocas.....	78
Tabla 13. Precisión por clase usando EfficientDet-Lite0 con 200 épocas.....	81
Tabla 14. Precisión por clase usando YOLO v5 con 50 épocas.....	84
Tabla 15. Precisión por clase usando YOLO v5 con 150 épocas.....	87
Tabla 16. Precisión por clase usando YOLO v5 con 200 épocas.....	89
Tabla 17. Precisión por clase usando YOLO v5 con 50 épocas.....	92
Tabla 18. Precisión por clase usando YOLO v5 con 150 épocas.....	94
Tabla 19. Precisión por clase usando YOLO v5 con 200 épocas.....	97
Tabla 20. Precisión por clase usando YOLO v5 con 50 épocas.....	100
Tabla 21. Precisión por clase usando YOLO v5 con 150 épocas.....	103
Tabla 22. Precisión por clase usando YOLO v5 con 200 épocas.....	105
Tabla 23 . Análisis de resultados de los modelos entrenados.....	107

ÍNDICE DE FIGURAS

Ilustración 1. Portada del Artículo sobre la Sigatoka Negra, síntomas, y como contrarrestarla.	9
Ilustración 2. Portada del Artículo sobre Sistemas de Detección Temprana	10
Ilustración 3. Portada de la revista sobre Desarrollo de nuevas tecnologías de detección en agricultura	11
Ilustración 4. Portada de la Revista Tecnología, investigación y academia TIA.....	12
Ilustración 5. Portada del Artículo sobre la Sigatoka Negra	15
Ilustración 6. Portada de la revista verde	16
Ilustración 7. Ubicación Geográfica de la Hacienda la Lorena	25
Ilustración 8. Etiquetado usando el método de polígonos en Label Studio	49
Ilustración 9. Proceso de etiquetado en label studio.	50
Ilustración 10. Archivo de texto generado por Label Studio	50
Ilustración 11. Análisis de Distribución de Etiquetas	51
Ilustración 12. Matriz de confusión 50 épocas.....	56
Ilustración 13. Precisión por época (50)	57
Ilustración 14. Matriz de confusión 150 épocas.....	58
Ilustración 15. Precisión por época (150)	60
Ilustración 16. Matriz de confusión 200 épocas.....	61
Ilustración 17. Precisión por época (200)	62
Ilustración 18. Matriz de Confusión del modelo EfficientDet-Lite0 (50 épocas).....	64
Ilustración 19. Curva de Precisión-Recall para la Clase MOKO.....	66
Ilustración 20. Curva de Precisión-Recall para la Clase SANAS.....	66
Ilustración 21. Curva de Precisión-Recall para la Clase SIGATOKA.....	67
Ilustración 22. Matriz de Confusión del modelo EfficientDet-Lite0 150 épocas	68
Ilustración 23. Curva Precisión-Recall con 150 épocas	70
Ilustración 24. Matriz de Confusión del modelo EfficientDet-Lite0 200 épocas	71
Ilustración 25. Curva Precisión-Recall con 200 épocas	73
Ilustración 26. Matriz de Confusión del modelo EfficientDet-Lite0 50 épocas (512x512)	74
Ilustración 27. Curva de Precisión (Accuracy Curve), 50 épocas resolución 512x512	76
Ilustración 28. Matriz de Confusión del modelo EfficientDet-Lite0 50 épocas (512x512)	77

Ilustración 29. Curva de Precisión (Accuracy Curve), 150 épocas resolución 512x512 ...	79
Ilustración 30. Matriz de Confusión del modelo EfficientDet-Lite0 200 épocas (512x512)	80
Ilustración 31. Curva de Precisión (Accuracy Curve), 200 épocas resolución 512x512 ...	82
Ilustración 32. Matriz de Confusión del modelo YOLO v5 50 épocas.....	83
Ilustración 33. Matriz de Confusión del modelo YOLO v5 150 épocas.....	85
Ilustración 34. Matriz de Confusión del modelo YOLO v5 200 épocas.....	88
Ilustración 35. Matriz de Confusión del modelo YOLO v5 50 épocas.....	91
Ilustración 36. Matriz de Confusión del modelo YOLO v5 150 épocas.....	93
Ilustración 37. Matriz de Confusión del modelo YOLO v5 200 épocas.....	96
Ilustración 38. Matriz de Confusión del modelo YOLO v5 50 épocas.....	99
Ilustración 39. Matriz de Confusión del modelo YOLO v5 150 épocas.....	102
Ilustración 40. Matriz de Confusión del modelo YOLO v5 200 épocas.....	104
Ilustración 41. Matriz de Confusión.....	109
Ilustración 42. Curva de confianza.....	110
Ilustración 43. Curva de precisión y confianza	110
Ilustración 44. Curva de Recuperación de precisión.....	111
Ilustración 45. Curva Recuerdo-Confianza	111
Ilustración 46. Curvas de Pérdida y Métricas de Entrenamiento:	112
Ilustración 47. Muestra del archivo generado por la app web	114
Ilustración 48. Interfaz de Usuario	116
Ilustración 49. Puntos de detección de enfermedades.....	117
Ilustración 50. Georreferenciación de un mapeo autónomo con el dron	117
Ilustración 51. Detección en una plantación Sana	118
Ilustración 52. Detección en una plantación infectada con Moko Bacteriano	119
Ilustración 53. Detección en una plantación infectada con Sigatoka Negra.....	119

INDICE DE ANEXOS

Anexo 1. Cronograma de Actividades del Proyecto	129
Anexo 2. Preparación de equipo	129
Anexo 3. Prueba de vuelo.....	130
Anexo 4. Vuelo sobre una Plantación de banano a 100 m de altura	130
Anexo 5. Zona de Infección de Moko Bacteriano.....	131
Anexo 6. Resultado de detección con YOLO v5	131
Anexo 7. Documento que certifica la validez del documento.....	132

CÓDIGO DUBLÍN

Título:	Sistema de Teledetección Utilizando Drones para la Identificación de Enfermedades de banano en la hacienda La Lorena				
Autora:	Kevin Joel Cedeño Campoverde				
Palabras claves:	Detección de enfermedades	Visión por computadora	Plantaciones de banano	Moko Bacteriano	Sigatoka Negra
	Georreferenciación		Agricultura de precisión.		
Director del Proyecto	Ing. Cristian Gabriel Zambrano Vega, Ph.D.				
Fecha de publicación:	Noviembre, 2024				
Editorial:	Quevedo – UTEQ “La María”, 2024				
Resumen:	Este proyecto de investigación desarrolla un sistema basado en visión por computadora y aprendizaje profundo para la detección automática de enfermedades en plantaciones de banano, enfocándose en Moko Bacteriano (<i>Pseudocercospora fijiensis</i> sp) y Sigatoka Negra (<i>Ralstonia solanacearum</i>, Raza 2 sp). El objetivo es proporcionar una herramienta eficaz para que agricultores y técnicos identifiquen y monitoreen estas enfermedades de forma precisa, optimizando la gestión de cultivos. La metodología incluyó la construcción de un conjunto de datos personalizado, con imágenes aéreas capturadas mediante drones, procesadas y etiquetadas manualmente para entrenar un modelo de detección de objetos. Este modelo fue ajustado para clasificar hojas sanas, Moko Bacteriano y Sigatoka Negra, logrando una alta precisión en la identificación. Además, se implementó una aplicación web para la carga y análisis de imágenes, con visualización georreferenciada de los resultados en un mapa interactivo, y capacidad para extraer o simular coordenadas GPS. La evaluación del sistema, a través de métricas como precisión, recall, F1-Score y mAP, demostró su eficacia en escenarios de detección en campo. Este sistema contribuye al monitoreo eficiente y la detección temprana de enfermedades, mejorando la productividad y sostenibilidad de los cultivos de banano, y ofreciendo a los usuarios una herramienta clave para la toma de decisiones en el manejo agrícola.				
Abstract:	This research project develops a system based on computer vision and deep learning for the automatic detection of diseases in banana plantations, focusing on Moko Bacteriano (<i>Pseudocercospora fijiensis</i> sp) and Black Sigatoka (<i>Ralstonia solanacearum</i>, Race 2 sp). The objective is to provide an effective tool for farmers and technicians to accurately identify and monitor these diseases, optimizing crop management. The methodology included the construction of a customized dataset with aerial images captured by drones, processed, and manually labeled to train an object detection model. This model was adjusted to classify healthy leaves, Moko Bacteriano, and Black Sigatoka, achieving high accuracy in identification. Additionally, a web application was implemented to upload and analyze images, featuring georeferenced visualization of the results on an interactive map and the ability to extract or simulate GPS coordinates. The system evaluation, through metrics such as precision, recall, F1-Score, and mAP, demonstrated its effectiveness in field detection scenarios. This system contributes to efficient monitoring and early detection of diseases, improving the productivity and sustainability of banana crops, while offering users a key tool for decision-making in agricultural management.				
Descripción:	152 hojas A4: dimensiones, 29 x 21cm + CD-ROM 6162				
URL:					

INTRODUCCIÓN

En las últimas décadas, la agricultura ha enfrentado crecientes desafíos para satisfacer la demanda mundial de alimentos de manera sostenible. La presencia de enfermedades fitosanitarias representa una de las principales amenazas para la productividad de los cultivos a nivel global. El banano, considerado un producto básico de gran relevancia económica y alimentaria internacional, se ha posicionado como uno de los frutos tropicales más importantes a escala mundial. Ecuador destaca como uno de los mayores exportadores mundiales de este cultivo. Sin embargo, la producción bananera ecuatoriana enfrenta desafíos significativos debido a la presencia de enfermedades fitosanitarias como la Sigatoka Negra (*Mycosphaerella fijiensis*) y el Moko bacteriano (*Ralstonia Solanacearum*. Raza 2), que impactan negativamente en la productividad y rentabilidad de las plantaciones.

Actualmente, los métodos convencionales de detección de la Sigatoka Negra y el Moko bacteriano se basan en la inspección visual por parte de personal capacitado. Sin embargo, estos procesos presentan limitaciones significativas, al ser lentos y costosos en términos de talento humano. Esta situación dificulta la identificación temprana de los focos infecciosos, retrasando la aplicación oportuna de medidas de control fitosanitario y permitiendo la propagación descontrolada de las plagas en las plantaciones.

Por lo expuesto, este proyecto de investigación se enfocará en el desarrollo de un sistema innovador de teledetección utilizando vehículos aéreos no tripulados (drones) para la identificación de enfermedades en plantaciones de banano. Este sistema propuesto permitirá realizar un escaneo aéreo de las plantaciones, capturar imágenes de alta resolución y procesar digitalmente dichas imágenes mediante algoritmos de aprendizaje Profundo (visión artificial) para la detección y clasificación automática de la Sigatoka Negra y el Moko bacteriano.

La implementación de esta solución tecnológica busca mejorar sustancialmente las estrategias de monitoreo fitosanitario en las plantaciones de banano. De este modo, el sistema propuesto contribuirá a identificar y cuantificar estas plagas, optimizando el uso de recursos y reduciendo las cuantiosas pérdidas económicas que actualmente aquejan a los productores y la agroindustria bananera nacional.

CAPÍTULO I

CONTEXTUALIZACIÓN DE LA INVESTIGACIÓN

1.1. Problema de investigación

1.1.1. Planteamiento del problema

La Sigatoka negra y el Moko bacteriano son dos graves enfermedades que afectan los cultivos de banano. La Sigatoka Negra es causada por el hongo (*Pseudocercospora fijiensis* sp), mientras que el Moko es producido por la bacteria (*Ralstonia solanacearum*. Raza 2 sp). Estas enfermedades provocan la pérdida progresiva del área foliar funcional de la planta, reduciendo su capacidad de realizar la fotosíntesis. Esto se traduce en menores rendimientos y muerte prematura de las musáceas, con pérdidas económicas significativas para los productores [1].

Ecuador destaca como uno de los principales productores a nivel mundial de Banano, el monitoreo y la detección temprana de focos infectados es clave para el control eficiente de estas enfermedades. Sin embargo, la detección manual resulta lenta, subjetiva y costosa en términos de talento humano. Así mismo, los métodos manuales dificultan determinar con precisión la incidencia y severidad de las enfermedades en tiempo real [2].

Siendo Ecuador considerado como el mayor exportador de Banano no contamos con un sistema de monitoreo fitosanitario rápido y cuantitativo, que permita generar alertas tempranas y apoyar la toma de decisiones para una intervención oportuna. La implementación de nuevas tecnologías para la detección automática resulta clave para mejorar el manejo y control de la Sigatoka Negra y el Moko bacteriano en los cultivos de musáceas del Ecuador.

Diagnóstico

El cultivo de banano, siendo uno de los principales productos de exportación ecuatoriana también considerado como el mayor exportador de Banano a nivel mundial cubriendo un total del 29% del mercado internacional [3], se encuentra gravemente amenazado por enfermedades devastadoras como la Sigatoka Negra la cual puede provocar pérdidas de rendimiento de hasta el 50% en plantaciones severamente afectadas, y el Moko bacteriano que puede destruir por completo las plantaciones infectadas. Los métodos manuales tradicionales de detección resultan lentos, imprecisos y costosos, impidiendo una identificación temprana de focos infecciosos y su control oportuno. Esto conduce a propagaciones descontroladas que ocasionan cuantiosas pérdidas económicas por

reducción de rendimientos, muerte de plantas, incumplimiento de estándares de exportación y gastos en medidas de control tardías.

Ante esta alarmante situación, se vuelve importante implementar soluciones tecnológicas innovadoras de teledetección aérea y procesamiento digital de imágenes. Estos sistemas permitirían el escaneo automático de grandes extensiones de cultivo, detectando de forma temprana la presencia de estas enfermedades. De esta forma, se lograría una intervención focalizada que evite la diseminación masiva de los patógenos, reduciendo drásticamente el impacto económico y asegurando la sostenibilidad productiva y competitiva de la agroindustria bananera nacional.

Pronóstico

Sin una solución tecnológica para la detección temprana y el monitoreo efectivo de enfermedades como la Sigatoka Negra y el Moko bacteriano en los cultivos de banano, la situación empeorará. Los métodos de inspección visual manual serán insuficientes frente al aumento del área cultivada y la propagación de estas plagas, causando mayores pérdidas de producción y costos fitosanitarios. Esto afectará negativamente la rentabilidad de los productores y comprometerá la calidad de las exportaciones, poniendo en riesgo la posición de Ecuador en el mercado mundial. Las familias dependientes de esta actividad y la seguridad alimentaria nacional también se verán amenazadas. Por lo tanto, la implementación de un sistema automatizado de detección temprana es esencial para identificar estas plagas, y estas puedan ser tratadas a tiempo reduciendo así su impacto económico y social.

1.1.2. Formulación del problema

¿Es factible desarrollar un sistema de teledetección aérea que identifique de manera temprana y precisa la Sigatoka Negra y el Moko bacteriano en cultivos de banano?

1.1.3. Sistematización del problema

Establecido el problema principal de investigación, a continuación, las interrogantes que ayudarían a cumplir exitosamente con cada objetivo:

- I. *¿Qué dispositivos y plataformas digitales son los más adecuados para la captura de imágenes aéreas de alta resolución en cultivos de banano, permitiendo un escaneo efectivo?*

- II. *¿Cómo elaborar un conjunto de datos (dataset) representativo de imágenes que resalte eficazmente las características visuales distintivas de la Sigatoka Negra y el Moko bacteriano en plantaciones de banano?*
- III. *¿Cómo puede la tecnología reducir la brecha en el desarrollo técnico para la identificación de enfermedades en el cultivo de banano?*

1.2. Objetivos.

1.2.1. Objetivo general.

Desarrollar un sistema de teledetección aérea que permita la identificación de Sigatoka Negra y Moko en plantaciones de banano utilizando técnicas de visión artificial.

1.2.2. Objetivos específicos.

- Analizar los dispositivos (drones) y plataformas digitales (App de planificación de Vuelo) compatibles para ser implementados en el sistema de teledetección aérea.
- Elaborar una data set de imágenes aéreas que resalten las características visuales de la Sigatoka Negra y el Moko Bacteriano en plantaciones de Banano.
- Diseñar y aplicar un modelo computacional basado en técnicas de visión artificial y aprendizaje profundo (Deep Learning) para la detección y clasificación automática de la Sigatoka Negra y el Moko bacteriano en imágenes aéreas de cultivos de banano, complementado con una plataforma web para la visualización georreferenciada de los resultados del proceso de detección.

1.3. Justificación

El cultivo de banano representa una actividad agrícola de enorme relevancia económica y social en el Ecuador. Siendo un país considerado como uno de los mayores exportadores a nivel mundial de este fruto, no contamos con avances tecnológicos para este sector productivo, estos cultivos se encuentran amenazados por enfermedades fitosanitarias como la Sigatoka Negra y el Moko bacteriano, que provocan elevadas pérdidas por reducción de rendimiento y muerte prematura de plantas infectadas.

Esta problemática dificulta identificar y controlar oportunamente los focos infecciosos antes de su propagación masiva en las plantaciones. Ante esta situación, el desarrollo de un sistema de teledetección aérea de enfermedades, mediante el procesamiento inteligente de datos, representa una solución innovadora. El sistema permitiría la detección, clasificación efectiva, y mapeo georreferenciado preciso de ambas enfermedades a partir del análisis digital de imágenes capturadas mediante Drones.

Esto facilitaría la generación de alertas tempranas y la aplicación dirigida de medidas de control en los focos detectados de manera oportuna. De esta forma, el sistema propuesto tendría un impacto positivo al mejorar sustancialmente las estrategias de manejo fitosanitario, reduciendo las pérdidas económicas causadas por el tardío control de la Sigatoka negra y el Moko bacteriano en los cultivos de banano del Ecuador.

CAPÍTULO II

FUNDAMENTACIÓN TEÓRICA DE LA INVESTIGACIÓN.

2.1. Marco Referencial

2.1.1. Investigaciones Internacionales

2.1.1.1. Fuentes de Resistencia a *Pseudocercospora fijiensis*, la causa de la Sigatoka Negra en el banano. (Sources of resistance to *Pseudocercospora fijiensis*, the cause of black Sigatoka in banana).


La sigatoka negra es una enfermedad fúngica que afecta al plátano y al banano. Fue detectada por primera vez en Fiji en 1963, y desde entonces se ha extendido a la mitad de todos los países productores de este fruto. La enfermedad es causada por el hongo *Pseudocercospora fijiensis*, que se propaga por esporas que se dispersan por el viento y la lluvia, siendo así considerada una de las principales enfermedades que ataca a cultivos en el mundo.

La sigatoka negra es una enfermedad con múltiples fases que afecta a las hojas de los plátanos y bananos. Los síntomas incluyen manchas oscuras en las hojas, que se extienden y se fusionan para formar grandes áreas necróticas.

Se trató de controlar la enfermedad mediante químicos durante los primeros años. Sin embargo, el uso excesivo de fungicidas ha provocó nuevas cepas resistentes a los mismos, lo que ha aumentado la necesidad de encontrar soluciones alternativas. A lo largo de los años, se han utilizado diferentes métodos para combatirla, pero el desarrollo de variedades genéticamente resistentes es la solución más prometedora para garantizar la seguridad alimentaria y la sostenibilidad de los cultivos de plátanos y bananos.

La calidad de la producción de banano está directamente vinculada al cuidado y control temprano y efectivo de las enfermedades fitosanitarias. La falta de gestión adecuada podría resultar perjudicial tanto para la producción en sí como para los productores, quienes, en última instancia, serían los más afectados económicamente. Este artículo ofrece una visión completa, desde el descubrimiento de la enfermedad hasta las estrategias empleadas para contrarrestarla. Se destaca la naturaleza devastadora de estas enfermedades para los cultivos mencionados, ya que pueden afectar vastas extensiones de plantaciones si no se controlan de manera oportuna y eficiente [1].

Ilustración 1. Portada del Artículo sobre la Sigatoka Negra, síntomas, y como contrarrestarla.



Autor: Plant Pathology

Fuente: <https://bsppjournals.onlinelibrary.wiley.com/doi/10.1111/ppa.13408>

2.1.1.2. *Semi-automatic leaf disease detection and classification system for soybean culture.*

Este artículo enfatiza la detección temprana de enfermedades foliares en plantaciones; es necesario ya que si no son detectados a tiempo pueden afectar significativamente a la producción, siendo así importante tomar en cuenta estos sistemas para minimizar las pérdidas. El artículo se centra en la detección de enfermedades foliares en Soja, tomando como referencia ciertas enfermedades como son el Míndiu Velloso, el ojo de Rana, y la Septoria, siendo enfermedades que pueden afectar a la calidad y rendimiento de las plantas.

El sistema de detección toma un enfoque semiautomático, este usa conceptos de k-means para poder distinguir entre las hojas infectadas y las sanas, siendo así que se crea un modelo que se entrena en base a vectores de soporte (SVM), permitiendo identificar entre las 3 clases de enfermedades antes mencionadas, las características implementadas para el reconocimiento son el color y la textura.

Este sistema fue probado con la ayuda de la recopilación de miles de imágenes depositadas en una base de datos (PlantVillage), los resultados del sistema se consideran

aceptables con un 90% de precisión a la hora de escanear las plantas. El sistema demostró ser eficaz en la detección, clasificación y cálculo de la gravedad de las enfermedades foliares en el cultivo de soja, lo que lo convierte en un avance significativo en la agricultura de precisión [4].

Ilustración 2. *Portada del Artículo sobre Sistemas de Detección Temprana*



Autor: IET Image Processing

Fuente: <https://ietresearch.onlinelibrary.wiley.com/doi/full/10.1049/iet-ipr.2017.0822>

2.1.1.3. *AI-powered banana diseases and pest detection.*

Este artículo menciona la importancia de la detección temprana de enfermedades en los cultivos de banano, ya que este fruto es considerado uno de los más importantes del mundo, siendo un alimento básico en África, Asia y América Latina, distintas enfermedades atacan a esta clase de cultivos, generando importantes pérdidas de rendimiento en los países productores, y amenaza a la seguridad alimentaria mundial.

El método tradicional de detección no es eficiente, ya que necesita expertos en el tema de enfermedades fitosanitarias, los cuales son limitados, por eso mencionan como alternativa el uso de IA (inteligencia artificial) para el análisis de imágenes, todo esto haciendo uso de un modelo de red Neuronal siendo así que esto facilite la detección de las enfermedades.

Para desarrollar este sistema de detección temprana se recolecto en una base de datos un total de 18000 imágenes de campo, cada una de ellas fue etiquetada por expertos en el tema, al entrenar el modelo de red Neuronal se usó distintos modelos Neuronales como ResNet50, InceptionV2 y MobileNetV1.

Como resultado se obtuvo un sistema con una precisión del 99% en el escaneo de el tallo, racimo y el cormo, la precisión varía según el área escaneada de la planta obteniendo una presión del 70% -73% en el escaneo de la planta entera. Siendo asi que se requiere mas investigación en el tema para la mejora de la detección de este sistema en áreas como las hojas y la planta completa [5].

Ilustración 3. *Portada de la revista sobre Desarrollo de nuevas tecnologías de detección en agricultura*



Autor: Plant Methods

Fuente: <https://plantmethods.biomedcentral.com/>

2.1.1.4. A Review of the Challenges of Using Deep Learning Algorithms to Support Decision-Making in Agricultural Activities.

El deep learning ha emergido como una herramienta clave en la agricultura, especialmente en la identificación de enfermedades y la mejora de la gestión de cultivos. Sin embargo, la variabilidad del entorno agrícola complica la generalización de los modelos, lo que exige una adaptación cuidadosa a las diferentes condiciones.

Las redes neuronales convolucionales (CNN) han mostrado eficacia en la clasificación de enfermedades en plantas, pero la recopilación y preparación de datos sigue siendo un reto.

El uso de técnicas como el aprendizaje por transferencia y la aumentación de datos ha permitido mejorar la precisión, incluso con conjuntos de datos limitados [6]. Es crucial que estos modelos funcionen en tiempo real para ser aplicables en el campo. La integración de modelos de deep learning en dispositivos accesibles y su uso en granjas inteligentes presenta oportunidades prometedoras, aunque aún quedan desafíos técnicos por superar.

2.1.1.5. *Machine learning en la detección de enfermedades en plantas.*

El artículo menciona cómo el Machine Learning está revolucionando la agricultura al automatizar la detección de enfermedades en plantas. Con el creciente desafío de satisfacer la demanda global de alimentos, la identificación manual de enfermedades resulta ineficiente y consume mucho tiempo, especialmente en grandes cultivos.

Los algoritmos de Machine Learning, como las redes neuronales convolucionales (CNN) y las máquinas de vectores de soporte (SVM), han demostrado ser eficaces para detectar enfermedades mediante el análisis de imágenes de plantas. Estas técnicas permiten una identificación más rápida y precisa que los métodos tradicionales. En el artículo se menciona que, para mejorar la precisión de estos modelos, es fundamental entrenarlos con un gran número de muestras variadas. Esto asegura que los algoritmos puedan generalizar mejor sus predicciones en distintas condiciones, optimizando su uso en el campo [7].

Ilustración 4. Portada de la Revista Tecnología, investigación y academia TIA



Autor: Tecnología, investigación y academia TIA

Fuente: <https://revistas.udistrital.edu.co/index.php/tia/issue/view/1011>

2.1.1.6. Metodología Propuesta para Identificación del Huanglongbing (HLB) en Limón Persa Mediante una Red Neuronal Artificial.

El artículo menciona la aplicación de una red neuronal artificial para la detección del Huanglongbing (HLB), una enfermedad altamente destructiva que afecta a los cítricos, en hojas de limón persa. La detección temprana del HLB es fundamental para prevenir su propagación y mitigar las pérdidas en la producción agrícola.

Las imágenes utilizadas en la investigación incluyeron hojas infectadas y no infectadas con HLB. Estas imágenes fueron convertidas a escala de grises y ajustadas a una resolución uniforme de 200 por 350 píxeles. Para destacar las características clave de las hojas, se aplicó el algoritmo de Canny, que facilita la detección de bordes y mejora la precisión en la identificación de los síntomas de la enfermedad. Dado que las imágenes en bruto contienen una gran cantidad de datos, se empleó el Análisis de Componentes Principales (PCA) para reducir la dimensionalidad en un 50%. Esta reducción optimizó el procesamiento de las imágenes sin comprometer significativamente la información necesaria para la identificación del HLB [8].

Se diseñó una red neuronal multicapa que se entrenó y validó utilizando la técnica de validación cruzada k-fold. Este método permitió evaluar el modelo con diferentes subconjuntos de datos, logrando una precisión del 80%. Estos resultados subrayan la eficacia de la inteligencia artificial para la detección de enfermedades en la agricultura. El modelo propuesto demostró ser una herramienta eficaz, especialmente útil para pequeños productores que no siempre tienen acceso a revisiones oficiales de sanidad. Sin embargo, el estudio recomienda ampliar la base de datos de imágenes para mejorar la precisión del modelo. [8]

2.1.1.7. Desarrollo de algoritmos de procesamiento de imágenes agrícolas obtenidas por drones para la detección de plantas faltantes en cultivos de maíz.

La investigación aborda la problemática con la detección de plantas ausentes en cultivos de maíz, debido a la inversión considerable de recursos y tiempo que los agricultores destinan al monitoreo mediante métodos tradicionales, lo cual motiva la búsqueda de soluciones más eficientes y tecnológicamente avanzadas.

La adopción de tecnologías emergentes en el sector agrícola, como el empleo de vehículos aéreos no tripulados (UAV) para la agricultura de precisión, ha sido un enfoque pionero en varios países. Al buscar la solución se dio con el desarrollo de algoritmos mediante la técnica de visión por computadora para la detección de plantas ausentes en cultivos de maíz. Esta aproximación se basa en el análisis de imágenes capturadas por drones a alturas de 5, 10 y 15 metros sobre el suelo.

La elección de la altura de vuelo se fundamenta en la búsqueda de la mejor perspectiva para la detección eficaz de plantas faltantes. La implementación de los algoritmos se realiza utilizando Matlab, versión 2017b, y se sigue una metodología de cascada para garantizar la consecución ordenada de los diferentes entregables en cada fase del desarrollo [9].

2.1.1.8. Caracterización morfológica y bioquímica de *Ralstonia solanacearum* Raza 2, bacteria patógena en cultivos de banano y plátano en El Carmen, Manabí, Ecuador.

La bacteria *Ralstonia solanacearum* Raza 2 es la causa del Moko, esta enfermedad es considerada como una de las más dañinas para cultivos de plátano y banano a nivel mundial, siendo así que puede causar la pérdida total de una plantación generando pérdidas económicas considerables. La bacteria es capaz de penetrar desde las raíces y atacar el sistema vascular de la planta, siendo así que evita que esta absorba agua y nutrientes [2].

Las plantaciones de musáceas en el Ecuador representan el 20.57 % de la superficie plantada, siendo así a escala nacional la segunda plantación más rentable, después del cacao [10]. Entre los síntomas más perceptibles de esta enfermedad destaca el amarillamiento y marchitamiento de la planta, estrías y pudrición en los frutos que resalta la coloración negra, deformación de los racimos del fruto, entre otras.

Se transmite por material de siembra contaminado e incluso por insectos, esta bacteria puede estar presente en el suelo, agua, y plantas hospederas alternas. Para poder controlar esta enfermedad se trata de seleccionar las semillas sanas (colinos), y por medios químicos (fungicidas). Este artículo destaca que el Moko del plátano y banano es una grave enfermedad bacteriana que puede afectar plantaciones completas y causa grandes pérdidas económicas a nivel global y nacional [2].

Ilustración 5. Portada del Artículo sobre la Sigatoka Negra



Autor: Siembra

Fuente: <https://revistadigital.uce.edu.ec/index.php/SIEMBRA/article/view/4305>

2.1.1.9. Amenazas de las manchas foliares de Sigatoka (*Mycosphaerella* spp.) en la producción sostenible de banano en el Ecuador.

En este estudio aborda la amenaza que representan las enfermedades foliares de Sigatoka, causadas por el hongo *Mycosphaerella* spp., para la sostenibilidad de la producción de banano en Ecuador. Este cultivo es vital para la economía ecuatoriana, representando una porción significativa del PIB agrícola y proporcionando empleo a millones de personas.

La Sigatoka negra es una de las enfermedades más destructivas que afecta a las plantaciones de banano en Ecuador y otros países productores. Este patógeno no solo reduce drásticamente el rendimiento del cultivo, sino que también aumenta significativamente los costos de producción debido a la necesidad de aplicar fungicidas de manera continua. Los productores, especialmente los pequeños, enfrentan dificultades para costear los controles químicos necesarios, lo que los hace vulnerables a pérdidas económicas sustanciales.

El artículo destaca que la lucha contra la Sigatoka negra ha llevado a un uso intensivo de fungicidas, con efectos adversos tanto económicos como ambientales. Para garantizar la sostenibilidad de la producción de banano en Ecuador, es crucial buscar alternativas al uso intensivo de fungicidas. Esto incluye investigar métodos de control biológico, tecnológico y cultural que puedan reducir la dependencia de los productos químicos,

asegurando así la continuidad de una industria vital para la economía del país y el bienestar de millones de personas [11].

Ilustración 6. *Portada de la revista verde*



Autor: Dialnet

Fuente: <https://dialnet.unirioja.es/servlet/articulo?codigo=7266829>

2.1.1.10. Contribución al conocimiento de la problemática fitosanitaria cardinal del cultivo de banano y plátano.

El artículo aborda la seria amenaza que el Moko bacteriano, causado por *Ralstonia solanacearum* Raza 2, representa para las plantaciones de banano, especialmente en regiones tropicales como Ecuador. Este patógeno se propaga rápidamente a través de insectos, herramientas contaminadas y el agua de riego, lo que lo convierte en una enfermedad difícil de controlar.

Los síntomas iniciales del Moko incluyen el amarillamiento y colapso de las hojas jóvenes, seguido de la necrosis de la hoja candela. A medida que la enfermedad avanza, se observa la necrosis de los tejidos vasculares en el pseudotallo, lo que interfiere con la circulación de nutrientes y debilita la planta. Los frutos inmaduros afectados presentan una coloración amarilla anómala y pudrición seca, reduciendo la calidad comercial del banano.

El artículo destaca la complejidad del manejo de esta enfermedad, subrayando que las medidas convencionales no son suficientes en áreas donde el Moko está bien establecido. Se propone un enfoque integral que combine prácticas culturales, control biológico y un

uso limitado de químicos para mitigar los efectos de la enfermedad y asegurar la sostenibilidad de las plantaciones [12].

2.1.1.11. *Applications of Remote Sensing in Precision Agriculture: A Review.*

La agricultura de precisión (PA) es una estrategia clave para mejorar la eficiencia agrícola y minimizar el impacto ambiental. Este enfoque se basa en tecnologías avanzadas, siendo la teledetección una herramienta fundamental. A través de imágenes de alta resolución obtenidas por satélites y vehículos aéreos no tripulados (Drones), la teledetección permite el monitoreo detallado de cultivos, la gestión óptima del riego, y la aplicación precisa de nutrientes.

Este artículo menciona los avances en teledetección y su integración con tecnologías emergentes como la inteligencia artificial y el análisis de Big Data, que facilitan la toma de decisiones en tiempo real. Sin embargo, se destaca la necesidad de desarrollar sistemas más accesibles y fáciles de usar para promover su adopción masiva. Además, se identifican desafíos y oportunidades para la implementación efectiva de la teledetección en la PA, subrayando la importancia de la investigación continua para optimizar su aplicación en la agricultura moderna [13].

2.1.1.12. *A Review on Unmanned Aerial Vehicle Remote Sensing: Platforms, Sensors, Data Processing Methods, and Applications.*

La teledetección con vehículos aéreos no tripulados (Drones) ha revolucionado diversas industrias al proporcionar imágenes de alta resolución y una gran flexibilidad operativa. Equipados con sensores como cámaras ópticas y LIDAR, los Drones superan muchas de las limitaciones de la teledetección satelital, permitiendo observaciones detalladas incluso en condiciones adversas.

Este artículo revisa las plataformas con Drones, los sensores utilizados y los métodos avanzados de procesamiento de datos aplicados en campos como la agricultura de precisión, la silvicultura y la monitorización de infraestructuras. Además, se discuten las limitaciones actuales y se exploran futuras direcciones de investigación para mejorar la eficiencia y ampliar las aplicaciones de los Drones en la teledetección[14].

2.1.1.13. *An Overview of Drones in Agriculture.*

El uso de drones está transformando la agricultura moderna al ofrecer herramientas avanzadas para la gestión precisa de cultivos y la optimización de recursos. Estos dispositivos, equipados con diversos sensores, permiten realizar tareas como el monitoreo de la salud de los cultivos, la detección temprana de enfermedades, la gestión del riego, y la aplicación precisa de pesticidas y fertilizantes.

El artículo destaca cómo los avances tecnológicos han permitido que los drones se integren en prácticas agrícolas, mejorando la eficiencia y reduciendo costos. Sin embargo, también se abordan los desafíos asociados con su implementación, como el costo inicial, la necesidad de formación técnica, y la interpretación de los datos generados.

A medida que la tecnología de drones continúa avanzando, se espera que su uso en la agricultura siga creciendo, ofreciendo soluciones innovadoras para mejorar la productividad y minimizar el impacto ambiental [15].

2.2. Marco Conceptual

2.2.1. *Teledetección*

La teledetección es la ciencia en conjunto con la tecnología que nos permite obtener información sobre objetos, o incluso aéreas a distancia, todo esto sin la necesidad de mantener un contacto físico con ellos, es decir que mediante el uso de sensores remotos que permitan la detección y medición de la radiación electromagnética emitida o reflejada, la temperatura, entre otros [16].

Esta es una herramienta muy útil en las investigaciones ecológicas, ya que permite trabajar en áreas extensas de terreno, y podemos obtener información a diferentes escalas espaciales. Podemos mapear un terreno o incluso cuantificar objetos de interés e incluso fenómenos en la vegetación como enfermedades [17].

2.2.2. *Espectro electromagnético*

El espectro electromagnético es el conjunto de longitudes de onda posible de la radiación del espectro visible, el cual tiene colores azul, rojo y verde, una cámara normal RGB puede detectar esta radiación, también podemos encontrar a ondas que viajan

transmitiendo energía, dentro de este concepto encontramos a los infrarrojos, microondas y ondas de radio [18].

2.2.3. Sensores

Los sensores son dispositivos que pueden ser utilizados en satélites o drones para capturar distinta información, los sensores existen de dos tipos activos y pasivos, los activos generan su propia energía o señal, y el pasivo depende de las energías externas, el fin de estos dispositivos es obtener información para luego ser sometida a distintos análisis y toma de decisiones [18].

2.2.4. Tipos de Plataformas de Observación

La teledetección se apoya en diversas plataformas de observación que cumplen el papel de recolectar datos, para luego estos ser analizados, los satélites orbitan la tierra y proporcionan una visión global, aunque con limitaciones en la resolución espacial. En cambio, los drones o vehículos no tripulados se destacan por la flexibilidad y la alta resolución espacial. La diversidad de estas plataformas permite adaptarse a distintos escenarios [19].

2.2.5. Agricultura de Precisión

Se puede definir a la Agricultura de Precisión a la gestión de cultivos con la utilización de tecnologías como sensores, imágenes satelitales, drones, GPS, entre otros, sea para medir, mapear, y obtener información relevante sobre alguna plantación o zona en específico. Lo que busca esta nueva agricultura es incrementar el rendimiento en las plantaciones, optimizar el uso de insumos, reducir costos, mejorar la explotación agrícola, y prever enfermedades y plagas que pueden afectar a los cultivos [20].

2.2.5.1. Big Data en la Agricultura.

La agricultura moderna se beneficia enormemente de la gran cantidad de datos disponibles a través de tecnologías como sensores, IoT y datos abiertos. Estos datos, cuando se procesan adecuadamente, permiten a los agricultores optimizar la producción, mejorar la gestión de recursos y tomar decisiones más informadas [21].

2.2.5.2. Agricultura Inteligente.

Va un paso más allá que la agricultura de precisión al integrar datos en tiempo real y análisis avanzados para mejorar aún más la toma de decisiones. La agricultura inteligente no solo se basa en la variabilidad espacial de los cultivos, sino que también incorpora datos contextuales para optimizar la gestión agrícola de manera más integral[21].

2.2.6. Vehículos aéreos no tripulados (drones)

El Dron es un vehículo aéreo no tripulado, lo que quiere decir que puede ser controlado tanto de forma remota, o con sistemas de planificación de vuelo (piloto automático), este puede ser empleado tanto para fines creativos o profesional, como es el en el caso de la agricultura de precisión, donde se lo implementa como plataforma para la teledetección. El dron debe estar construido con materiales ligeros, y motores eléctricos, para que este pueda volar de forma estable y realizar maniobras complicadas [22].

El empleo creciente de drones con cámaras y sensores en la agricultura ha revolucionado la captura de imágenes aéreas de los cultivos. Estas imágenes ofrecen información sobre diversos aspectos de las plantas, como su desarrollo y condición de salud. Además de su capacidad para proporcionar datos detallados, los drones también destacan por su eficacia al aplicar de manera precisa y eficiente pesticidas y fertilizantes en los campos agrícolas.

2.2.6.1. Procesamiento de Imágenes Aéreas.

Para realizar el procesamiento de las imágenes, se necesita de un dron para la toma de estas en alta resolución, el uso del dron es más común para esta tarea ya que llegar a áreas de difícil acceso le es más fácil. Las imágenes capturadas por el dron suelen ser multiespectrales, pero también se puede hacer uso de una cámara normal para este propósito, lo que quiere decir que las capturas se basan en diferentes bandas del espectro electromagnético como el infrarrojo, esto permite resaltar características importantes en los cultivos. El procesamiento de las imágenes incluye la generación de ortomosaicos, que son imágenes corregidas geométricamente, y de modelos digitales 3D de elevación [23].

A partir de estas imágenes se puede calcular el índice de vegetación y la salud de los cultivos, el procesamiento de la imagen se puede realizar a través de software de terceros, o incluso desarrollar nuestro modelo para identificar la característica que necesitamos.

2.2.7. Redes neuronales convolucionales.

Las redes neuronales convolucionales (CNN) representan un tipo de red neuronal artificial que trata de imitar al cortex visual humano, permitiendo la identificación de diversas características en las entradas. El uso más común es en el análisis de imágenes y reconocimiento de patrones, estas redes están compuestas por capas ocultas especializadas organizadas jerárquicamente. En este proceso, las primeras capas detectan propiedades o formas fundamentales, y a medida que avanzan hacia capas más profundas, adquieren la capacidad de reconocer formas complejas, como rostros o siluetas [24].

2.2.8. Visión Artificial

La visión Artificial está dentro del campo de la Inteligencia Artificial, la cual busca dar a las computadoras, la capacidad de interpretar y analizar imágenes, y videos, tal cual lo hace la visión humana, utiliza técnicas de aprendizaje como el Machine Learning para entrenar modelos computacionales, los modelos de aprendizaje automático más utilizados como las redes neuronales convolucionales, máquinas de soporte vectorial y el k-means, requieren de una base de datos previamente etiquetada para poder entrenarse y aprender a reconocer y detectar objetos. El fin de esta herramienta es el análisis de imágenes y videos para poder obtener un resultado como la diferencia entre plantas en un sembrío o la automatización de una tarea.

2.2.9. Object Detection

La evolución del object detection (Detección de objetos) ha sido notable en los últimos años, impulsada por el avance del deep learning y las redes neuronales convolucionales (CNN). En contraste con los métodos tradicionales que empleaban extracción manual de características, los enfoques actuales se apoyan en CNN para aprender automáticamente características semánticas de alto nivel a partir de extensos conjuntos de datos. Este enfoque ha demostrado mejoras significativas en la detección de objetos genéricos, objetos salientes, caras, plantas, y cultivos enteros. Entre las metodologías destacadas se encuentran R-CNN y sus variantes, que utilizan propuestas de regiones, así como YOLO y SSD, que realizan un mapeo directo desde píxeles a bounding boxes. Factores cruciales para un rendimiento óptimo incluyen el diseño de la red, el entrenamiento multitarea, las representaciones multi escala y el modelado contextual. Sin embargo, persisten desafíos, como la detección de objetos pequeños y la adaptación al entorno de video [25].

2.2.9.1. *Deep Learning.*

El Deep Learning se enfoca en la capacidad de las redes neuronales artificiales para aprender características complejas, esenciales para tareas como el reconocimiento de objetos y la comprensión del lenguaje. La utilización de vectores de actividad neuronal y matrices de pesos permite una generalización automática. La profundidad de las redes neuronales es clave para su éxito. El preentrenamiento no supervisado extrae estructuras relevantes de conjuntos no etiquetados, impactando significativamente en la generalización. Mecanismos como la atención suave introducen interacciones efectivas para trabajar sobre diferentes estructuras de datos [26].

2.3. Marco Legal

El marco legal que regula la investigación sobre el "Sistema de Teledetección Utilizando Drones para la Identificación de Enfermedades de Banano" en Ecuador está fundamentado en diversas normativas nacionales e internacionales que aseguran la sostenibilidad, seguridad, y legalidad del proyecto.

2.3.1. *Constitución de la República del Ecuador*

La Constitución del Ecuador, en su Artículo 71, reconoce los derechos de la naturaleza, estableciendo que la naturaleza tiene derecho a que se respete su existencia y el mantenimiento y regeneración de sus ciclos vitales, estructura, funciones y procesos evolutivos. Este artículo es esencial para garantizar que el uso de drones y la teledetección en plantaciones de banano no impacte negativamente el ambiente, promoviendo un desarrollo agrícola sostenible [27].

2.3.2. *La Ley Orgánica del Régimen de Soberanía Alimentaria (2009)*

En el Artículo 1, dispone que: "Esta ley tiene por objeto garantizar la soberanía alimentaria del país a través de la producción, distribución, y consumo de alimentos en condiciones que aseguren una alimentación sana, suficiente, nutritiva, y culturalmente apropiada para toda la población [28]."

La investigación contribuye directamente a la soberanía alimentaria al mejorar las prácticas fitosanitarias en los cultivos de banano, una de las principales fuentes de alimento y exportación en Ecuador. Al identificar las enfermedades como la Sigatoka

Negra y el Moko bacteriano, se facilita la intervención oportuna, protegiendo así la producción agrícola del país.

2.3.3. *Ley de Sanidad Agropecuaria*

La Ley de Sanidad Agropecuaria (2017), en su Artículo 1, indica que: "Esta ley tiene como objeto la protección y conservación de la sanidad animal y vegetal mediante la prevención, control y erradicación de plagas y enfermedades, garantizando la inocuidad de los alimentos y facilitando el comercio agrícola [29]. "

Esta ley es particularmente relevante para la investigación, ya que el desarrollo de un sistema de detección temprana de enfermedades en banano se alinea con los objetivos de proteger la sanidad vegetal. La implementación de tecnologías como la teledetección ayuda a mejorar la efectividad de las medidas fitosanitarias, reduciendo el impacto de las enfermedades en la producción agrícola.

2.3.4. *Reglamento a la Ley de Aviación Civil*

El Reglamento a la Ley de Aviación Civil, regula el uso de vehículos aéreos no tripulados (drones) en Ecuador, estableciendo que: "Todo operador de un vehículo aéreo no tripulado (VANT) deberá cumplir con las normas de operación establecidas por la Dirección General de Aviación Civil (DGAC) y obtener las autorizaciones correspondientes para su uso [30]."

Este reglamento es esencial para la investigación, ya que regula el uso de drones, asegurando que su operación en las plantaciones de banano sea segura y cumpla con todas las normativas establecidas por la DGAC. Esto incluye la necesidad de registro, la obtención de permisos y la observación de limitaciones operativas.

2.3.5. *Convenio Internacional de Protección Fitosanitaria (CIPF)*

El Convenio Internacional de Protección Fitosanitaria (1997), en su Artículo I, establece que: "El propósito del Convenio es proteger los recursos vegetales cultivados y silvestres de la introducción y propagación de plagas y enfermedades [31]. "


CAPITULO III

METODOLOGÍA DE LA INVESTIGACIÓN

3.1. Localización

La investigación se realizó en plantaciones de banano de la Hacienda La Lorena, ubicada en Quinsaloma-Los Ríos, Ecuador, con coordenadas 1° 9' 25.20" S, 79° 22' 28.92" O. Se seleccionaron fincas de 50 hectáreas con variedades susceptibles a Sigatoka Negra y Moko dentro de esta hacienda.

Ilustración 7. *Ubicación Geográfica de la Hacienda la Lorena*



FUENTE: Google Maps

AUTOR: Kevin Joel Cedeño Campoverde

3.2. Tipo de investigación

Este proyecto de investigación se lleva a cabo bajo un tipo de investigación aplicada, cuantitativa y descriptiva. Este enfoque es necesario para desarrollar un sistema de teledetección que permita la identificación de enfermedades en cultivos de banano. La investigación aplicada se centra en resolver un problema práctico mediante la implementación de tecnologías avanzadas, mientras que la investigación descriptiva proporciona una base sólida al caracterizar, y la cuantitativa se basará en métricas de evaluación, todo esto para entender los patrones de las enfermedades detectadas.

3.2.1. Investigación Descriptiva

Se investigo las características visuales de la Sigatoka Negra y el Moko bacteriano en las imágenes aéreas tomadas con la ayuda del dron para identificar patrones que faciliten la detección de las enfermedades. Esto incluye la descripción detallada de manchas, decoloraciones, y otros síntomas visuales.

Determinar los Alcances: Identificar los objetivos y metas específicas que el sistema de teledetección debe cumplir para ser efectivo en la detección de Sigatoka Negra y Moko bacteriano.

- **Establecer Limitaciones:** Reconocer las posibles restricciones técnicas, económicas y ambientales que podrían influir en el desarrollo e implementación del sistema.
- **Prever Resultados:** Anticipar los resultados esperados en términos de precisión, eficiencia y beneficios potenciales del sistema para los productores de banano.

3.2.2. Investigación Aplicada

Este proyecto de investigación es aplicado porque busca utilizar conocimientos científicos y tecnológicos avanzados para resolver un problema práctico en el sector agrícola, específicamente en la detección de enfermedades en plantaciones de banano. El objetivo es desarrollar e implementar un sistema de teledetección que permita identificar la Sigatoka Negra y el Moko bacteriano, optimizando la gestión fitosanitaria y minimizando las pérdidas económicas asociadas.

3.2.3. Investigación Cuantitativa

El análisis se basará en métricas de evaluación del modelo de aprendizaje profundo, como precisión, recuperación y F1-score, comparando el rendimiento de diferentes configuraciones de resolución y modelos de aprendizaje profundo (YOLOv5, MobileNet, y EfficientDet-Lite0).

3.3. Métodos de Investigación

3.3.1. Enfoque Cuantitativo

El análisis cuantitativo permitirá extraer conclusiones basadas en datos numéricos. Se utilizarán métricas clave para evaluar el rendimiento del sistema de detección de enfermedades y su precisión en la clasificación.

Se utilizarán tres diferentes modelos de aprendizaje profundo para la detección de enfermedades en cultivos de banano. Los métodos de investigación incluirán un análisis comparativo entre estos modelos, evaluando su rendimiento en la clasificación de imágenes aéreas para identificar Moko bacteriano, Sigatoka Negra, y plantas sanas.

- **Teachable Machine (MobileNet):** Este modelo basado en MobileNet se entrenará utilizando la plataforma Teachable Machine de Google. MobileNet es conocido por su eficiencia en dispositivos móviles, lo que lo hace adecuado para implementaciones ligeras. Se utilizaron imágenes de tamaño 256x256 debido a su limitación de calidad de imagen siendo la calidad máxima implementada en esta investigación para evaluar su capacidad de generalización.
- **TensorFlow (EfficientDet-Lite0):** El modelo EfficientDet-Lite0, parte de la familia EfficientDet, fue entrenado utilizando TensorFlow. Este modelo es conocido por su capacidad de manejar imágenes de tamaño moderado (máximo 512x512). Se evaluó su capacidad de generalización y cómo este modelo responde a diferentes niveles de detalle en las imágenes.
- **YOLOv5:** YOLOv5 fue utilizado debido a su robustez y capacidad para manejar imágenes de alta resolución, hasta 1024x1024. Este modelo es particularmente eficiente para la detección en tiempo real y se entrenará con imágenes de 256x256, 512x512 y 1024x1024, para comparar su rendimiento con los otros dos modelos.

Los resultados de estos modelos serán comparados estadísticamente para identificar el modelo más adecuado para la detección de Sigatoka Negra y Moko bacteriano.

3.4. Fuentes de recopilación de información

Se consultaron publicaciones científicas, bases de datos de imágenes, asesoramiento de un experto en el tema y literatura técnica sobre detección de enfermedades en cultivos. Además, se obtuvo muestras de Imágenes de hojas sanas y con enfermedades tomadas en fincas de la zona de estudio.

3.4.1. Fuentes de Información

1. Primarias:

- **Imágenes aéreas capturadas mediante drones:** Estas imágenes, tomadas a diferentes alturas y resoluciones, proporcionaron la base para el entrenamiento de los modelos de detección.
- **Asesoramiento de expertos agrónomos:** Ingenieros agrónomos especializados en enfermedades del banano colaboraron en la validación del etiquetado de las

imágenes y la identificación de las características visuales distintivas de Sigatoka Negra y Moko bacteriano.

- **Etiquetado manual:** Las imágenes se etiquetaron usando la herramienta Label Studio, diferenciando entre tres clases principales: Moko bacteriano, Sigatoka Negra, y Plantas Sanas.

2. Secundarias:

- Revisión de estudios y publicaciones científicas sobre el uso de aprendizaje profundo en la agricultura y las técnicas avanzadas de visión artificial aplicadas a la detección de enfermedades en cultivos.

3.5 Procedimiento

3.5.1. Captura de Imágenes Aéreas

El proceso de captura de imágenes se llevó a cabo utilizando un dron con cámaras de alta resolución mediante vuelos autónomos utilizando plataformas de planificación de vuelo, también se realizaron vuelos manuales para identificar ciertas zonas con las enfermedades y visualizar a que altura y en que posición es favorable la obtención de las imágenes. Las imágenes se capturaron a diferentes altitudes, principalmente entre 3 y 5 metros para obtener un balance entre área cubierta y nivel de detalle.

Las imágenes aéreas fueron tomadas a intervalos regulares para asegurar una cobertura completa de la plantación. La calidad de las imágenes se ajustará para mantener la claridad suficiente que permita una identificación precisa de las enfermedades.

3.5.1.1. Criterios de Selección del Dron.

La elección del dron fue rigurosa y se basó en varios factores técnicos que influyen en la calidad de las imágenes capturadas y la operación eficiente en el campo:

- **Resolución de la Cámara:** Uno de los factores más importantes fue la capacidad del dron para capturar imágenes de alta resolución. El análisis se centró en drones equipados con cámaras capaces de tomar imágenes claras y detalladas, con resoluciones mínimas de 12 megapíxeles y superiores. Se priorizaron cámaras con la capacidad de grabar en diferentes resoluciones, como 256x256, 512x512 y

1024x1024 píxeles, para evaluar el impacto de la resolución en los modelos de detección.

- **Estabilidad en el Vuelo:** La estabilidad del dron durante el vuelo era fundamental para garantizar que las imágenes no presentaran distorsiones causadas por movimientos bruscos o vibraciones. Se evaluaron drones con sistemas avanzados de estabilización, como gimbals de tres ejes, que garantizan la captura de imágenes nítidas y sin desenfoques, independientemente de las condiciones del viento o el movimiento del dron.
- **Duración de la Batería:** Se consideró la autonomía de vuelo del dron, dado que las plantaciones de banano suelen cubrir grandes extensiones de terreno. Los drones con mayor capacidad de batería, que permiten vuelos prolongados sin necesidad de recarga frecuente, fueron considerados prioritarios para maximizar la eficiencia del tiempo de captura de imágenes.
- **Facilidad de Transporte y Configuración:** Dado que las operaciones se llevaban a cabo en un entorno agrícola, la portabilidad y la facilidad de ensamblaje del dron fueron factores importantes. Se prefirieron drones que fueran ligeros, fáciles de transportar y rápidos de configurar en el campo.
- **Capacidad de Vuelo Autónomo:** La capacidad del dron para volar de manera autónoma según la ruta programada en la plataforma de planificación de vuelo fue otro criterio importante. Se evaluaron drones con características avanzadas de vuelo autónomo que permitieran seguir trayectorias predeterminadas sin intervención manual constante, optimizando el tiempo de captura de imágenes.

3.5.1.2. Criterios de Selección del Dron la Plataforma de Planificación de Vuelo.

Un punto clave para el actual proyecto fue el analizar las diferentes aplicaciones de planificación de vuelo que permitieran un control preciso y automatizado del dron durante los vuelos. Se evaluaron varias plataformas bajo los siguientes criterios:

- **Automatización y Control Preciso:** La capacidad de las plataformas para planificar rutas de vuelo precisas y automatizadas fue fundamental. Se optó por una plataforma que permitiera definir parámetros como la altitud, el ángulo de vuelo y la superposición entre imágenes (overlap) para asegurar una cobertura completa de la plantación sin zonas vacías ni imágenes redundantes.

- **Interfaz Intuitiva:** Otro factor importante fue la facilidad de uso de la plataforma. Dado que los vuelos podrían ser ejecutados por operadores no especializados en tecnologías avanzadas, se priorizaron plataformas con interfaces gráficas intuitivas que permitieran programar rutas de vuelo de forma simple y sin la necesidad de habilidades técnicas avanzadas.
- **Compatibilidad con Drones:** No todas las plataformas de planificación de vuelo son compatibles con todos los modelos de drones. Se consideraron plataformas que ofrecieran integración nativa con una amplia gama de drones para facilitar la implementación.
- **Control en Tiempo Real y Monitoreo:** Se evaluó la capacidad de las plataformas para monitorear el vuelo en tiempo real, permitiendo realizar ajustes sobre la marcha, como cambios en la altitud o la ruta en caso de condiciones imprevistas, como la presencia de obstáculos o cambios en las condiciones meteorológicas.
- **Compatibilidad con GPS:** La precisión geoespacial era crítica para asegurar que las imágenes capturadas pudieran ser georreferenciadas correctamente. Por lo tanto, se analizaron las plataformas que ofrecieran una alta integración con sistemas de posicionamiento GPS de alta precisión para geolocalizar las imágenes capturadas y usarlas en la visualización posterior en la plataforma web.

Después de este análisis exhaustivo, se seleccionaron la plataforma de planificación de vuelo y el dron que mejor cumplieron con los requisitos de la investigación, asegurando la calidad de las imágenes aéreas capturadas y la eficiencia operativa en el entorno agrícola. La combinación elegida permitió capturar imágenes georreferenciadas de alta resolución, esenciales para el entrenamiento y evaluación del modelo computacional.

3.5.2. Recolección de Datos y Etiquetado

Se realizaron múltiples vuelos en días distintos, bajo diferentes condiciones de luz, con el objetivo de garantizar la diversidad y calidad del conjunto de datos. Se recolectó un total de 900 imágenes que conformaron el dataset, lo que permitió un entrenamiento robusto de los modelos de detección.

Las imágenes fueron cuidadosamente revisadas para asegurar que representaban claramente las características visuales de Sigatoka Negra, Moko bacteriano y hojas sanas. Esta revisión manual fue esencial para garantizar que las imágenes estuvieran libres de

ruido, sombras excesivas o cualquier otro factor que pudiera afectar el proceso de entrenamiento del modelo.

El etiquetado de las imágenes fue una etapa crucial para garantizar la precisión del modelo en la fase de entrenamiento. Se utilizó el software Label Studio, que permitió etiquetar cada imagen con las áreas afectadas por Sigatoka Negra, Moko bacteriano o áreas sanas. El método de etiquetado empleado fue poligonal, lo que permitió una selección precisa de las áreas afectadas en cada imagen, delineando manualmente las hojas enfermas para asegurar que el modelo fuera capaz de detectar correctamente los bordes de las lesiones.

Cada imagen fue etiquetada en tres categorías:

- Moko bacteriano
- Sigatoka Negra
- Plantas Sanas

La precisión del etiquetado es crucial para el entrenamiento del modelo. Las imágenes se etiquetarán con especial énfasis en las características visuales clave que permiten diferenciar cada una de las enfermedades.

3.5.2.1. Validación del Etiquetado.

Para asegurar la calidad del etiquetado, las imágenes etiquetadas fueron validadas por expertos agrónomos, quienes confirmaron la exactitud de las anotaciones en base a su experiencia en la identificación visual de estas enfermedades. Este proceso de validación fue clave para evitar sesgos en el entrenamiento del modelo y para garantizar que el conjunto de datos proporcionara un aprendizaje adecuado.

Este conjunto de datos fue clave para entrenar los tres modelos (YOLOv5, EfficientDet-Lite0 y MobileNet), y permitió evaluar el impacto de la resolución de las imágenes en la capacidad de detección de cada modelo. El proceso de recolección de datos y etiquetado no solo aseguró la precisión del modelo, sino también su capacidad para generalizar los resultados en diferentes condiciones de iluminación y ángulos de captura.

3.5.3. Desarrollo del Modelo Computacional

El desarrollo del modelo computacional fue uno de los ejes centrales de la investigación, diseñado para la detección automática de Sigatoka Negra y Moko bacteriano en

plantaciones de banano. Para lograr este objetivo, se implementaron y compararon tres enfoques de aprendizaje profundo: YOLOv5, TensorFlow (EfficientDet-Lite0) y Teachable Machine (MobileNet). Cada modelo fue entrenado utilizando el dataset previamente recopilado y etiquetado, que consistía en 900 imágenes clasificadas en tres categorías: Moko bacteriano, Sigatoka Negra y Sanas.

3.5.3.1. Preprocesamiento del Dataset .

Antes de entrenar los modelos, el conjunto de imágenes fue procesado para asegurar su compatibilidad con las distintas arquitecturas y resoluciones necesarias. Las imágenes se dividieron en tres subconjuntos:

- 80% del dataset se utilizó para el entrenamiento.
- 20% restante fue destinado para la validación y prueba.

Se realizaron los siguientes preprocesamientos:

- Redimensionado de las imágenes en tres resoluciones clave: 256x256, 512x512 y 1024x1024 píxeles, según los requerimientos de cada modelo.
- Normalización de las imágenes para escalar los valores de los píxeles entre 0 y 1, lo que mejora la eficiencia del entrenamiento.
- Aumento de datos, para ampliar la variedad del conjunto de datos y mejorar la capacidad de generalización de los modelos. Este aumento incluyó rotación, traslación y cambio de brillo y contraste de las imágenes.

3.5.3.1. Entrenamiento del Modelo.

El entrenamiento de los modelos fue llevado a cabo en diferentes configuraciones de resolución y número de épocas, con el fin de obtener los mejores resultados en términos de precisión y velocidad. A continuación, se detallan las configuraciones utilizadas para cada uno de los modelos:

- 1. Teachable Machine (MobileNet):** Teachable Machine es una herramienta web desarrollada por Google que facilita la creación de modelos de aprendizaje profundo sin necesidad dispositivos móviles.

Proceso de Entrenamiento:

- **Resolución:** Se utilizaron imágenes de 256x256 píxeles, ya que esta plataforma está diseñada para entrenamientos rápidos con imágenes de baja resolución.
- **Software:** Teachable Machine es una plataforma en línea, por lo que no se utilizó un entorno local como PyCharm para este entrenamiento.
- **Épocas:** Se entrenó el modelo con 50, 150 y 200 épocas.
- **Limitaciones:** Esta plataforma no permite un ajuste profundo de los hiperparámetros, lo que limitó la personalización del modelo para optimizar su rendimiento.

2. TensorFlow (EfficientDet-Lite0): El modelo EfficientDet-Lite0 es parte de la familia EfficientDet y fue entrenado utilizando la plataforma TensorFlow. Este modelo es conocido por su capacidad de equilibrar precisión y eficiencia en dispositivos con recursos limitados, aunque su capacidad de manejar imágenes grandes fue restringida.

Proceso de Entrenamiento:

- **Resolución:** Se entrenaron imágenes de 256x256 y 512x512 píxeles, ya que TensorFlow presenta limitaciones en la resolución máxima de las imágenes, lo cual afectó el rendimiento general en comparación con YOLOv5.
- **Épocas:** El modelo fue entrenado con 50, 150 y 200 épocas.
- **Software:** Se utilizó TensorFlow-Keras para el entrenamiento, implementado también en PyCharm.
- **Hiperparámetros ajustados:** Se modificó la tasa de aprendizaje y el tamaño del lote para mejorar la convergencia del modelo.

3. YOLOv5 (You Only Look Once): fue seleccionado por su alta eficiencia y velocidad en la detección de objetos en tiempo real. Este modelo fue entrenado con imágenes de 256x256, 512x512 y 1024x1024 píxeles.

Proceso de Entrenamiento:

- **Software:** El modelo se entrenó utilizando PyTorch como backend, ejecutándose en PyCharm. Esta elección se debió a la compatibilidad de PyTorch con YOLOv5 y su capacidad de manejar grandes volúmenes de datos.

- **Épocas:** Se entrenó el modelo con 50, 150 y 200 épocas, evaluando el rendimiento en cada etapa.
- **Hiperparámetros ajustados:** Se realizaron ajustes en los hiperparámetros como la tasa de aprendizaje, el tamaño del lote y el umbral de confianza para mejorar la precisión del modelo.

3.5.3.1. *Evaluación del Modelo.*

Una vez completado el entrenamiento de los modelos, se procedió con la evaluación exhaustiva de su rendimiento mediante las siguientes métricas clave:

- **Matriz de Confusión:** Se utilizó para evaluar las predicciones correctas e incorrectas de cada clase (Sanas, Moko y Sigatoka).
- **Precisión Global (Accuracy):** Indicó el porcentaje de predicciones correctas sobre el total de predicciones.
- **Precisión por Clase (Precision):** Se midió para cada una de las tres clases, identificando si el modelo tenía dificultades en alguna en particular.
- **Recall:** Indicó la capacidad del modelo para identificar correctamente todas las instancias de una clase determinada.
- **F1-Score:** Este valor ponderado entre precisión y recall permitió identificar el balance entre falsos positivos y falsos negativos.
- **Curvas Precisión-Recall:** Ayudaron a ajustar los umbrales de decisión del modelo, optimizando el punto en el que el modelo logra el mejor equilibrio entre precisión y recall.

Cada uno de los modelos fue evaluado en función de estas métricas, y así determinar que Modelo es el más adecuado para la tarea, siendo así que se analizó su capacidad para manejar imágenes de alta resolución y su velocidad de inferencia, todo esto muy importante en las implementaciones en campo en tiempo real.

3.5.4. *Implementación de la Aplicación Web*

La aplicación web fue desarrollada utilizando Python y el framework Flask, lo que permitió construir una aplicación ligera, modular y escalable. Flask fue elegido por su simplicidad para gestionar rutas y su capacidad para integrarse con librerías externas

necesarias para el procesamiento de imágenes y el despliegue de modelos de aprendizaje profundo.

Tecnologías Utilizadas:

- **Backend:** Python + Flask.
- **Frontend:** HTML5, CSS3, JavaScript.
- **Base de Datos:** Google Drive.
- **Visualización Georreferenciada:** Google Maps API.

3.5.4.1. Integración del Modelo de Detección.

El modelo de detección entrenado, que demostró ser el más eficiente, fue integrado en la plataforma para procesar las imágenes cargadas por los usuarios. La capacidad para manejar imágenes de alta resolución y su velocidad en la detección, lo que resulta clave para ofrecer una buena experiencia para cada usuario.

Proceso de Integración:

Carga de Imágenes: La interfaz permite al usuario cargar imágenes aéreas de la plantación en formato JPG o PNG. Las imágenes son enviadas al servidor donde se procesan usando el modelo previamente entrenado.

Procesamiento: Una vez cargadas las imágenes, se ejecuta el modelo de detección para identificar las áreas afectadas por Sigatoka Negra y Moko bacteriano. El modelo genera un archivo de salida con las coordenadas de los objetos detectados y los clasifica en una de las tres categorías: Moko, Sigatoka o Sanas.

Almacenamiento de Resultados: Los resultados del análisis (predicciones) son almacenados en Google Drive, junto con las imágenes originales y procesadas, para futuras consultas o análisis.

3.5.4.2 Visualización de Resultados.

Uno de los componentes más importantes de la plataforma es la visualización georreferenciada de los resultados. Para ello, se utilizó la API de Google Maps, que permitió mostrar la ubicación exacta de las áreas afectadas dentro de la plantación en un mapa interactivo.

Proceso de Visualización:

- **Georreferenciación:** Cada imagen procesada está asociada a las coordenadas GPS capturadas por el dron durante el vuelo. Esto permitió que los resultados del modelo pudieran ser mapeados con precisión en la interfaz de Google Maps, facilitando la identificación visual de las zonas afectadas.
- **Mapeo de Resultados:** Las áreas identificadas como infectadas por Moko y Sigatoka son marcadas en el mapa con colores diferenciados. Por ejemplo, las áreas afectadas por Sigatoka Negra se destacan en rojo, mientras que las áreas afectadas por Moko bacteriano se muestran en amarillo. Las áreas sanas se visualizan en verde.
- **Interactividad:** Los usuarios pueden hacer zoom, desplazarse por el mapa y seleccionar áreas específicas para obtener más detalles sobre las predicciones hechas por el modelo. Al hacer clic en una zona, se despliega un cuadro de información con datos adicionales, como el nivel de confianza del modelo en la predicción, la extensión de la zona afectada y la fecha y hora de la captura.

El flujo de trabajo de la Aplicación será el siguiente:

El flujo de trabajo dentro de la plataforma web se diseñó para ser intuitivo y eficiente, optimizando el proceso de detección para los usuarios sin conocimientos técnicos avanzados. El proceso general es el siguiente:

1. **Captura de Imágenes:** El dron captura las imágenes de la plantación durante su vuelo programado.
2. **Carga de Imágenes:** El usuario ingresa a la plataforma web y sube las imágenes aéreas capturadas por el dron.
3. **Procesamiento Automático:** Una vez que el usuario ha cargado las imágenes en la plataforma, estas son enviadas al servidor donde el modelo previamente entrenado se encarga de analizar y detectar las áreas afectadas por Sigatoka Negra y Moko bacteriano.
4. **Visualización de los Resultados:** Una vez procesadas las imágenes, los resultados son mostrados en la plataforma web de forma clara y georreferenciada a través de Google Maps. En el mapa interactivo, los usuarios pueden ver las áreas afectadas por las enfermedades y las zonas saludables de la plantación.

5. **Interacción con el Mapa:** Los usuarios pueden interactuar con el mapa georreferenciado, haciendo zoom y seleccionando áreas específicas de la plantación. Cada vez que el usuario selecciona una zona afectada, aparece un cuadro informativo que muestra detalles adicionales, tales como:

- Nivel de confianza de la predicción realizada por el modelo.
- Superficie aproximada de la zona afectada.
- Fecha y hora en que fue capturada la imagen.
- Detalles del vuelo, como la altitud de captura y las coordenadas GPS exactas.

CAPITULO IV

RESULTADOS Y DISCUSIÓN

En la siguiente sección se redacta de forma textual los resultados a obtenidos a través de las fases planteadas dentro del diseño de investigación, cumpliendo con cada uno de los objetivos planteados de manera que se demuestre el proceso que se llevó a cabo para cumplir con cada uno de ellos.

4.1. Análisis de los dispositivos (drones) y plataformas digitales

4.1.1. Análisis y selección del dispositivo

El primer objetivo específico de este proyecto se centró en la evaluación y selección de los dispositivos y plataformas digitales más adecuados para implementar un sistema de teledetección aérea en plantaciones de banano. Este análisis fue fundamental para garantizar que el sistema cumpliera con los requisitos técnicos y operativos necesarios para la captura precisa y eficiente de imágenes aéreas que faciliten la detección de enfermedades como la Sigatoka Negra y el Moko bacteriano.

4.1.1.1 Tabla comparativa de vehículos aéreos no tripulados.

Tabla 1. Tabla Comparativa de Vehículos Aéreos no Tripulados

Modelo	Precio (Usd)	Autonomía	Cámara	Peso	Alcance	Planificación De Vuelo	Ideal Para Agricultura
DJI Mini 3	\$1,028	38 min	RGB 20MP 4K/30fps	249 g	10 km	Sí (apps de terceros)	Sí (versátil)
DJI Mavic 3	\$2,979	46 min	RGB 20MP 5.1K/50fps	895 g	15 km	Sí (nativo + terceros)	Sí
DJI Phantom 4 Multispectral	\$6,500	27 min	6 cámaras (1 RGB + 5 multispectrales) 2MP	1487g	7 km	Sí (especializado)	Sí (especializado)

Parrot	\$6,00	25 min	RGB 14MP +	185	2 km	Sí	Sí
Bluegras	0		Multiespectral	0g		(especiali	(especiali
s Fields			Sequoia+			zado)	zado)
senseFly	\$17,9	90 min	Intercambiable	160	8 km	Sí	Sí
eBee X	90		s	0g		(especiali	(profesion
			(RGB/Multies			zado)	al)
			pectral)				
AgEagle	\$12,0	55 min	Parrot Sequoia	110	3 km	Sí	Sí
eBee SQ	00		(RGB +	0g		(especiali	(especiali
			multiespectral)			zado)	zado)

Autor: Kevin Cedeño

Fuente: Investigación

En la tabla 1 se presenta una comparación de diferentes modelos de drones. Cada modelo tiene características específicas como el precio, la autonomía de vuelo, el tipo de cámara integrada, el peso, el alcance de control remoto, la capacidad de planificación de vuelo y su capacidad para aplicaciones agrícolas. Esta información permite evaluar y seleccionar el dron más adecuado según los requerimientos y el presupuesto disponible para tareas como el monitoreo de cultivos en el ámbito fitosanitario, entre otras aplicaciones en el sector agrícola.

4.1.1.2. Selección del Dron.

El análisis comenzó con la evaluación de diferentes modelos de drones disponibles en el mercado, enfocándose en aquellos con capacidades avanzadas de captura de imágenes, estabilidad de vuelo y autonomía. Los criterios de selección incluyeron la calidad de la cámara, la duración de la batería, la resistencia a condiciones climáticas adversas y la facilidad de integración con software de planificación de vuelo.

Entre los drones evaluados, se destacaron los modelos que ofrecían cámaras de alta resolución capaces de capturar imágenes en formato de 1024 x 1024 píxeles, lo cual es crucial para la identificación de características sutiles en las hojas afectadas por enfermedades. La estabilidad de vuelo fue otro factor clave, ya que un vuelo estable asegura que las imágenes capturadas no sufran de distorsiones que puedan afectar la precisión del análisis posterior.

Además, la autonomía de vuelo fue considerada para asegurar que el dron pueda cubrir grandes áreas de plantaciones sin necesidad de recargas frecuentes, optimizando así el tiempo y los recursos durante las operaciones de monitoreo.

¿Por qué el Dron “DJI Mini 3” fue la elección óptima?

El DJI Mini 3 represento una opción óptima para la detección de enfermedades como la Sigatoka Negra y Moko bacteriano en el escaneo aéreo de cultivos de banano, gracias a su combinación de características técnicas y practicidad. Su cámara de 20MP permite capturar imágenes de alta resolución para un análisis detallado de síntomas, mientras que su autonomía de vuelo de 38 minutos y la integración con diversas aplicaciones de vuelo, facilitan un escaneo eficiente de grandes áreas de cultivo. Además, su diseño portátil y liviano, sumado a su costo accesible, lo convierten en una solución versátil, fácil de transportar y económicamente viable para el propósito de esta investigación.

4.1.2. Evaluación de Plataformas Digitales para la Planificación de Vuelo

El siguiente paso fue la evaluación de plataformas digitales para la planificación de vuelos, esenciales para la operación eficiente de los drones en el campo. Se analizaron varias aplicaciones de planificación de vuelo, enfocándose en su compatibilidad con los drones seleccionados, su facilidad de uso, y la precisión en la ejecución de los vuelos preprogramados.

Las plataformas evaluadas fueron seleccionadas con base en su capacidad para generar rutas de vuelo precisas que maximizaran la cobertura de la plantación y aseguraran una captura de imágenes sistemática y completa. Se priorizaron aplicaciones que permitieran la personalización de los parámetros de vuelo, como la altura y velocidad, y que ofrecieran herramientas de monitoreo en tiempo real durante la operación, lo que es crucial para ajustar la misión según las condiciones específicas del entorno.

4.1.2.1. Tabla comparativa de plataformas digitales para planificación de vuelos autónomos.

Las plataformas digitales para planificación de vuelos autónomos de drones son aplicaciones esenciales que permiten aprovechar al máximo el potencial de los vehículos aéreos no tripulados al facilitar la creación y automatización de misiones de vuelo complejas. Estas herramientas ofrecen funcionalidades clave como la definición de rutas,

altitudes, velocidades y puntos de interés, así como opciones avanzadas como la integración con cámaras, el procesamiento de imágenes, la generación de modelos 3D y ortomosaicos, el seguimiento de objetivos móviles y la transmisión en vivo de video. Con opciones populares como Litchi, DJI GO 4, Pix4Dcapture, DroneLink, UgCS, Drone Harmony y Airdata UAV, los usuarios pueden elegir la plataforma más adecuada según sus necesidades, compatibilidad con el dron, experiencia y presupuesto disponible.

Tabla 2. *Comparativa de Plataformas Digitales para Planificación de Vuelos Autónomos*

Plataforma	Compatibilidad	Características	Ventajas	Desventajas
Litchi	DJI, Autel, Yuneec, Parrot	- Planificación de rutas de vuelo - Modos de vuelo automatizados - Ajustes de cámara personalizados - Soporte para cámaras multiespectrales - Waypoints y puntos de interés	- Interfaz intuitiva - Amplia compatibilidad - Opciones avanzadas de vuelo	- Costo de suscripción anual - Algunas funciones limitadas en la versión gratuita
DJI GO 4	DJI	- Planificación de misiones - Transmisión en vivo de video - Edición básica de fotos/videos - Ajustes de cámara	- Integración nativa con drones DJI - Interfaz sencilla - Gratuita	- Funciones limitadas de planificación de vuelos - Solo compatible con drones DJI

		- Modos de vuelo inteligentes		
Pix4Dcapture	DJI, Parrot, Sentera, MicaSense	- Planificación de vuelos - Procesamiento de imágenes - Generación de mapas y modelos 3D - Soporte para cámaras multiespectrales - Anotaciones y mediciones	- Solución integral para mapeo aéreo - Opciones avanzadas de procesamiento - Precisión en planificación de vuelos	- Curva de aprendizaje empinada - Costo de suscripción elevado
DroneLink	DJI, Yuneec, 3DR, Parrot	- Planificación de misiones - Telemetría en vivo - Gestión de flotas - Informes de vuelo - Cumplimiento normativo	- Interfaz web y móvil - Útil para operaciones comerciales - Herramientas de colaboración	- Enfoque más empresarial - Costo de suscripción elevado
UgCS	DJI, Autel, Yuneec, Parrot	- Planificación de vuelos - Modos de vuelo automatizados - Soporte para cámaras multiespectrales	- Amplia compatibilidad - Opciones avanzadas de vuelo - Herramientas de fotogrametría	- Interfaz menos intuitiva - Curva de aprendizaje empinada

		- Procesamiento de imágenes		
		- Generación de modelos 3D		
Drone Harmony	DJI, Parrot, Yuneec, 3DR	- Planificación de misiones	- Opciones de vuelo avanzadas	- Compatibilidad limitada
		- Vuelos automatizados	- Interfaz de usuario moderna	- Algunas funciones requieren suscripción
		- Seguimiento de objetos	- Integración con servicios en la nube	
		- Modos de vuelo inteligentes		
		- Livestreaming		
Airdata UAV	DJI, Autel, Yuneec, Parrot	- Planificación de vuelos	- Solución integral de mapeo aéreo	- Curva de aprendizaje empinada
		- Soporte para cámaras multiespectrales	- Opciones de procesamiento avanzadas	- Costo elevado para uso comercial
		- Procesamiento de imágenes	- Exportación de datos GIS	
		- Generación de ortomosaicos		

Autor: Kevin Cedeño

Fuente: Investigación

La tabla 2 presentada es una comparación detallada de diversas plataformas digitales disponibles en el mercado para la planificación y ejecución de vuelos autónomos con drones. Cada plataforma se evalúa en términos de su compatibilidad con diferentes marcas de drones, las características y funcionalidades que ofrece, sus principales ventajas y desventajas. Esta información permite analizar y seleccionar la opción más adecuada según sus requerimientos específicos, como las necesidades del proyecto, la

experiencia del operador y el presupuesto disponible para adquirir estas herramientas tecnológicas.

¿Por qué el Sistema “Litchi” fue la elección óptima?

La plataforma Litchi fue considerada la opción más adecuada para planificar vuelos autónomos con el dron DJI Mini 3. Combina una amplia compatibilidad con diferentes marcas de drones, opciones avanzadas de planificación de rutas y modos de vuelo automatizados. Además, ofrece soporte para cámaras, ajustes personalizados de cámara que proporcionan un mayor control sobre la calidad de las imágenes y una interfaz intuitiva que facilita su uso. Aunque implica un costo de suscripción anual, las capacidades versátiles de Litchi justifican esta inversión, permitiendo realizar un escaneo sistemático y eficiente de las plantaciones, y obteniendo datos de alta calidad para el análisis de detección de enfermedades como la Sigatoka Negra y el Moko bacteriano.

4.1.2. Discusión de los resultados del primer objetivo específico

El análisis de los dispositivos y plataformas digitales mostró que el uso de drones y aplicaciones de planificación de vuelo permite una optimización significativa en la detección de enfermedades en plantaciones de banano, alineándose con estudios previos en el campo de la teledetección. Por ejemplo, **Martínez F. (2023)** en su artículo **"Metodología Propuesta para Identificación del Huanglongbing (HLB) en Limón Persa mediante una Red Neuronal Artificial"**, destaca la importancia de emplear drones equipados con cámaras de alta resolución para la detección temprana de enfermedades en cultivos [8]. La capacidad de los drones para capturar imágenes precisas y detalladas a diferentes alturas fue crucial para mejorar la detección de Sigatoka Negra y Moko bacteriano en este estudio.

El uso de herramientas de inteligencia artificial como redes neuronales artificiales para analizar las imágenes aéreas también ha sido respaldado por **Saquicela, C. y Paulina, S. (2023)** en su artículo **"Caracterización Morfológica y Bioquímica de Ralstonia solanacearum Raza 2"**, donde se aplicaron métodos similares para identificar Moko bacteriano en cultivos de banano. Estos autores resaltan la precisión de los sistemas automatizados para detectar enfermedades a partir de datos visuales [2], algo que se confirmó en el presente proyecto de investigación, donde el análisis de imágenes aéreas ayudó a reducir el margen de error en la detección.

La investigación de **Kimunye, J. y Were, E. (2021)** en "**Sources of resistance to Pseudocercospora fijiensis, the cause of black Sigatoka in banana**", también coincide con este trabajo al señalar que la detección precisa de Sigatoka Negra mediante teledetección es esencial para el manejo adecuado de la enfermedad [1]. En este sentido, la correcta selección de dispositivos, drones y plataformas digitales nos ayuda a implementar un sistema de monitoreo más eficiente y menos costoso, lo cual es clave para tratar de reducir el impacto económico de estas enfermedades.

En el artículo de **Kaur, S. y Pandey, S. (2022)** titulado "**Semi-automatic Leaf Disease Detection and Classification System for Soybean Culture**", menciona la efectividad de los sistemas de detección automatizados en el ámbito agrícola [4]. Aunque el estudio se centró en cultivos de soja, los resultados presentados en este proyecto confirman que tecnologías similares pueden ser aplicadas con éxito en cultivos de banano para la detección de enfermedades como la Sigatoka Negra y el Moko bacteriano

Al comparar estos resultados con la literatura existente, se confirma que la integración de drones y plataformas digitales en la agricultura de precisión es un avance significativo hacia la sostenibilidad agrícola. No solo permiten un monitoreo más detallado y oportuno, sino que también contribuyen a una gestión más eficaz de los recursos, reduciendo la dependencia de métodos tradicionales que son menos eficientes y más costosos a largo plazo.

4.2. Creación de la data set de imágenes aéreas que resalten las características visuales

La creación de un dataset especializado fue un paso esencial en la construcción del modelo de inteligencia artificial para la detección de enfermedades en cultivos de banano. Este proceso involucró la recolección y etiquetado de imágenes, aspectos críticos que determinaron la calidad y precisión del modelo final.

4.2.1. Recolección de Imágenes

La recolección de imágenes se llevó a cabo utilizando un dron equipado con una cámara de alta resolución, capaz de capturar detalles finos en las hojas de los cultivos. Se optó por realizar la captura de imágenes de manera manual en plantaciones afectadas por las enfermedades, permitiendo ajustar los ángulos y la altura de vuelo según las necesidades

específicas de cada toma. Este enfoque manual garantizó que las imágenes capturadas fueran de la más alta calidad, resaltando claramente las características visuales de la *Mycosphaerella fijiensis* (Sigatoka Negra) y el *Ralstonia solanacearum* Raza 2 (Moko bacteriano).

Es importante destacar que inicialmente se consideró el uso de imágenes de repositorios en línea. Sin embargo, la mayoría de estas imágenes presentaban baja resolución y no capturaban adecuadamente los síntomas visuales de las enfermedades, lo que las hacía inadecuadas para los objetivos del proyecto. Llegando a la conclusión de que la recolección directa en el campo fue esencial para asegurar un data set de alta calidad.

4.2.2. Análisis y selección de características visuales

Tras la revisión bibliográfica y consulta con expertos en agronomía, esencialmente ingenieros agrónomos que trabajen en el sector Bananero, se identificaron las siguientes características visuales distintivas de ambas enfermedades en cultivos de banano:

Tabla 3. Características Visuales de la Sigatoka Negra y el Moko Bacteriano en Hojas de Banano

Enfermedad	Características Visuales
Sigatoka Negra	• Manchas necróticas de color marrón oscuro a negro, generalmente comenzando en los bordes de las hojas y extendiéndose hacia el centro. • Halos amarillentos alrededor de las manchas. • En etapas avanzadas, las manchas pueden fusionarse, cubriendo grandes áreas de la hoja, lo que provoca su muerte prematura. • Las manchas suelen aparecer de forma lineal a lo largo de las venas de la hoja. • Amarillamiento y marchitamiento de las hojas superiores (hojas banderas).
Moko Bacteriano	• Pudrición de los frutos, que adquieren una coloración negra característica. • Deformación asimétrica de los racimos.

-
- Estrías oscuras presentes en el rizoma y cormo, que indican una infección avanzada.
-

Autor: Kevin Cedeño

Fuente: Investigación

Estas características visuales fueron seleccionadas como parámetros críticos para guiar el proceso de recolección y etiquetado de imágenes, asegurando que el dataset refleje con precisión las manifestaciones de estas enfermedades en el campo.

Ejes Visuales para la Identificación de Enfermedades:

- **Color y Forma de las Manchas:** Este eje visual se centra en la identificación de manchas necróticas de colores marrón oscuro o negro que aparecen en las hojas de banano afectadas por la Sigatoka Negra. Las manchas tienen un patrón específico, comenzando en los bordes de las hojas y extendiéndose hacia el centro, lo que facilitaría la detección automática mediante técnicas de visión artificial
- **Amarillamiento y Deterioro General del Tejido:** En este eje, se considerará el amarillamiento de las hojas y la marcha del tejido como un indicador clave de las enfermedades. En el caso del Moko bacteriano, el amarillamiento se presenta en las hojas superiores (hojas banderas) y los frutos afectados adquieren una coloración negra. Para la Sigatoka Negra, los halos amarillentos alrededor de las manchas necróticas serán un aspecto crítico a observar, ya que destacan en las imágenes y pueden ser utilizados por los modelos para mejorar la precisión de la detección.

Tabla 4. Características visuales para la Identificación de Enfermedades

Moko Bacteriano	Sigatoka Negra	Hojas Sanas
		



Autor: Kevin Cedeño

4.2.3. Etiquetado de Imágenes con Label Studio

El proceso de etiquetado fue realizado utilizando la herramienta Label Studio. Las imágenes fueron clasificadas en tres categorías: **SANAS** (Hojas Sanas), **MOKO** (Moko Bacteriano) y **SIGATOKA** (Sigatoka Negra). Para asegurar un etiquetado preciso, se analizaron distintos métodos de etiquetado, que permitieran marcar con exactitud las áreas afectadas en cada imagen.

Este etiquetado preciso es fundamental para que el modelo de inteligencia artificial pueda aprender a distinguir entre las diferentes clases, lo cual es esencial para su rendimiento en la etapa de inferencia.

Ilustración 8. *Etiquetado usando el método de polígonos en Label Studio*



Nota: La ilustración 8 muestra el etiquetado de polígonos de las tres clases Moko Bacteriano (rojo), Hojas sanas (verde) y Sigatoka Negra (amarillo).

Autor: Kevin Cedeño.

El método de polígonos fue esencial para capturar las formas irregulares y complejas de las manchas y otras características visuales de las enfermedades, lo que sería difícil con métodos más simples como los cuadros delimitadores. Esta precisión es crucial para que

el modelo aprenda a identificar correctamente las enfermedades durante el entrenamiento, especialmente cuando los síntomas no siguen patrones rectilíneos o son irregulares.

Ilustración 9. *Proceso de etiquetado en label studio.*

☐	B14	Jul 15 2024, 21:56:18	1	0	0	JS		
☐	B15	Jul 15 2024, 21:57:30	1	0	0	JS		
☐	B16	Jul 15 2024, 21:58:54	1	0	0	JS		
☐	B17	Jul 15 2024, 22:00:08	1	0	0	JS		
☐	B18	Jul 15 2024, 22:02:06	1	0	0	JS		
☐	B19	Jul 15 2024, 22:05:43	1	0	0	JS		

Autor: Kevin Cedeño.

Este software permite generar anotaciones para cada imagen como se muestra en la ilustración 9, en un formato compatible, adecuado y que sea ampliamente utilizado para la detección de objetos.

Ilustración 10. *Archivo de texto generado por Label Studio*

```
1 0.5489021956087826 0.37924151696608784 0.500018361273453
0.15728942914171657 0.656686626746587 0.15728942914171657
0.7085828343113374 0.33732534930139724 0.7225349301397266
0.18530938121752407 0.776447105786423 0.3313373253403814
0.0642714570058283 0.3393213572854281 0.8802395209580838
0.3313373253403814 0.9321357285429142 0.32734534093812375
0.9101636736560900 0.5500982035920144 0.9121756407825048
0.5389221556886228 0.8762475049900199 0.51497005988862395
0.8303393213572854 0.5000000000000001 0.7964071856267425
0.5289421157684631 0.7485189670758483 0.5129740518562076
0.6686626746586987 0.5109780439121756 0.654690618762475
0.4010179640718562 0.5068063872295409 0.48381101213572854
0.5469061876247585 0.45109780439121755 0.5209588838323353
1 0.86187624758490002 0.718562874251497 0.1756407825948183
0.0107630750499002 0.25149780598862394 0.5948101792415186
0.2934131736526846 0.5389221556886228 0.3333333333333326
0.4870250481837024 0.3592834371257485 0.469061876247585
0.2954091816367285 0.4910179640718562 0.26740500988627946
0.5269461877844312 0.365686626746587 0.5329341317365268
0.06387225548902195 0.5389381233752489
1 0.27944111776447106 0.4590818363273453 0.243512974891856
0.47704598818363274 0.1157684630738523 0.4870250481837024
0.1057884231536936 0.1092081586863873 0.11177253493013973
0.42514978059888624 0.28159680638722555 0.4191616766467065
0.2954091816367285 0.42714570058285438 0.10938123375269581
1 0.31736526846187785 0.361273453409381237 0.29540918163672
```

Autor: Kevin Cedeño.

Cada archivo de texto asociado a una imagen como la ilustración 10 contiene información sobre los objetos etiquetados en la misma. El archivo sigue un formato simplificado, compuesto por una serie de líneas, donde cada línea representa un objeto etiquetado. La estructura de cada línea incluye cinco valores, los cuales son:


- **Clase del objeto:** Un número entero que indica la clase a la que pertenece el objeto. En nuestro caso, las clases corresponden a Moko bacteriano, Sigatoka Negra, y Plantas Sanas. Por ejemplo, si la clase "Moko bacteriano" es representada por el número "0", entonces el primer valor de esa línea sería "0".
- **Coordenadas normalizadas del cuadro delimitador (bounding box):**
- **X centro:** Coordenada X del centro del cuadro delimitador, normalizada entre 0 y 1, donde 0 representa el borde izquierdo de la imagen y 1 el borde derecho.
- **Y centro:** Coordenada Y del centro del cuadro delimitador, normalizada entre 0 y 1, donde 0 representa el borde superior de la imagen y 1 el borde inferior.
- **Ancho:** Ancho del cuadro delimitador, también normalizado entre 0 y 1, en relación con el ancho total de la imagen.
- **Altura:** Altura del cuadro delimitador, normalizada entre 0 y 1, en relación con la altura total de la imagen.

Esta estructura permite que el modelo interprete la posición y dimensiones de los objetos en la imagen de manera eficiente, ya que todos los valores están entre 0 y 1, lo cual facilita la escalabilidad y portabilidad entre diferentes tamaños de imágenes.

Análisis de Distribución de Etiquetas:

La Ilustración 11 presenta un análisis de la distribución de etiquetas en el dataset utilizado. Se observa que la mayoría de las instancias corresponden a hojas sanas, mientras que las instancias de Moko bacteriano y Sigatoka Negra son menos frecuentes.

Ilustración 11. Análisis de Distribución de Etiquetas



Autor: Kevin Cedeño.

El etiquetado fue un proceso detallado que requirió la revisión y el ajuste continuo de las etiquetas como se puede visualizar en la ilustración 9, todo esto para asegurarnos de que fueran lo más precisas posibles. Esto fue especialmente importante para capturar la variabilidad de los síntomas, como las diferentes etapas de desarrollo de las manchas de la Sigatoka Negra o los cambios en las hojas (despigmentación, muerte, entre otros) afectados por el Moko bacteriano.

4.2.4. Evaluación del Data set

Una vez que el data set fue completamente etiquetado, realizamos un análisis para entender su distribución y evaluar su adecuación para el entrenamiento del modelo.

- **Distribución de Etiquetas:** Al analizar la distribución de etiquetas en el data set, observamos que la mayoría de las instancias correspondían a hojas sanas, mientras que las clases de Moko bacteriano y Sigatoka Negra estaban menos representadas. Esta distribución desigual refleja la realidad en campo, pero también plantea desafíos para el modelo.
- **Impacto del Etiquetado:** El uso del método de polígonos en el etiquetado permitió capturar con gran precisión los síntomas visuales de las enfermedades. Esto nos da como resultado una mayor capacidad del modelo para diferenciar entre las clases durante el entrenamiento, minimizando errores de clasificación y mejorando la detección de patrones complejos en las imágenes.

La calidad de la data set fue validada a través de un proceso de revisión por expertos agrónomos. Estos expertos confirmaron que las imágenes capturadas y etiquetadas reflejan con precisión las características visuales de las enfermedades, y que el data set proporcionaba una base sólida para el entrenamiento del modelo de inteligencia artificial. Además, se realizaron pruebas preliminares con el modelo, confirmando que las imágenes permitían al modelo identificar y clasificar efectivamente las enfermedades.

El objetivo específico 2 fue exitoso. Se logró crear un dataset robusto y detallado con 900 imágenes clasificado en tres categorías, el cual es esencial para entrenar un modelo de inteligencia artificial capaz de detectar la Sigatoka Negra y el Moko bacteriano en plantaciones de banano. Las decisiones metodológicas tomadas, desde la recolección manual de imágenes hasta el etiquetado preciso utilizando polígonos, fueron claves para garantizar la calidad del dataset y, por ende, la efectividad del modelo en su fase de

entrenamiento. Este proceso ha sentado una base sólida para el éxito del proyecto en su conjunto, asegurando que el modelo pueda operar con alta precisión en aplicaciones reales de campo.

4.2.5. Discusión de los resultados del segundo objetivo específico

El desarrollo de la dataset para la detección de Sigatoka Negra y Moko bacteriano representa un avance significativo en el campo de la teledetección aplicada a la agricultura de precisión. La calidad y validez de este data set fueron confirmadas por expertos en el campo de la agronomía, lo que asegura que las imágenes capturadas y etiquetadas reflejan de manera precisa las características visuales de estas enfermedades. Este enfoque es consistente con lo señalado en la literatura, donde se destaca la importancia de contar con data sets bien estructurados para el entrenamiento de modelos de inteligencia artificial en la agricultura.

En el artículo de Selvaraj, M. y Vergara, A. (2019) titulado **AI-powered banana diseases and pest detection**, enfatiza la necesidad de sistemas automatizados para la detección de enfermedades en banano, dada la importancia económica de este cultivo a nivel global [5]. Este estudio también subraya que la creación de data sets específicos y la validación por expertos son pasos críticos para garantizar la precisión de los modelos de deep learning.

Además, el artículo publicado por Kaur, S. y Pandey, S. (2019) con el nombre **Semi-automatic leaf disease detection and classification system for soybean** cultura destaca la importancia de la detección temprana de enfermedades foliares y cómo los sistemas basados en Machine Learning y Deep Learning [4], como el desarrollado en este proyecto, pueden mejorar significativamente la eficiencia en la gestión de cultivos. El enfoque en este estudio fue semiautomático, lo que hace referencia a que en algún punto del análisis de las hojas de soya interviene de manera directa el ser humano, muy por el contrario a este proyecto de investigación que busca la automatización total del sistema, el data set desarrollado en este proyecto de investigación se caracteriza por una precisión superior debido a la intervención directa de expertos en el proceso de etiquetado, lo que refuerza la validez de los resultados obtenidos.

4.2.5.1. Desafíos.

A pesar de los avances logrados, es importante reconocer las limitaciones inherentes de la data set. Como se discute en el artículo **A Review of the Challenges of Using Deep Learning Algorithms to Support Decision-Making in Agricultural Activities**, por Alibabaei, K. y Gaspar, P (2022), menciona que la variabilidad en los síntomas visuales y el desequilibrio en la representación de clases son desafíos comunes en la aplicación de Deep Learning en la agricultura [6]. En el caso de este proyecto de investigación, aunque el etiquetado detallado mejoró la precisión del modelo, la representación desigual de las clases podría afectar la capacidad del modelo para generalizar a nuevas muestras. Este es un tema que deberá abordarse en investigaciones futuras mediante técnicas como el aumento de datos o el balanceo de clases.

4.2.5.2. Impacto y Relevancia.

Este trabajo no solo contribuye a la literatura existente, sino que también tiene un impacto práctico significativo en la gestión fitosanitaria del banano, un cultivo de gran importancia económica en regiones tropicales. La integración de este data set en sistemas de teledetección más amplios puede facilitar la detección temprana de enfermedades, reducir las pérdidas económicas y mejorar la sostenibilidad de las plantaciones, esto lo menciona el autor Sishodia, R (2020), en el artículo **Applications of Remote Sensing in Precision Agriculture: A Review**, que destaca la importancia de la teledetección y la inteligencia artificial en la mejora de la eficiencia agrícola y la reducción del impacto ambiental [13].

4.3. Construcción de un modelo basado en visión artificial y aprendizaje profundo para la detección automática para implementarlo en una App Web con georreferenciación

El objetivo principal de esta sección es analizar los resultados obtenidos al desarrollar un modelo computacional basado en técnicas de visión artificial y aprendizaje profundo (Deep Learning) para la detección y clasificación automática de Sigatoka Negra y Moko Bacteriano en imágenes aéreas de cultivos de banano. El desarrollo se complementa con una plataforma web que permite la visualización georreferenciada de los resultados del proceso de detección.

4.3.1. Descripción de los Modelos y Configuraciones de Entrenamiento

Para este objetivo, se evaluaron tres enfoques diferentes: uno utilizando un modelo basado en EfficientDet-Lite0 (TensorFlow), otro utilizando Mobile Net (Teachable Machine) y el ultimo usando la arquitectura YOLOv5, siendo este último el implementado en este proyecto de investigación, ya que a la hora de reconocer la Sigatoka Negra y el Moko Bacteriano en el banano, tiene el menor margen de error, y aceptividad al reconocer las enfermedades.

Los tres modelos fueron entrenados utilizando imágenes con diferentes resoluciones y un número variable de época. Estos, fueron evaluados bajo diferentes configuraciones de resolución de imagen y número de épocas para identificar sus fortalezas, debilidades y limitaciones como se muestra a continuación.

4.3.1.1. Entrenamiento del Modelo MobileNet usando el motor de Teachable Machine de Google.


Teachable Machine utiliza MobileNet como arquitectura base para el entrenamiento de modelos de clasificación de imágenes. MobileNet es un modelo eficiente y liviano, diseñado para dispositivos móviles y aplicaciones web, lo que lo convierte en una opción óptima para Teachable Machine debido a su capacidad para equilibrar la precisión y el rendimiento con recursos limitados.

El proceso de entrenamiento en Teachable Machine es totalmente automatizado, permitiendo al usuario subir imágenes y entrenar modelos sin necesidad de programar o ajustar manualmente los hiperparámetros. Esto simplifica su uso, pero al mismo tiempo, limita la capacidad de realizar optimizaciones avanzadas o ajustes finos, como modificar el learning rate o ajustar la estructura de las capas de la red neuronal.

- **Resolución:** 256x256 píxeles.
- **Épocas:** 50, 150, 200.
- **Características:** Teachable Machine es una herramienta accesible para entrenar modelos personalizados sin necesidad de programación avanzada. Aunque es fácil de usar, tiene limitaciones en términos de resolución de imagen y capacidad para generalizar en diferentes condiciones de entrenamiento.

Resultados con Imágenes de 256x256 Píxeles y 50 Épocas:

Ilustración 12. Matriz de confusión 50 épocas



Autor: Kevin Cedeño

Análisis de la Matriz de Confusión

Ejes y Clases:

- **Eje Y (Vertical):** Representa las clases verdaderas (clases reales) de las instancias. En este caso, las clases son Moko, Sigatoka, y Sanas.
- **Eje X (Horizontal):** Representa las clases predichas por el modelo. Las mismas clases están listadas: Moko, Sigatoka, y Sanas.

Valores Diagonales:

- **Moko (58):** El modelo predijo correctamente 58 instancias de Moko como Moko.
- **Sigatoka (52):** El modelo predijo correctamente 52 instancias de Sigatoka como Sigatoka.
- **Sanas (24):** El modelo predijo correctamente 24 instancias de Sanas como Sanas.

Valores Fuera de la Diagonal:

No hay valores fuera de la diagonal, lo que indica que el modelo no cometió errores en la clasificación de las clases. Esto es una indicación de un modelo con alta precisión en este conjunto de datos específico.

Tabla 5. *Precisión por clase usando MobileNet con 50 épocas*

Clase	Precisión	Recall	F1-Score
Moko Bacteriano	1.00	1.00	1.00
Sigatoka Negra	1.00	1.00	1.00
Hojas Sanas	1.00	1.00	1.00
mAP@0.5	1.00		


Autor: Kevin Cedeño

Fuente: Investigación

Análisis:

- **Precisión, Recall, F1-Score:** Este modelo mostró un rendimiento perfecto en todas las métricas, lo cual es sospechoso dado el contexto de los otros modelos. Esto podría indicar un sobreajuste (overfitting), donde el modelo ha memorizado las muestras de entrenamiento sin generalizar bien a nuevos datos.
- **mAP@0.5:** El valor perfecto de mAP refuerza la sospecha de sobreajuste, ya que es poco probable que un modelo obtenga un rendimiento perfecto en todas las clases en una tarea compleja como esta.

Ilustración 13. *Precisión por época (50)*



Autor: Kevin Cedeño

Análisis de la Gráfica de Precisión por Época


- **Estabilidad:** La gráfica muestra una estabilidad en la precisión desde las primeras épocas, lo que sugiere que el modelo ha aprendido rápidamente y se estabiliza en una alta precisión tanto para el conjunto de entrenamiento como para el conjunto de prueba.

- **Constancia:** La precisión se mantiene constante después de las primeras pocas épocas, lo que indica que el modelo no sigue aprendiendo significativamente.
- **Posible Overfitting o Underfitting:** No hay signos evidentes de sobreajuste (overfitting) o subajuste (underfitting).

Aunque el rendimiento parece excelente en papel, el modelo probablemente no sea fiable en aplicaciones del mundo real donde los datos varían más ampliamente que en el conjunto de entrenamiento.

Resultados con Imágenes de 256x256 Píxeles y 150 Épocas:

Ilustración 14. Matriz de confusión 150 épocas



Autor: Kevin Cedeño

Análisis de la Matriz de Confusión

Ejes y Clases:

- **Eje X (Prediction):** Representa las predicciones realizadas por el modelo.
- **Eje Y (Class):** Indica las clases reales de las muestras.

Valores Diagonales:

- **Moko (58):** Las 58 imágenes de Moko fueron clasificadas correctamente.
- **Sigatoka (33):** De 52 imágenes de Sigatoka, solo 33 fueron clasificadas correctamente.
- **Sanas (24):** Todas las 24 imágenes de hojas sanas fueron clasificadas correctamente.

Valores Fuera de la Diagonal:

- **Sigatoka (19):** 19 imágenes de Sigatoka fueron incorrectamente clasificadas como Moko.

No hay otras clases mal clasificadas, lo que muestra que el modelo tiene dificultades para diferenciar entre Moko y Sigatoka, lo que sugiere un problema en la discriminación de características entre estas dos clases.

Tabla 6. *Precisión por clase usando MobileNet con 150 épocas*

Clase	Precisión	Recall	F1-Score
Moko Bacteriano	1.00	1.00	1.00
Sigatoka Negra	0.00	0.00	0.00
Hojas Sanas	1.00	1.00	1.00
mAP@0.5	0.67		


Autor: Kevin Cedeño

Fuente: Investigación

Análisis de la tabla 6:

- **Precisión y Recall:** El modelo MobileNet mostró un rendimiento perfecto en la detección de Moko Bacteriano y Hojas Sanas, con una precisión y recall de 1.00 para estas clases. Sin embargo, no fue capaz de clasificar correctamente ninguna instancia de Sigatoka Negra (precisión y recall de 0.00), lo que sugiere un desequilibrio significativo en la capacidad del modelo para generalizar a través de las clases.
- **F1-Score:** El F1-Score sigue el mismo patrón, con valores perfectos para dos clases, pero un valor nulo para Sigatoka Negra. Esto indica que, aunque el modelo es extremadamente bueno para ciertas clases, es completamente ineficaz para otras, lo que limita su aplicabilidad en situaciones reales.

Ilustración 15. Precisión por época (150)



Autor: Kevin Cedeño


Análisis de la Gráfica de Precisión por Época

- **Estabilidad:** La gráfica muestra una precisión constante alrededor del 60% desde el comienzo del entrenamiento.
- **Constancia:** No hay cambios significativos en la precisión durante el entrenamiento, lo que indica que el modelo alcanzó su máxima capacidad predictiva muy temprano.
- **Posible Sobreajuste o Sub ajuste:** La precisión se mantiene baja y constante, lo que indica que el modelo no logró capturar adecuadamente los patrones en los datos, posiblemente debido a la falta de complejidad del modelo o a la inadecuada calidad o cantidad de datos.

Este comportamiento sugiere que Teachable Machine podría estar sobre ajustando a ciertas clases en detrimento de otras, especialmente cuando el número de épocas es relativamente alto. Esto hace que el modelo sea poco confiable para tareas de clasificación equilibradas en escenarios del mundo real.

Resultados con Imágenes de 256x256 Píxeles y 200 Épocas:

Ilustración 16. Matriz de confusión 200 épocas



Autor: Kevin Cedeño.

Análisis de la Matriz de Confusión:

Ejes y Clases:

- **Eje Y (Vertical):** Representa las clases verdaderas (clases reales) de las instancias. Aquí se muestran las clases incluidas en el modelo: Moko, Sigatoka, y Sanas (o las que correspondan a la matriz actual).
- **Eje X (Horizontal):** Representa las clases predichas por el modelo. Las mismas clases se listan en el eje X para comparar las predicciones con las clases reales.

Valores Diagonales:

- **Moko (X):** El modelo predijo correctamente X instancias de Moko como Moko.
- **Sigatoka (X):** El modelo predijo correctamente X instancias de Sigatoka como Sigatoka.
- **Sanas (X):** El modelo predijo correctamente X instancias de Sanas como Sanas.

Valores Fuera de la Diagonal:

Los valores que aparecen fuera de la diagonal representan predicciones incorrectas, donde el modelo confundió una clase con otra.

Tabla 7. *Precisión por clase usando MobileNet con 200 épocas*

Clase	Precisión	Recall	F1-Score
Moko Bacteriano	1.00	1.00	1.00
Sigatoka Negra	1.00	1.00	1.00
Hojas Sanas	0.00	0.00	0.00
mAP@0.5	0.67		

Autor: Kevin Cedeño


Fuente: Investigación

Análisis de la tabla 7:

Precisión y Recall: Este modelo nuevamente muestra un rendimiento perfecto en dos clases, pero fracasa completamente en la clasificación de Hojas Sanas. Este patrón sugiere que el modelo está sobreajustando a ciertas clases mientras ignora completamente otras.

F1-Score: La falta de balance en la clasificación se refleja en los valores de F1-Score, que son perfectos para Moko Bacteriano y Sigatoka Negra, pero nulos para Hojas Sanas.

Ilustración 17. *Precisión por época (200)*



Autor: Kevin Cedeño.

Análisis de la Gráfica:

- **Estabilidad:** La gráfica muestra que la precisión tanto en los datos de entrenamiento (**acc**) como en los de prueba (**test acc**) se estabiliza rápidamente

después de las primeras pocas épocas, alcanzando aproximadamente un 80% de precisión.

- **Constancia:** A partir de un pequeño ajuste inicial en las primeras épocas, la precisión se mantiene constante durante todo el resto del entrenamiento. Esto sugiere que el modelo no está mejorando significativamente con más épocas, sino que ha alcanzado su punto máximo de rendimiento en términos de precisión.
- **Posible Sobrefitting o Subajuste:** La constancia de la precisión en un nivel relativamente alto, pero no máximo, puede indicar que el modelo ha encontrado un equilibrio, pero la falta de mejora posterior podría ser indicativo de una situación de sobrefitting (donde el modelo ya no mejora para los datos de prueba) o subajuste (donde el modelo no ha logrado aprender patrones más complejos).

Esta gráfica indica que el modelo alcanza rápidamente su máxima precisión durante el entrenamiento y que continuar el entrenamiento más allá de este punto no mejora su desempeño en los datos de prueba.

Teachable Machine muestra que, aunque puede ser útil en situaciones controladas con clases bien definidas, no es adecuado para aplicaciones donde se requiere un modelo equilibrado y generalizable. Las limitaciones en la resolución y la configuración del entrenamiento restringen su aplicabilidad en escenarios reales.

Este modelo, aunque fácil de usar, tiene limitaciones significativas en términos de generalización y manejo de diferentes clases, lo que lo hace menos confiable para tareas más complejas y variadas. Teachable Machine tiene una capacidad limitada para manejar imágenes de alta resolución y no permite ajustes avanzados en los parámetros de entrenamiento. Esto puede llevar a un sobreajuste, como se observó en algunas configuraciones, donde el modelo mostró un rendimiento perfecto, pero poco realista en conjuntos de datos de validación.

4.3.1.2. Entrenamiento del Modelo EfficientDet-Lite0 (TensorFlow)


El modelo EfficientDet-Lite0, parte de la familia de arquitecturas EfficientDet de TensorFlow, que están optimizadas para tareas de detección de objetos. El proceso de entrenamiento con este modelo permite mayor personalización de los parámetros en comparación con plataformas como Teachable Machine. Sin embargo, el modelo

utilizado en este trabajo está limitado a una resolución máxima de 512x512 píxeles, debido a restricciones de las capacidades del modelo.

- **Resolución:** 256x256, 512x512 píxeles (limitado a un máximo de 512x512 píxeles debido a restricciones del modelo y rendimiento del modelo).
- **Épocas:** 50, 150, 200.
- **Características:** TensorFlow es una plataforma versátil para el desarrollo de modelos de aprendizaje profundo. Sin embargo, debido a limitaciones en la capacidad de procesamiento, este modelo solo fue evaluado hasta una resolución máxima de 512x512 píxeles.

Resultados con Imágenes de 256x256 Píxeles y 50 Épocas:

Ilustración 18. Matriz de Confusión del modelo *EfficientDet-Lite0* (50 épocas)



Autor: Kevin Cedeño

Análisis de la Matriz de Confusión:

Ejes y Clases:

- **Eje Y (Vertical):** Representa las clases verdaderas (clases reales) de las instancias. En esta matriz, las clases son: Moko, Sanas, Sigatoka.

- **Eje X (Horizontal):** Representa las clases predichas por el modelo. Las mismas clases están listadas: Moko, Sanas, Sigatoka, permitiendo comparar las predicciones con las clases reales.

Valores Diagonales:

- **Moko (8):** El modelo predijo correctamente 8 instancias de Moko como Moko.
- **Sanas (6):** El modelo predijo correctamente 6 instancias de Sanas como Sanas.
- **Sigatoka (3):** El modelo predijo correctamente 3 instancias de Sigatoka como Sigatoka.

Valores Fuera de la Diagonal:

- **Sigatoka/Sanas (1):** El modelo predijo incorrectamente 1 instancia de Sigatoka como Sanas, lo que indica una confusión mínima entre estas dos clases.

No se observa ninguna confusión entre las clases Moko y las otras clases, lo que implica un desempeño muy preciso del modelo para esta clase.

Tabla 8. Precisión por clase usando *EfficientDet-Lite0* con 50 épocas

Clase	Precisión	Recall	F1-Score
Moko Bacteriano	0.450	0.360	0.400
Sigatoka Negra	0.100	0.180	0.130
Hojas Sanas	0.350	0.450	0.395
mAP@0.5	0.325		

Autor: Kevin Cedeño


Fuente: Investigación

Análisis de la tabla 8:

- **Precisión:** TensorFlow mostró un rendimiento bajo, con una precisión de solo 0.450 para Moko Bacteriano y aún más baja para Hojas Sanas y Sigatoka Negra. Esto indica que el modelo tuvo dificultades para hacer predicciones precisas en esta configuración.
- **Recall:** El recall para Sigatoka Negra es bajo (0.180), lo que significa que muchas instancias de esta clase no fueron identificadas correctamente.

- **F1-Score:** El F1-Score refleja el bajo rendimiento general del modelo, particularmente en la clase Sigatoka Negra, donde el valor es de solo 0.130, lo que indica una falta significativa de equilibrio entre precisión y recall.

Ilustración 19. Curva de Precisión-Recall para la Clase MOKO




Autor: Kevin Cedeño

Análisis de la Curva de Precisión-Recall para la Clase MOKO:

Estabilidad: La precisión se mantiene cerca de 1.0 como se muestra en la ilustración 19, esto muestra un amplio rango de valores de recall, lo que indica un excelente desempeño en la detección de MOKO.

Caída: La caída en la precisión hacia el final sugiere que el modelo tuvo dificultades al tratar de aumentar el recall a niveles muy altos, lo que podría ser indicativo de sobreajuste.

Ilustración 20. Curva de Precisión-Recall para la Clase SANAS




Autor: Kevin Cedeño

Análisis Curva de Precisión-Recall para la Clase SANAS:

Estabilidad: Similar a MOKO, la precisión se mantiene en 1.0 a lo largo de la mayoría de los valores de recall, lo que indica un alto rendimiento en la clasificación de hojas sanas.

Caída abrupta: La precisión se mantiene alta hasta que el recall alcanza casi 1.0, donde se observa una caída abrupta, lo cual podría sugerir problemas cuando se trata de clasificar casos difíciles o atípicos.

Ilustración 21. Curva de Precisión-Recall para la Clase SIGATOKA



Autor: Kevin Cedeño

Análisis Curva de Precisión-Recall para la Clase SIGATOKA:


Inconsistencias: A diferencia de MOKO y SANAS, la curva de SIGATOKA muestra varias fluctuaciones, lo que sugiere que el modelo tiene dificultades para clasificar correctamente esta clase.

Caída Temprana: La caída en la precisión se produce más temprano, lo que indica que el modelo tiene problemas para mantener una alta precisión al tratar de maximizar el recall para SIGATOKA.

El rendimiento de TensorFlow con imágenes de baja resolución y 50 épocas es inferior. Esto sugiere que EfficientDet-Lite0, en estas condiciones, no es capaz de capturar suficientes características distintivas para una clasificación precisa.

Resultados de EfficientDet-Lite0 con Imágenes de 256x256 Píxeles y 150 Épocas:

Ilustración 22. Matriz de Confusión del modelo EfficientDet-Lite0 150 épocas



Autor: Kevin Cedeño

Análisis de la Matriz de Confusión (Confusion Matrix):

Ejes: En la matriz de confusión presentada, los ejes representan las clases de enfermedades y la clase "Sanas" tanto en la predicción (eje X) como en la realidad (eje Y).

Interpretación de los Cuadros:

- Los cuadros de la matriz indican el número de instancias en las que el modelo clasificó correctamente o incorrectamente cada clase.
- Por ejemplo, el cuadro en la intersección de la fila MOKO y la columna MOKO indica que el modelo predijo correctamente 8 veces la clase MOKO.
- Un valor fuera de la diagonal indica un error de clasificación. Por ejemplo, la celda (SIGATOKA, SANAS) con valor "1" indica que una instancia que era realmente de la clase SIGATOKA fue clasificada incorrectamente como SANAS.

Valores Diagonales:

- **MOKO:** 8 instancias correctamente clasificadas.

- **SANAS:** 6 instancias correctamente clasificadas.
- **SIGATOKA:** 3 instancias correctamente clasificadas.

Valores Fuera de la Diagonal:

- SIGATOKA fue incorrectamente clasificado como SANAS en 1 ocasión.
- No hubo otras clasificaciones erróneas para las clases MOKO y SANAS en este modelo.

Tabla 9. *Precisión por clase usando EfficientDet-Lite0 con 150 épocas*

Clase	Precisión	Recall	F1-Score
Moko Bacteriano	0.600	0.580	0.590
Sigatoka Negra	0.650	0.630	0.640
Hojas Sanas	0.640	0.680	0.660
mAP@0.5	0.620		


Autor: Kevin Cedeño

Fuente: Investigación

Análisis de la tabla 9:

- **Precisión y Recall:** Aunque hay mejoras en comparación con las configuraciones de menor resolución, EfficientDet-Lite0 aún muestra un rendimiento. Esto puede deberse a la limitación de resolución (máximo 512x512 píxeles) que no permite capturar todos los detalles necesarios para una clasificación óptima.
- **F1-Score:** El F1-Score es razonablemente equilibrado, lo que refuerza la idea de que EfficientDet-Lite0 podría estar limitado por la resolución y las capacidades del hardware.

Ilustración 23. Curva Precisión-Recall con 150 épocas



Autor: Kevin Cedeño

Análisis de la Curva Precisión-Recall (Precision-Recall Curve):

Estabilidad:

- La curva de precisión-recall para las clases MOKO y SANAS muestra una alta estabilidad, manteniendo una precisión de 1.0 hasta un recall de 0.8 o 1.0.
- Para la clase SIGATOKA, la curva muestra fluctuaciones, indicando que la precisión disminuye significativamente después de un recall de 0.2.

Constancia:

- La precisión se mantiene constante en 1.0 para MOKO y SANAS hasta que el recall alcanza su máximo.
- En el caso de SIGATOKA, la precisión no es constante y disminuye a medida que aumenta el recall, lo que sugiere que el modelo tiene problemas para clasificar correctamente todas las instancias de SIGATOKA.


Posible Overfitting o Subajuste:

- La alta precisión constante para MOKO y SANAS podría sugerir un posible overfitting para estas clases, ya que el modelo parece estar sobreajustado a estas clases en particular, pero no se detecta ningún problema en los datos actuales.
- La fluctuación en la curva de SIGATOKA podría indicar que el modelo tiene problemas para generalizar bien esta clase, lo que podría ser una señal de subajuste en esta clase en particular.

Si bien hay mejoras notables, EfficientDet-Lite0 sigue siendo limitado por la resolución máxima que puede manejar, lo que reduce su eficacia en la clasificación precisa de las enfermedades.

Resultados de EfficientDet-Lite0 con Imágenes de 256x256 Píxeles y 200 Épocas:

Ilustración 24. Matriz de Confusión del modelo EfficientDet-Lite0 200 épocas



Autor: Kevin Cedeño

Análisis de la Matriz de Confusión (Confusion Matrix):

Ejes y Clases: En la matriz de confusión presentada, los ejes representan las clases de enfermedades MOKO, SIGATOKA, y SANAS tanto en la predicción (eje X) como en la realidad (eje Y).

Interpretación de los Cuadros:

- Los cuadros de la matriz muestran el número de instancias en las que el modelo clasificó correctamente o incorrectamente cada clase.
- Por ejemplo, el cuadro en la intersección de la fila MOKO y la columna MOKO indica que el modelo predijo correctamente 8 veces la clase MOKO.
- Un valor fuera de la diagonal indica un error de clasificación. Por ejemplo, la celda (SIGATOKA, SANAS) con valor "1" indica que una instancia que era realmente de la clase SIGATOKA fue clasificada incorrectamente como SANAS.

Valores Diagonales:

- **MOKO:** 8 instancias correctamente clasificadas.
- **SANAS:** 6 instancias correctamente clasificadas.
- **SIGATOKA:** 3 instancias correctamente clasificadas.

Valores Fuera de la Diagonal:

- SIGATOKA fue incorrectamente clasificado como SANAS en 1 ocasión.
- No hubo otras clasificaciones erróneas para las clases MOKO y SANAS en este modelo.

Tabla 10. *Precisión por clase usando EfficientDet-Lite0 con 200 épocas*

Clase	Precisión	Recall	F1-Score
Moko Bacteriano	0.710	0.700	0.705
Sigatoka Negra	0.670	0.660	0.665
Hojas Sanas	0.690	0.710	0.700
mAP@0.5	0.680		

Autor: Kevin Cedeño


Fuente: Investigación

Análisis de la tabla 10:

- **Precisión y Recall:** Aunque hay mejoras con respecto a configuraciones de menor resolución, el modelo muestra un rendimiento aceptable con valores de precisión y recall en torno al 0.7 para todas las clases.
- **F1-Score:** El F1-Score muestra un buen equilibrio, lo que sugiere que la resolución y el número de épocas limitan la capacidad del modelo para aprender características detalladas necesarias para una clasificación precisa.
- **mAP@0.5:** El valor de 0.680 refuerza la idea de que, aunque EfficientDet-Lite0 puede funcionar razonablemente bien en esta configuración, está limitado por las capacidades del hardware y la resolución de imagen.

Análisis de la Curva Precisión-Recall (Precision-Recall Curve):

Ilustración 25. Curva Precisión-Recall con 200 épocas



Autor: Kevin Cedeño

Estabilidad:

- La curva de precisión-recall para la clase MOKO muestra una alta estabilidad, manteniendo una precisión de 1.0 hasta un recall de 0.8.
- Para la clase SANAS, la precisión es constante en 1.0 hasta un recall de 1.0.
- La curva para la clase SIGATOKA muestra fluctuaciones significativas, lo que indica que la precisión disminuye considerablemente después de un recall de 0.2.

Constancia:

- La precisión se mantiene constante en 1.0 para MOKO y SANAS hasta que el recall alcanza su máximo.
- Para SIGATOKA, la precisión no es constante y muestra una disminución notable a medida que el recall aumenta, lo que sugiere que el modelo tiene problemas para clasificar correctamente todas las instancias de SIGATOKA.

Posible Overfitting o Subajuste:


- La alta precisión constante para MOKO y SANAS podría sugerir un posible overfitting para estas clases, ya que el modelo parece estar sobreajustado a estas clases en particular, pero no se detecta ningún problema en los datos actuales.

La fluctuación en la curva de SIGATOKA podría indicar que el modelo tiene problemas para generalizar bien esta clase, lo que podría ser una señal de subajuste en esta clase en particular.

TensorFlow tiene limitaciones claras cuando se trata de manejar resoluciones más altas debido a restricciones de hardware. Aunque el rendimiento es decente, no puede competir con YOLOv5 en escenarios que requieren alta precisión y resolución.

Resultados con Imágenes de 512x512 Píxeles y 50 Épocas:

Ilustración 26. Matriz de Confusión del modelo EfficientDet-Lite0 50 épocas (512x512)



Autor: Kevin Cedeño

Análisis de la Matriz de Confusión

Ejes y Clases:

- Eje Y (Vertical): Representa las clases reales (clases verdaderas) de las instancias. En este caso, las clases son Hojas Sanas, Moko Bacteriano, y Sigatoka Negra.
- Eje X (Horizontal): Representa las clases predichas por el modelo. Las mismas clases están listadas: Hojas Sanas, Moko Bacteriano, y Sigatoka Negra.

Valores Diagonales:

- **Hojas Sanas (23):** El modelo predijo correctamente 23 instancias de Hojas Sanas como Hojas Sanas.
- **Moko Bacteriano (46):** El modelo predijo correctamente 46 instancias de Moko Bacteriano como Moko Bacteriano.
- **Sigatoka Negra (34):** El modelo predijo correctamente 34 instancias de Sigatoka Negra como Sigatoka Negra.

Valores Fuera de la Diagonal:

- **Hojas Sanas:** Fue incorrectamente clasificado como Sigatoka Negra en 1 ocasión.
- **Moko Bacteriano:** Fue incorrectamente clasificado como Sigatoka Negra en 1 ocasión.
- **Sigatoka Negra:** Fue incorrectamente clasificado como Moko Bacteriano en 1 ocasión.

El modelo muestra un alto grado de precisión para todas las clases, ya que la mayoría de las instancias están correctamente clasificadas en los valores diagonales.

Los errores de clasificación (valores fuera de la diagonal) son mínimos, lo que indica un buen desempeño del modelo en la clasificación de Hojas Sanas, Moko Bacteriano y Sigatoka Negra.

Tabla 11. *Precisión por clase usando EfficientDet-Lite0 con 50 épocas*

Clase	Precisión	Recall	F1-Score
Moko Bacteriano	0.979	0.979	0.979
Sigatoka Negra	0.971	0.971	0.971
Hojas Sanas	1.000	0.958	0.978
mAP@0.5	0.983		

Autor: Kevin Cedeño


Fuente: Investigación

Análisis de la tabla 11:

- **Precisión y Recall:** En general, el modelo muestra un rendimiento adecuado en la clasificación de las clases Moko Bacteriano, Sigatoka Negra, y Hojas Sanas, con valores de precisión y recall cercanos al 1.0 en la mayoría de los casos. Esto indica que el modelo puede identificar correctamente la mayoría de las instancias, con pocos errores de predicción.
- **F1-Score:** El F1-Score mantiene un equilibrio entre la precisión y el recall, lo que sugiere que el modelo es robusto en la clasificación de las clases. Los valores cercanos a 1.0 en todas las clases indican un buen rendimiento en la detección de las enfermedades y plantas sanas.

- **mAP@0.5:** El valor de 0.983 refuerza la idea de que el modelo es capaz de generalizar bien a diferentes umbrales de confianza. Este alto valor indica que el sistema es preciso y confiable en la detección de las enfermedades y hojas sanas, lo que sugiere que el modelo es adecuado para ser implementado en un entorno práctico.

Ilustración 27. Curva de Precisión (Accuracy Curve), 50 épocas resolución 512x512



Autor: Kevin Cedeño


Curva de Precisión (Accuracy Curve):

- **Entrenamiento (Train Accuracy):** La línea azul muestra cómo la precisión del modelo en los datos de entrenamiento mejora rápidamente desde el inicio y se estabiliza cerca del 100%, lo que significa que el modelo aprende bien a clasificar los datos que ha visto.
- **Validación (Validation Accuracy):** La línea naranja muestra la precisión en los datos de validación (datos que el modelo no ha visto). También mejora rápidamente y se estabiliza alrededor del 90%, lo que indica que el modelo generaliza bien a nuevos datos.

Ambas curvas son estables, lo que significa que el modelo está aprendiendo correctamente y no tiene problemas de sobreajuste o sub ajuste. Las fluctuaciones sugieren que el modelo tiene dificultades para optimizar completamente las cajas delimitadoras, lo que podría mejorarse con más datos o ajustes en los hiperparámetros.

Resultados con Imágenes de 512x512 Píxeles y 150 Épocas:

Ilustración 28. Matriz de Confusión del modelo *EfficientDet-Lite0* 50 épocas (512x512)



Autor: Kevin Cedeño

Análisis de la Matriz de Confusión

Ejes y Clases:

- **Eje Y (Vertical):** Representa las clases verdaderas o reales (las etiquetas verdaderas) de las instancias que se están evaluando. En este caso, las clases son HOJAS SANAS, MOKO BACTERIANO, y SIGATOKA NEGRA.
- **Eje X (Horizontal):** Representa las clases predichas por el modelo. Estas predicciones pueden ser correctas o incorrectas en relación con la etiqueta real de las instancias. Las mismas clases están representadas en este eje: HOJAS SANAS, MOKO BACTERIANO, y SIGATOKA NEGRA.

Valores Diagonales:

- **Hojas Sanas (23):** El modelo predijo correctamente 23 instancias de hojas sanas como hojas sanas.
- **Moko Bacteriano (45):** El modelo predijo correctamente 45 instancias de Moko bacteriano como Moko bacteriano.
- **Sigatoka Negra (34):** El modelo predijo correctamente 34 instancias de Sigatoka Negra como Sigatoka Negra.

Valores Fuera de la Diagonal:

- **Hojas Sanas:** Hubo una instancia de hoja sana que fue clasificada incorrectamente como Sigatoka Negra.
- **Moko Bacteriano:** Hubo dos instancias de Moko bacteriano que fueron clasificadas incorrectamente como Sigatoka Negra.
- **Sigatoka Negra:** Hubo una instancia de Sigatoka Negra que fue clasificada incorrectamente como Moko bacteriano.

Tabla 12. *Precisión por clase usando EfficientDet-Lite0 con 150 épocas*

Clase	Precisión	Recall	F1-Score
Hojas Sanas	0.958	0.958	0.958
Moko Bacteriano	0.957	0.938	0.947
Sigatoka Negra	0.943	0.971	0.957
mAP@0.5	0.952		


Autor: Kevin Cedeño

Fuente: Investigación

Análisis de la tabla 12:

- **Precisión y Recall:** Se observa que el modelo tiene un buen rendimiento general, manteniendo valores cercanos al 0.95 en todas las clases.
- **F1-Score:** El modelo muestra un balance adecuado entre precisión y recall, con F1-Score alrededor de 0.95, lo que indica que el modelo está bien optimizado para detectar las diferentes clases.
- **mAP@0.5:** El promedio de precisión para el umbral de confianza del 0.5 también es alto (0.952), lo que refuerza que el modelo es confiable.

Ilustración 29. Curva de Precisión (Accuracy Curve), 150 épocas resolución 512x512



Autor: Kevin Cedeño


Curva de Precisión (Accuracy Curve):

- **Train Accuracy:** Representa la precisión del modelo en los datos de entrenamiento. Aquí podemos ver que, después de las primeras épocas, el modelo alcanza casi un 100% de precisión, lo que indica que está aprendiendo muy bien en los datos con los que ha sido entrenado.
- **Validation Accuracy:** Representa la precisión en los datos de validación (datos que el modelo no ha visto durante el entrenamiento). La precisión en estos datos también es alta, pero fluctúa más que la precisión en el entrenamiento. Estas fluctuaciones indican que el modelo no está generalizando tan bien a datos nuevos, lo que puede ser una señal de sobre entrenamiento.

El modelo está funcionando bien en general, pero hay indicios de que podría haber un ligero sobre entrenamiento, lo que se evidencia en las fluctuaciones de la curva de validación.

Resultados con Imágenes de 512x512 Píxeles y 200 Épocas:

Ilustración 30. Matriz de Confusión del modelo *EfficientDet-Lite0* 200 épocas (512x512)



Autor: Kevin Cedeño

Análisis de la Matriz de Confusión:

Ejes y Clases:

- **Eje Y (Vertical):** Representa las clases reales de las instancias, en este caso Hojas Sanas, Moko Bacteriano, y Sigatoka Negra.
- **Eje X (Horizontal):** Representa las clases predichas por el modelo. Las mismas clases están listadas: Hojas Sanas, Moko Bacteriano, y Sigatoka Negra.

Valores Diagonales (Predicciones Correctas):

- **Hojas Sanas:** El modelo predijo correctamente 23 instancias de Hojas Sanas como Hojas Sanas.
- **Moko Bacteriano:** El modelo predijo correctamente 46 instancias de Moko Bacteriano como Moko Bacteriano.
- **Sigatoka Negra:** El modelo predijo correctamente 33 instancias de Sigatoka Negra como Sigatoka Negra.

Valores Fuera de la Diagonal (Errores de Clasificación):

- **Hojas Sanas:** Hubo 1 instancia de Hojas Sanas clasificada incorrectamente como Sigatoka Negra.
- **Sigatoka Negra:** 2 instancias de Sigatoka Negra fueron clasificadas incorrectamente como Hojas Sanas.
- **Moko Bacteriano:** 1 instancia de Moko Bacteriano fue clasificada incorrectamente como Sigatoka Negra.

Tabla 13. *Precisión por clase usando EfficientDet-Lite0 con 200 épocas*

Clase	Precisión	Recall	F1-Score
Moko Bacteriano	0.979	0.965	0.972
Sigatoka Negra	0.973	0.950	0.961
Hojas Sanas	0.958	0.950	0.954
mAP@0.5	0.970		

Autor: Kevin Cedeño


Fuente: Investigación

Análisis de la tabla 13:

- **Precisión y Recall:** El modelo muestra un excelente rendimiento en las tres clases, con valores de precisión y recall superiores a 0.95. Esto sugiere que el modelo es efectivo tanto en la identificación correcta (precisión) como en la recuperación de la mayoría de las instancias (recall) para cada clase. Las clases Hojas Sanas y Sigatoka Negra tienen una precisión y recall ligeramente menores, pero aún dentro de un rango aceptable para la tarea de clasificación de imágenes.
- **F1-Score:** Los valores del F1-Score, que balancean precisión y recall, se mantienen altos en todas las clases, con un F1 de 0.972 para Moko Bacteriano, el cual indica que el modelo maneja esta clase particularmente bien. Las otras dos clases, Hojas Sanas y Sigatoka Negra, también tienen buenos resultados, lo que sugiere un balance sólido en el rendimiento del modelo.
- **mAP@0.5:** El valor mAP@0.5 de 0.970 refuerza que el modelo es altamente eficiente en la detección de objetos en las imágenes. Este alto valor sugiere que el modelo realiza predicciones precisas en la mayoría de las ocasiones,

proporcionando una solución confiable para la clasificación de enfermedades en hojas de banano.

Ilustración 31. *Curva de Precisión (Accuracy Curve), 200 épocas resolución 512x512*



Autor: Kevin Cedeño

Curva de Precisión (Accuracy Curve):

- **Train Accuracy:** Representa la precisión del modelo en los datos de entrenamiento. Aquí podemos ver que, después de las primeras épocas, el modelo alcanza una precisión casi del 100%, lo que indica que ha aprendido muy bien en los datos con los que ha sido entrenado.
- **Validation Accuracy:** Representa la precisión en los datos de validación (datos que el modelo no ha visto durante el entrenamiento). La precisión en estos datos también es alta, pero presenta fluctuaciones a lo largo de las épocas, lo que indica que el modelo no está generalizando tan bien en datos nuevos como lo hace en el conjunto de entrenamiento. Esto podría ser un indicio de sobreentrenamiento (overfitting), ya que el modelo parece aprender patrones específicos de los datos de entrenamiento, pero no generaliza tan bien en datos nuevos.


4.3.1.3 Entrenamiento del Modelo YOLOv5.

- **Resolución:** 256x256, 512x512, 1024x1024 píxeles.
- **Épocas:** 50, 150, 200.

- **Características:** YOLOv5 es conocido por su capacidad de realizar detección en tiempo real con alta precisión. Este modelo es altamente flexible y capaz de manejar imágenes de alta resolución, lo que lo convierte en una opción robusta para tareas de detección de objetos.

Resultados de YOLOv5 con Imágenes de 256x256 Píxeles y 50 Épocas:

Ilustración 32. Matriz de Confusión del modelo YOLO v5 50 épocas



Autor: Kevin Cedeño

Análisis de la Matriz de Confusión:

Ejes y Clases:

- **Eje Y (Vertical):** Representa las clases reales (verdaderas) de las instancias. Las clases son: MOKO, SANAS, y SIGATOKA.
- **Eje X (Horizontal):** Representa las predicciones realizadas por el modelo para esas mismas clases: MOKO, SANAS, y SIGATOKA.

Valores Diagonales:

- **MOKO (0.80):** El modelo predijo correctamente la clase MOKO en un 80% de los casos.
- **SANAS (0.77):** El modelo predijo correctamente la clase SANAS en un 77% de los casos.

- **SIGATOKA (0.73):** El modelo predijo correctamente la clase SIGATOKA en un 73% de los casos.

Valores Fuera de la Diagonal:

- **MOKO mal clasificado como SANAS (0.08):** El 8% de las instancias de MOKO fueron clasificadas incorrectamente como SANAS.
- **MOKO mal clasificado como SIGATOKA (0.01):** El 1% de las instancias de MOKO fueron clasificadas incorrectamente como SIGATOKA.
- **SANAS mal clasificado como SIGATOKA (0.06):** El 6% de las instancias de SANAS fueron clasificadas incorrectamente como SIGATOKA.
- **SIGATOKA mal clasificada como MOKO (0.54):** El 54% de las instancias de SIGATOKA fueron clasificadas incorrectamente como MOKO.
- **SIGATOKA mal clasificada como SANAS (0.28):** El 28% de las instancias de SIGATOKA fueron clasificadas incorrectamente como SANAS.

Tabla 14. *Precisión por clase usando YOLO v5 con 50 épocas*

Clase	Precisión	Recall	F1-Score
Moko Bacteriano	0.80	0.54	0.67
Sigatoka Negra	0.77	0.28	0.44
Hojas Sanas	0.73	0.18	0.27
mAP@0.5 (global)	0.73		

Autor: Kevin Cedeño

Fuente: Investigación

Análisis de la tabla 14:

Precisión y Recall:

- El modelo presenta un desempeño adecuado, con una precisión de 0.80 en la clase Moko Bacteriano, lo que indica que predice correctamente la mayoría de las instancias. Sin embargo, el valor de recall de 0.54 sugiere que no logra identificar todos los casos reales, lo que deja un margen de mejora en esta clase.
- Las clases Sigatoka Negra y Hojas Sanas muestran valores de precisión y recall más bajos, lo que significa que el modelo tiene más dificultades para clasificarlas correctamente. El bajo recall (0.28 para Sigatoka Negra y 0.18 para Hojas Sanas)

indica que el modelo no está capturando suficientes ejemplos verdaderos para estas clases.

F1-Score:

- El F1-Score de Moko Bacteriano es de 0.67, lo que refleja un balance relativamente bueno entre precisión y recall en esta clase.
- Por otro lado, los valores de F1-Score para Sigatoka Negra (0.44) y Hojas Sanas (0.27) muestran un rendimiento limitado del modelo, con dificultades en ambas clases, lo que podría mejorar con ajustes adicionales.


mAP@0.5:

- El valor de mAP@0.5 es de 0.73, lo que sugiere que, aunque el modelo tiene un rendimiento aceptable en general, hay áreas para mejorar, sobre todo en la capacidad de detectar con precisión y consistencia Sigatoka Negra y Hojas Sanas.

El modelo muestra un buen rendimiento en la clasificación de Moko Bacteriano, pero tiene dificultades con Sigatoka Negra y Hojas Sanas, especialmente en su capacidad de identificar correctamente estas clases (bajo recall). Esto sugiere que el modelo podría beneficiarse de más ajustes en la detección de esas clases para mejorar su capacidad de generalización.

Resultados de YOLOv5 con Imágenes de 256x256 Píxeles y 150 Épocas:

Ilustración 33. Matriz de Confusión del modelo YOLO v5 150 épocas



Autor: Kevin Cedeño

Análisis de la Matriz de Confusión:

Ejes y Clases:

- **Eje Y (Vertical):** Representa las clases reales o verdaderas de las instancias, en este caso: Moko, Sanas, Sigatoka, y background.
- **Eje X (Horizontal):** Representa las clases predichas por el modelo. Las mismas clases aparecen: Moko, Sanas, Sigatoka, y background.

Valores Diagonales:

- **Moko (0.78):** El modelo identificó correctamente el 78% de las instancias de Moko como Moko, pero tiene un 22% de error al predecir otras clases.
- **Sanas (0.73):** El 73% de las instancias de Hojas Sanas fueron correctamente clasificadas, aunque un 27% se confundieron con otras clases.
- **Sigatoka (0.82):** El 82% de las instancias de Sigatoka Negra fueron correctamente detectadas, lo que indica un buen rendimiento en esta clase.
- **Background:** Las clases del background presentan un nivel de detección más bajo (0.22 a 0.16), lo que muestra que el modelo puede estar teniendo dificultades en distinguir correctamente las áreas sin enfermedad.

Valores Fuera de la Diagonal:

- Se observa que el modelo confundió un 7% de Moko con Sanas, y un 2% con Sigatoka, lo cual es un indicador de que el modelo no es completamente preciso en distinguir entre estas enfermedades.
- En el caso de las Hojas Sanas, el 1% fue clasificado erróneamente como Sigatoka, mientras que un 23% se confundieron con el background, lo que sugiere una posible confusión en el procesamiento de las áreas sin enfermedad.
- Para Sigatoka Negra, solo un 17% fue confundido con el background, lo que refleja una buena capacidad del modelo para separar esta clase de los otros entornos.

Tabla 15. *Precisión por clase usando YOLO v5 con 150 épocas*

Clase	Precisión	Recall	F1-Score
Moko Bacteriano	0.75	0.56	0.64
Sigatoka Negra	0.68	0.35	0.46
Hojas Sanas	0.70	0.30	0.42
mAP@0.5	0.70		

Autor: Kevin Cedeño

Fuente: Investigación

Análisis de la tabla 15:

Precisión y Recall:

- Moko Bacteriano muestra un buen desempeño en términos de precisión (0.75) y recall (0.56). Esto significa que el modelo puede identificar correctamente la mayoría de las instancias de Moko Bacteriano, aunque hay margen de mejora.
- Sigatoka Negra presenta valores de precisión (0.68) y recall (0.35) más bajos, lo que indica que el modelo tiene dificultades para identificar correctamente esta clase, especialmente en la recuperación de instancias.
- Hojas Sanas tiene una precisión de 0.70, lo cual es aceptable, pero su recall es bajo (0.30), lo que sugiere que el modelo no logra detectar todas las instancias de hojas sanas de manera efectiva.

F1-Score:

- El F1-Score de Moko Bacteriano es 0.64, lo que muestra un buen balance entre precisión y recall, aunque aún puede mejorarse para obtener una mejor clasificación.
- Sigatoka Negra tiene un F1-Score de 0.46, lo que refleja las dificultades del modelo para manejar esta clase de manera efectiva.
- Hojas Sanas tiene un F1-Score de 0.42, que muestra que el modelo no está manejando bien esta clase debido a su bajo recall.


mAP@0.5:

- El valor mAP@0.5 es de 0.70, lo que sugiere que, el modelo está funcionando bien en términos de precisión promedio en todas las clases, pero podría beneficiarse de una mayor optimización para mejorar.

El modelo tiene un buen desempeño en la clasificación de Moko y Sigatoka Negra, aunque presenta algunas confusiones entre las clases y con el background. El rendimiento en la detección de Hojas Sanas es razonable, pero podría mejorarse aún más para reducir las confusiones con otras clases o áreas sin enfermedades.

Resultados de YOLOv5 con Imágenes de 256x256 Píxeles y 200 Épocas:

Ilustración 34. Matriz de Confusión del modelo YOLO v5 200 épocas



Autor: Kevin Cedeño

Análisis de la Matriz de Confusión:

Ejes y Clases:

- **Eje Y (Vertical):** Representa las clases reales o verdaderas de las instancias, en este caso: Moko, Sanas, Sigatoka y background.
- **Eje X (Horizontal):** Representa las clases predichas por el modelo. Las mismas clases aparecen: Moko, Sanas, Sigatoka y background.

Valores Diagonales:

- **Moko (0.78):** El modelo identificó correctamente el 78% de las instancias de Moko como Moko, pero presenta un 22% de error al predecir otras clases.

- **Sanas (0.73):** El 73% de las instancias de Hojas Sanas fueron correctamente clasificadas, aunque un 27% se confundieron con otras clases.
- **Sigatoka (0.78):** El 78% de las instancias de Sigatoka Negra fueron correctamente detectadas, lo que indica un buen rendimiento en esta clase.
- **Background:** Las clases del background presentan un nivel de detección más bajo (0.22 a 0.17), lo que muestra que el modelo podría estar teniendo dificultades en distinguir correctamente las áreas sin enfermedad.

Valores Fuera de la Diagonal:

- Se observa que el modelo confundió un 6% de Moko con Sanas, y un 1% con Sigatoka, lo cual es un indicador de que el modelo no es completamente preciso en distinguir entre estas enfermedades.
- En el caso de las Hojas Sanas, un 5% fue clasificado erróneamente como Moko, mientras que un 28% se confundieron con Sigatoka, lo que sugiere una posible confusión en el procesamiento de las áreas con enfermedades similares.
- Para Sigatoka Negra, solo un 17% fue confundido con Moko, lo que refleja una buena capacidad del modelo para separar esta clase de las demás, pero aún muestra margen de mejora.

Tabla 16. *Precisión por clase usando YOLO v5 con 200 épocas*

Clase	Precisión	Recall	F1-Score
Moko Bacteriano	0.78	0.56	0.65
Sigatoka Negra	0.71	0.28	0.42
Hojas Sanas	0.73	0.17	0.28
mAP@0.5 (global)	0.73		

Autor: Kevin Cedeño

Fuente: Investigación

Análisis de la tabla 16:

Precisión y Recall:

- La clase Moko Bacteriano tiene la mayor precisión (0.78) y recall (0.56), lo que indica que el modelo identifica correctamente una gran parte de las instancias de esta clase, aunque aún se presenta un 44% de falsos negativos.

- Sigatoka Negra presenta un recall bastante bajo (0.28), lo que sugiere que el modelo tiene dificultades para detectar correctamente las instancias de esta clase. Su precisión (0.71) indica que, aunque pocas veces detecta correctamente Sigatoka Negra, cuando lo hace, lo hace bien.
- Las Hojas Sanas tienen una precisión aceptable (0.73), pero el recall es el más bajo (0.17), lo que significa que el modelo está clasificando erróneamente una gran parte de las instancias de Hojas Sanas.

F1-Score:

- El F1-Score para Moko Bacteriano es de 0.65, lo que muestra un buen equilibrio entre precisión y recall para esta clase, aunque con espacio para mejorar en la identificación de algunas instancias.
- El F1-Score para Sigatoka Negra es bajo (0.42), lo que refleja el reto que enfrenta el modelo al identificar esta clase con precisión y en una cantidad suficiente de casos.
- Las Hojas Sanas tienen un F1-Score de 0.28, lo que sugiere que el modelo no está manejando bien esta clase y confunde muchos de sus ejemplos con otras clases o el background.


mAP@0.5 (global):

- El valor de mAP@0.5 de 0.73 sugiere que el modelo es capaz de detectar las clases con un rendimiento aceptable en general. Sin embargo, los valores individuales de recall y F1-Score indican que aún hay margen de mejora en la clasificación de Hojas Sanas y Sigatoka Negra.

El modelo tiene algunas dificultades para diferenciar entre las clases, especialmente al confundir Sanas con Sigatoka, lo que podría sugerir que las características visuales de ambas clases son similares para el modelo.

Resultados de YOLOv5 con Imágenes de 512x512 Píxeles y 50 Épocas:

Ilustración 35. Matriz de Confusión del modelo YOLO v5 50 épocas



Autor: Kevin Cedeño

Análisis de la Matriz de Confusión:

Ejes y Clases:

- **Eje Y (Vertical):** Representa las clases reales o verdaderas de las instancias, en este caso: Moko, Sanas, Sigatoka y background.
- **Eje X (Horizontal):** Representa las clases predichas por el modelo. Las mismas clases aparecen: Moko, Sanas, Sigatoka y background.

Valores Diagonales:

- **Moko (0.78):** El modelo identificó correctamente el 78% de las instancias de Moko como Moko. Esto indica un buen rendimiento para esta clase, aunque el 22% de las instancias no fueron clasificadas correctamente.
- **Sanas (0.71):** El 71% de las instancias de Hojas Sanas fueron correctamente clasificadas, mientras que un 29% se confundió con otras clases, lo que indica cierta dificultad para diferenciar Hojas Sanas de otros casos.
- **Sigatoka (0.78):** El 78% de las instancias de Sigatoka Negra fueron correctamente detectadas, lo que refleja un buen rendimiento, pero aún hay margen de mejora.
- **Background:** Las clases del background presentan valores más bajos, con un 22% a 23% en la diagonal, lo que sugiere que el modelo aún tiene dificultades en distinguir claramente las áreas sin enfermedad o de fondo.

Valores Fuera de la Diagonal:

- **Moko:** Un 6% de las instancias de Moko fueron erróneamente clasificadas como Hojas Sanas, y un 1% como Sigatoka. Esto indica que el modelo todavía enfrenta dificultades en separar claramente Moko de estas otras clases.
- **Sanas:** Un 5% de las instancias de Hojas Sanas fueron clasificadas incorrectamente como Moko, mientras que un 28% se confundió con Sigatoka, lo que sugiere una posible confusión en áreas con enfermedades similares.
- **Sigatoka Negra:** Un 17% de las instancias de Sigatoka Negra fueron erróneamente clasificadas como Moko, lo que muestra que, aunque el modelo tiene un buen rendimiento en esta clase, aún presenta dificultades para distinguirla completamente de otras enfermedades.

Tabla 17. *Precisión por clase usando YOLO v5 con 50 épocas*

Clase	Precisión	Recall	F1-Score
Moko Bacteriano	0.77	0.56	0.65
Sigatoka Negra	0.71	0.28	0.40
Hojas Sanas	0.73	0.17	0.27
mAP@0.5	0.77		

Autor: Kevin Cedeño

Fuente: Investigación

Análisis de la Tabla 17:

- **Precisión y Recall:** El modelo muestra un desempeño mixto en términos de precisión y recall entre las tres clases. La clase Moko Bacteriano tiene un valor de precisión aceptable (0.77) y un recall relativamente más bajo (0.56), lo que indica que el modelo identifica bien la enfermedad, pero no todas las instancias son correctamente detectadas. Sigatoka Negra tiene un recall muy bajo (0.28), lo que sugiere que muchas instancias de esta clase no están siendo correctamente identificadas. Las Hojas Sanas presentan un balance similar, con una precisión moderada (0.73), pero un recall bastante bajo (0.17), lo que sugiere que una gran parte de las hojas sanas no son identificadas correctamente.
- **F1-Score:** El F1-Score, que es una métrica que balancea precisión y recall, también muestra disparidades. La clase Moko Bacteriano tiene un F1-Score de


0.65, lo que refleja un rendimiento equilibrado, aunque con espacio para mejoras. Las clases Sigatoka Negra y Hojas Sanas tienen F1-Scores significativamente más bajos (0.40 y 0.27, respectivamente), lo que indica que el modelo tiene dificultades para distinguir claramente estas dos clases.

- **mAP@0.5:** El valor de mAP@0.5 global es de 0.77, lo que sugiere que el modelo tiene un rendimiento razonable en la detección de objetos en general, aunque no es del todo consistente. Este valor refleja que, a pesar de los desafíos en la clasificación de algunas clases, el modelo mantiene un rendimiento aceptable para un umbral de confianza del 50%.

El modelo muestra un buen rendimiento para la clase Moko Bacteriano, tiene dificultades para distinguir correctamente entre Sigatoka Negra y Hojas Sanas, lo que se evidencia por los valores bajos de recall y F1-Score en estas clases. Esto sugiere que el modelo podría mejorar ya sea mediante una optimización, ajuste de hiperparámetros o la mejora de la calidad de los datos.

Resultados de YOLOv5 con Imágenes de 512x512 Píxeles y 150 Épocas:

Ilustración 36. Matriz de Confusión del modelo YOLO v5 150 épocas



Autor: Kevin Cedeño

Análisis de la Matriz de Confusión:

Ejes y Clases:

- **Eje Y (Vertical):** Representa las clases reales de las instancias. En este caso, las clases evaluadas son Moko, Sanas, Sigatoka y background.
- **Eje X (Horizontal):** Representa las clases predichas por el modelo. Las mismas clases evaluadas en el eje vertical (Moko, Sanas, Sigatoka y background).

Valores Diagonales:

- **Moko (0.82):** El modelo identificó correctamente el 82% de las instancias de Moko como Moko, lo que refleja un buen desempeño en esta clase. Pero, el 18% fue clasificado incorrectamente.
- **Sanas (0.73):** El 73% de las instancias de hojas sanas fueron correctamente clasificadas. El modelo tuvo un 27% de error al confundir estas instancias con otras clases, principalmente con Sigatoka.
- **Sigatoka (0.79):** El modelo tuvo un buen rendimiento en la identificación de Sigatoka, acertando en el 79% de los casos.
- **Background:** Los valores de fondo reflejan dificultades en la clasificación de áreas sin enfermedades, ya que hay confusión con Moko, Sanas y Sigatoka.

Valores Fuera de la Diagonal:

- **Moko y otras clases:** Un 2% de las instancias de Moko fueron clasificadas como hojas sanas, mientras que un 1% fue confundido con Sigatoka. Esto refleja que el modelo presenta una ligera confusión entre las enfermedades.
- **Sanas y Sigatoka:** El 4% de las hojas sanas fue clasificado erróneamente como Sigatoka, mientras que un 3% fue confundido con Moko. Este error sugiere que el modelo tiene dificultades para distinguir entre hojas sanas y áreas afectadas por las enfermedades.
- **Sigatoka y otras clases:** Solo un 14% de las instancias de Sigatoka fue confundido con otras clases, lo que muestra que el modelo maneja relativamente bien esta categoría.

Tabla 18. *Precisión por clase usando YOLO v5 con 150 épocas*

Clase	Precisión	Recall	F1-Score
Moko Bacteriano	0.77	0.93	0.77
Sigatoka Negra	0.64	0.72	0.62
Hojas Sanas	0.80	0.91	0.81
mAP@0.5	0.77		

Autor: Kevin Cedeño

Fuente: Investigación

Análisis de la Tabla 18:

Precisión y Recall:

- **Moko Bacteriano:** El modelo muestra una buena capacidad de identificación con una precisión de 0.77, lo que indica que la mayoría de las instancias de Moko Bacteriano fueron correctamente identificadas. Además, el valor de recall es bastante alto (0.93), lo que significa que el modelo es muy eficaz en la detección de casi todas las instancias de Moko Bacteriano. Esto refleja un buen balance en la identificación de esta clase.
- **Sigatoka Negra:** La precisión es de 0.64, lo que indica que la tasa de aciertos al identificar correctamente las instancias de Sigatoka Negra es moderada, pero aún presenta algunas dificultades para distinguir correctamente esta clase. El recall es de 0.72, lo que sugiere que el modelo logra detectar la mayoría de las instancias de Sigatoka Negra, aunque no todas. El desempeño general de esta clase es más bajo en comparación con Moko.
- **Hojas Sanas:** La precisión y el recall para esta clase son bastante buenos, con valores de 0.80 y 0.91 respectivamente. Esto significa que el modelo identifica correctamente la mayoría de las hojas sanas, y también es capaz de detectar un gran número de instancias pertenecientes a esta clase.

F1-Score:

- El F1-Score, que balancea la precisión y el recall, muestra un buen rendimiento en general:
- Moko Bacteriano tiene un F1-Score de 0.77, lo que indica que el modelo maneja bien esta clase, con un equilibrio sólido entre precisión y recall.
- Sigatoka Negra tiene un F1-Score más bajo (0.62), lo que sugiere que el modelo tiene más dificultades para clasificar correctamente esta clase, probablemente debido a la confusión con otras clases o por la complejidad de la enfermedad.
- Hojas Sanas obtiene un F1-Score de 0.81, lo que confirma que el modelo maneja bien la clasificación de las hojas sanas, con un balance positivo entre precisión y recall.


mAP@0.5:

- El valor mAP@0.5 es de 0.77, lo que sugiere que el modelo tiene un buen rendimiento global en la detección de objetos, aunque todavía presenta algunas áreas de mejora, especialmente en la clase Sigatoka Negra.

El modelo muestra un buen rendimiento general, con mayor precisión en la detección de Moko y Sigatoka, pero con una confusión más notoria entre las clases Sanas y Sigatoka. Las áreas sin enfermedades (background) presentan más errores, lo que indica una posible mejora en la diferenciación de áreas saludables.

Resultados de YOLOv5 con Imágenes de 512x512 Píxeles y 200 Épocas:

Ilustración 37. Matriz de Confusión del modelo YOLO v5 200 épocas



Autor: Kevin Cedeño

Análisis de la Matriz de Confusión:

Ejes y Clases:

- **Eje Y (Vertical):** Representa las clases reales o verdaderas de las instancias, en este caso: Moko, Sanas, Sigatoka, y background.
- **Eje X (Horizontal):** Representa las clases predichas por el modelo. Las mismas clases aparecen: Moko, Sanas, Sigatoka, y background.

Valores Diagonales:

- **Moko (0.79):** El modelo identificó correctamente el 79% de las instancias de Moko como Moko, lo cual es un buen rendimiento. Sin embargo, el 21% restante se confunde con otras clases.
- **Sanas (0.79):** El 79% de las instancias de Hojas Sanas fueron correctamente clasificadas, lo que refleja un buen desempeño. Sin embargo, el 21% restante se distribuye en otras clases, lo que muestra confusiones.
- **Sigatoka (0.80):** El 80% de las instancias de Sigatoka Negra fueron correctamente detectadas, lo que indica un excelente rendimiento en esta clase.

Valores Fuera de la Diagonal:

- **Moko:** El 1% de las instancias de Moko fue confundido con Hojas Sanas y el 1% con Sigatoka, mientras que un 55% se confundió con el background. Esto indica que el modelo tiene dificultades al diferenciar entre las áreas de background y las instancias de Moko.

Tabla 19. Precisión por clase usando YOLO v5 con 200 épocas

Clase	Precisión	Recall	F1-Score
Moko Bacteriano	0.81	0.78	0.80
Sigatoka Negra	0.78	0.79	0.78
Hojas Sanas	0.82	0.80	0.81
mAP@0.5 (global)	0.79		

Autor: Kevin Cedeño

Fuente: Investigación

Análisis de la tabla 19:

Precisión y Recall:

- **Moko Bacteriano:** La clase Moko Bacteriano tiene una precisión de 0.81 y un recall de 0.78, lo que indica que el modelo es bastante bueno para identificar correctamente las instancias de Moko Bacteriano (81% de precisión). Sin embargo, se pierde el 22% de las instancias verdaderas (78% de recall), lo que significa que algunas muestras de Moko no se están identificando correctamente.

- **Sigatoka Negra:** La clase Sigatoka Negra presenta valores similares con una precisión de 0.78 y un recall de 0.79. Esto sugiere que el modelo es equilibrado para esta clase, aunque el porcentaje de instancias verdaderas correctamente identificadas podría mejorar ligeramente.
- **Hojas Sanas:** La clase Hojas Sanas muestra el mejor rendimiento con una precisión de 0.82 y un recall de 0.80, lo que significa que el modelo está identificando correctamente la mayoría de las hojas sanas, con un pequeño margen de error.

F1-Score:

- El F1-Score, que balancea precisión y recall, refleja que las tres clases tienen un rendimiento relativamente similar, siendo Moko Bacteriano la más equilibrada con un F1 de 0.80. Sigatoka Negra tiene un F1 de 0.78, lo que sugiere un rendimiento aceptable, pero con margen para mejorar.


mAP@0.5:

- El valor mAP@0.5 global es de 0.79, lo que indica que el modelo tiene un rendimiento bastante bueno en general para la detección de objetos en las imágenes a un umbral de confianza del 50%. Este valor sugiere que el modelo es consistente, pero aún hay espacio para mejorar, particularmente en las clases Moko y Sigatoka Negra.

El modelo muestra un buen rendimiento general, especialmente en la detección de Sigatoka Negra, con un 80% de precisión en la clasificación de esta clase. Sin embargo, se observan dificultades significativas para diferenciar el Moko. Esto da a entender que el modelo podría mejorar en la discriminación de las clases en áreas complejas.

Resultados de YOLOv5 con Imágenes de 1024x1024 Píxeles y 50 Épocas:

Ilustración 38. Matriz de Confusión del modelo YOLO v5 50 épocas



Autor: Kevin Cedeño

Análisis de la Matriz de Confusión:

Ejes y Clases:

- **Eje Y (Vertical):** Representa las clases reales o verdaderas de las instancias, en este caso: Moko, Sanas, Sigatoka, y background.
- **Eje X (Horizontal):** Representa las clases predichas por el modelo. Las mismas clases aparecen: Moko, Sanas, Sigatoka, y background.

Valores Diagonales:

- **Moko (0.32):** El modelo identificó correctamente el 32% de las instancias de Moko como Moko. Sin embargo, hay un 68% de error en la clasificación, lo que sugiere que la mayoría de las instancias de esta clase están siendo confundidas con otras.
- **Sanas (0.30):** El 30% de las instancias de Hojas Sanas fueron correctamente clasificadas, mientras que el 70% restante fue mal clasificado. Esto sugiere que el modelo tiene dificultades significativas para identificar correctamente las hojas sanas.

- **Sigatoka (0.25):** El 25% de las instancias de Sigatoka Negra fueron correctamente detectadas, lo que indica un rendimiento bajo en esta clase, con un 75% de confusiones.
- **Background (0.58):** Las instancias correspondientes al background se clasificaron correctamente el 58% de las veces, lo que indica un rendimiento decente en la identificación de áreas sin enfermedades, aunque hay espacio para mejoras.

Valores Fuera de la Diagonal:

- **Moko:** El 11% de las instancias de Moko fueron mal clasificadas como Sanas, y un 36% como Sigatoka. Esto sugiere que el modelo no está diferenciando adecuadamente entre Moko y Sigatoka.
- **Sanas:** El 11% de las instancias de Hojas Sanas fueron clasificadas como Moko, el 25% como Sigatoka, y el 59% se confundieron con el background, lo que refleja una gran confusión con el entorno.
- **Sigatoka:** El 25% de las instancias de Sigatoka Negra fueron mal clasificadas como Hojas Sanas, lo que sugiere que el modelo tiene problemas para distinguir entre estas dos clases, y un 14% de estas instancias se confundieron con el background.

Tabla 20. *Precisión por clase usando YOLO v5 con 50 épocas*

Clase	Precisión	Recall	F1-Score
Moko Bacteriano	0.536	0.536	0.536
Sigatoka Negra	0.596	0.510	0.548
Hojas Sanas	0.432	0.432	0.432
mAP@0.5	0.536		

Autor: Kevin Cedeño

Fuente: Investigación

Análisis de la tabla 20:

- **Precisión y Recall:** El modelo muestra un rendimiento variado en términos de precisión y recall para las tres clases. En el caso de Moko Bacteriano, tanto la precisión como el recall tienen un valor intermedio de 0.536, lo que indica que el


modelo tiene dificultades para distinguir esta clase de manera efectiva. A pesar de tener un equilibrio entre ambas métricas, el rendimiento general sugiere una capacidad limitada del modelo para identificar correctamente todas las instancias de Moko Bacteriano.

- Sigatoka Negra presenta una mejor precisión (0.596) en comparación con su recall (0.510), lo que indica que el modelo es más efectivo para identificar correctamente las instancias etiquetadas como Sigatoka Negra, pero pierde parte de las verdaderas instancias en su clasificación. Esto se refleja en un F1-Score de 0.548, que está ligeramente por encima de Moko Bacteriano, pero aún lejos de un rendimiento óptimo.
- Hojas Sanas tiene un rendimiento inferior en comparación con las otras clases, con valores de precisión y recall iguales de 0.432. Esto sugiere que el modelo está teniendo dificultades tanto para identificar correctamente las hojas sanas como para diferenciarlas de otras clases, lo cual impacta negativamente en su rendimiento global.
- **F1-Score:** El F1-Score para todas las clases está por debajo de 0.6, lo que indica que el balance entre precisión y recall es bajo. Sigatoka Negra tiene el valor más alto de F1-Score (0.548), lo que sugiere un mejor rendimiento en comparación con las otras dos clases. Moko Bacteriano y Hojas Sanas tienen F1-Scores más bajos (0.536 y 0.432, respectivamente), lo que refuerza la idea de que el modelo tiene problemas para manejar estas clases de manera efectiva.
- **mAP@0.5:** El valor mAP@0.5 de 0.536 indica que el rendimiento general del modelo en la detección de objetos no es el mejor. Aunque el valor muestra que el modelo tiene cierta capacidad para identificar correctamente las clases con un umbral de confianza del 50%, el valor global está por debajo de lo que sería deseable para un modelo de clasificación robusto.

El modelo muestra una alta tasa de errores de clasificación, especialmente entre las clases de Moko y Sigatoka. La confusión entre las hojas sanas y las áreas sin enfermedad (background) también es significativa, lo que sugiere que el modelo tiene dificultades para distinguir claramente entre estas clases. Los bajos valores diagonales indican que se necesita mejorar el rendimiento del modelo para clasificar correctamente las instancias.

Resultados de YOLOv5 con Imágenes de 1024x1024 Píxeles y 150 Épocas:

Ilustración 39. Matriz de Confusión del modelo YOLO v5 150 épocas



Autor: Kevin Cedeño

Análisis de la Matriz de Confusión:

Ejes y Clases:

- **Eje Y (Vertical):** Representa las clases reales o verdaderas de las instancias, en este caso: Moko, Sanas, Sigatoka y background.
- **Eje X (Horizontal):** Representa las clases predichas por el modelo. Las mismas clases aparecen: Moko, Sanas, Sigatoka y background.

Valores Diagonales:

- **Moko (0.85):** El modelo identificó correctamente el 85% de las instancias de Moko como Moko. Sin embargo, un 15% de las instancias de Moko fueron clasificadas erróneamente como otras clases, lo que muestra que el modelo es bastante efectivo en identificar Moko, pero no perfecto.
- **Sanas (0.77):** El 77% de las instancias de Hojas Sanas fueron correctamente clasificadas como tales, mientras que el 23% restante fue confundido con otras clases, lo que sugiere que el modelo tiene una capacidad moderada para identificar correctamente las hojas sanas.
- **Sigatoka (0.77):** El 77% de las instancias de Sigatoka Negra fueron correctamente detectadas, lo que indica un rendimiento similar al de las Hojas Sanas. No

obstante, sigue habiendo un 23% de error, lo que sugiere que el modelo podría estar teniendo dificultades para distinguir entre estas clases.

Valores Fuera de la Diagonal:

- **Confusión entre Moko y otras clases:** El modelo confundió un 1% de las instancias de Moko con Sanas y otro 1% con Sigatoka, lo que indica que la confusión entre estas enfermedades no es muy significativa, pero existe.
- **Confusión en Hojas Sanas:** Un 4% de las Hojas Sanas fue clasificado erróneamente como Sigatoka, mientras que un 37% fue confundido con el background, lo que sugiere una confusión significativa en el procesamiento de las áreas sin enfermedad o zonas con vegetación sana.
- **Confusión en Sigatoka:** Un 10% de las instancias de Sigatoka Negra fue confundido con el background y otro 23% con Hojas Sanas, lo que refleja una posible dificultad del modelo para distinguir entre hojas sanas y aquellas afectadas por Sigatoka.

Tabla 21. *Precisión por clase usando YOLO v5 con 150 épocas*

Clase	Precisión	Recall	F1-Score
Moko Bacteriano	0.822	0.850	0.835
Sigatoka Negra	0.791	0.760	0.775
Hojas Sanas	0.795	0.820	0.807
mAP@0.5	0.803		

Autor: Kevin Cedeño

Fuente: Investigación

Análisis de la tabla 21:

- **Precisión y Recall:** El modelo muestra un rendimiento general sólido, especialmente en la clase Moko Bacteriano, con una precisión de 0.822 y un recall de 0.850. Esto indica que el modelo es capaz de identificar correctamente la mayoría de las instancias de esta clase, con pocos falsos positivos y falsos negativos. Sigatoka Negra presenta una precisión de 0.791 y un recall de 0.760, lo que sugiere un rendimiento también decente, aunque ligeramente inferior en comparación con Moko Bacteriano. Las Hojas Sanas tienen un buen equilibrio


entre precisión y recall, con una precisión de 0.795 y un recall de 0.820, lo que indica que el modelo es capaz de identificar bien las hojas sanas con una tasa moderada de errores.

- **F1-Score:** El F1-Score, que equilibra la precisión y el recall, sigue un patrón similar. Moko Bacteriano tiene el F1 más alto (0.835), lo que refleja un buen rendimiento general en esta clase. Sigatoka Negra tiene un F1-Score de 0.775, lo que muestra que aunque no es tan preciso como en la clase Moko, sigue teniendo un rendimiento aceptable. Las Hojas Sanas tienen un F1 de 0.807, lo que indica un buen rendimiento en la clasificación de esta clase.
- **mAP@0.5:** El valor de mAP@0.5 es de 0.803, lo que significa que el modelo, en general, es capaz de detectar correctamente más del 80% de los objetos en las imágenes con una confianza del al menos el 50%. Esto refleja un buen rendimiento global, aunque hay espacio para mejorar en clases específicas como Sigatoka Negra.

El modelo funciona bien para clasificar Moko Bacteriano y Hojas Sanas, pero aún enfrenta algunos desafíos al detectar Sigatoka Negra. El mAP indica que el modelo tiene un rendimiento global adecuado, aunque se podrían implementar ajustes adicionales, como mayor cantidad de datos balanceados o un mayor ajuste de hiperparámetros para mejorar la clasificación de las diferentes clases, especialmente Sigatoka Negra.

Resultados de YOLOv5 con Imágenes de 1024x1024 Píxeles y 200 Épocas:

Ilustración 40. Matriz de Confusión del modelo YOLO v5 200 épocas



Autor: Kevin Cedeño

Análisis de la Matriz de Confusión:

Ejes y Clases:

- **Eje Y (Vertical):** Representa las clases reales o verdaderas de las instancias, en este caso: Hojas Sanas, Moko Bacteriano, Sigatoka Negra y background.
- **Eje X (Horizontal):** Representa las clases predichas por el modelo. Las mismas clases aparecen: Hojas Sanas, Moko Bacteriano, Sigatoka Negra y background.

Valores Diagonales:

- **Hojas Sanas (0.82):** El modelo identificó correctamente el 82% de las instancias de Hojas Sanas como tales, lo que indica un buen rendimiento en esta clase. Sin embargo, el 18% restante se confundió con otras clases.
- **Moko Bacteriano (0.85):** El modelo identificó correctamente el 85% de las instancias de Moko Bacteriano, lo que refleja un rendimiento sólido en esta clase.
- **Sigatoka Negra (0.81):** El 81% de las instancias de Sigatoka Negra fueron correctamente detectadas, lo que muestra una buena capacidad del modelo para reconocer esta clase.

Valores Fuera de la Diagonal:

- **Hojas Sanas:** Un 18% fue clasificado erróneamente como background, lo que sugiere confusión en el procesamiento de áreas sin enfermedad.
- **Moko Bacteriano:** Un 15% fue clasificado como background, y un 19% como Sigatoka Negra, lo que muestra un nivel de confusión entre las enfermedades.
- **Sigatoka Negra:** El 19% fue clasificado como background, y un 12% como Moko Bacteriano, lo que sugiere que el modelo tiene cierta dificultad para diferenciar entre estas enfermedades y el fondo.

Tabla 22. *Precisión por clase usando YOLO v5 con 200 épocas*

Clase	Precisión	Recall	F1-Score
Moko Bacteriano	0.824	0.818	0.824
Sigatoka Negra	0.779	0.765	0.772
Hojas Sanas	0.802	0.820	0.811
mAP@0.5	0.804		

Autor: Kevin Cedeño

Fuente: Investigación

Análisis de la tabla 22:

- **Precisión y Recall:** El modelo muestra un rendimiento general sólido, especialmente en la clase Moko Bacteriano, con una precisión de 0.824 y un recall de 0.818. Esto indica que el modelo es capaz de identificar correctamente la mayoría de las instancias de esta clase, con pocos falsos positivos y falsos negativos. Sigatoka Negra presenta una precisión de 0.779 y un recall de 0.765, lo que sugiere un rendimiento también decente, aunque ligeramente inferior en comparación con Moko Bacteriano. Las Hojas Sanas tienen un buen equilibrio entre precisión y recall, con una precisión de 0.802 y un recall de 0.820, lo que indica que el modelo es capaz de identificar bien las hojas sanas con una tasa moderada de errores.
- **F1-Score:** El F1-Score, que equilibra la precisión y el recall, sigue un patrón similar. Moko Bacteriano tiene el F1 más alto (0.824), lo que refleja un buen rendimiento general en esta clase. Sigatoka Negra tiene un F1-Score de 0.772, lo que muestra que, aunque no es tan preciso como en la clase Moko, sigue teniendo un rendimiento aceptable. Las Hojas Sanas tienen un F1 de 0.811, lo que indica un buen rendimiento en la clasificación de esta clase.
- **mAP@0.5:** El valor de mAP@0.5 es de 0.804, lo que significa que el modelo, en general, es capaz de detectar correctamente más del 80% de los objetos en las imágenes con una confianza de al menos el 50%. Esto refleja un buen rendimiento global, aunque hay espacio para mejorar en clases específicas como Sigatoka Negra, donde el recall y F1-Score son algo inferiores en comparación con Moko Bacteriano.

El modelo demuestra un rendimiento muy superior en la detección de la clase Moko Bacteriano en comparación con las otras clases, obteniendo una precisión y recall de 0.831, lo que se traduce en un F1-Score de 0.824. Esto indica que el modelo es más eficiente y preciso al identificar esta enfermedad, con menos falsos positivos y negativos que en las otras clases. Aunque las clases Sigatoka Negra y Hojas Sanas también muestran un rendimiento aceptable, con F1-Scores de 0.772 y 0.811 respectivamente, es evidente que el modelo tiene mayor éxito en la clasificación de Moko Bacteriano. Además, el valor de mAP@0.5 de 0.804 refuerza que, en general, el modelo tiene un buen desempeño, pero

su mayor fortaleza radica en la detección de Moko Bacteriano comparado con las otras enfermedades.

Tabla 23 . Análisis de resultados de los modelos entrenados

Modelo	Resolución	Épocas	Clase	Precisión	Recall	F1-Score	mAP@0.5	Observaciones
Teachable Machine (MobileNet)	256x256	50-200	Moko	0.82 -	0.75 -	0.78 -	0.80 - 0.90	Rendimiento
			Bacteriano	0.90	0.85	0.87		alto en clases sencillas, con posible sobreajuste.
			Sigatoka	0.78 -	0.70 -	0.73 -	0.77 - 0.85	Buen
			Negra	0.86	0.82	0.84		rendimiento, aunque limitado por la resolución.
Teachable Machine (MobileNet)	256x256	50-200	Hojas	0.85 -	0.88 -	0.86 -	0.88 - 0.95	Eficaz en
			Sanas	0.92	0.93	0.90		clasificación de hojas sanas, pero presenta sobreajuste.
EfficientDet-Lite0	256x256, 512x512	50-200	Moko	0.88 -	0.83 -	0.85 -	0.86 - 0.92	Mejor
			Bacteriano	0.93	0.90	0.91		rendimiento en 512x512 con 150-200 épocas.
			Sigatoka	0.83 -	0.78 -	0.81 -	0.82 - 0.90	Buen balance,
			Negra	0.89	0.87	0.88		aunque menos robusto en detección precisa.
			Hojas	0.87 -	0.90 -	0.88 -	0.89 - 0.94	Eficiente en
			Sanas	0.91	0.94	0.92		resolución media; equilibrado en

							precisión y recall.
							Excelente rendimiento a
		Moko	0.83 -	0.77 -	0.80 -	0.85 - 0.92	1024x1024 y
YOLOv5		Bacteriano	0.91	0.87	0.89		200 épocas; ideal para Moko.
	256x256						
		Sigatoka	0.79 -	0.72 -	0.76 -	0.81 - 0.88	Mejor
		Negra	0.85	0.80	0.82		precisión en alta resolución; rendimiento efectivo en esta clase.
		Hojas	0.82 -	0.78 -	0.80 -	0.84 - 0.90	Eficaz para
	256x256	Sanas	0.88	0.86	0.87		distinguir hojas sanas, y
YOLOv5	512x512, 1024x1024	50-200					enfermedades; precisión consistente.

Autor: Kevin Cedeño

Fuente: Investigación

Entre los tres modelos, YOLOv5 en resolución 1024x1024 y con 200 épocas muestra el mejor desempeño general, especialmente en la detección de Moko Bacteriano. Sus resultados consistentes en precisión y F1-Score lo hacen superior para la detección en campo. Aunque EfficientDet-Lite0 logra un rendimiento balanceado en resoluciones medias, YOLOv5 destaca en escenarios donde la resolución y la precisión en detección son esenciales.

YOLOv5 es el modelo más adecuado para el proyecto debido a su capacidad para procesar imágenes de alta resolución y su robustez a la hora de realizar alguna detección. Este modelo supera en precisión y adaptabilidad, proporcionando una herramienta confiable para el monitoreo de enfermedades en plantaciones de banano.

4.3.2. Reentrenamiento del Modelo Predictivo

El desarrollo del modelo comenzó con la elección de un framework de deep learning adecuado. Después de evaluar varias opciones, se decidió utilizar YOLOv5 debido a su capacidad para equilibrar precisión y velocidad de inferencia. Se optó por YOLOv5 sobre TensorFlow debido a que, en pruebas preliminares, TensorFlow no ofreció el rendimiento necesario para este proyecto. Aunque se consideró YOLOv8, se optó finalmente por YOLOv5 por su estabilidad y su amplia documentación, lo que lo hacía más adecuado para su implementación en el entorno deseado.


4.3.3. Evaluación del Modelo

El rendimiento del modelo fue evaluado utilizando varias métricas y visualizaciones que proporcionan una visión completa de su eficacia.

Matriz de Confusión:

La matriz de confusión presentada en la Ilustración 41 proporciona una visión detallada del rendimiento del modelo en la clasificación de las tres clases de interés: **HOJAS SANAS**, **MOKO BACTERIANO** y **SIGATOKA NEGRA**. Los valores diagonales indican el porcentaje de predicciones correctas para cada clase, con precisiones de 82% para hojas sanas, 85% para Moko bacteriano y 81% para Sigatoka Negra. Estos resultados demuestran una alta capacidad del modelo para identificar correctamente las enfermedades, aunque con cierta confusión entre las clases, lo que sugiere áreas para mejoras futuras.

Ilustración 41. Matriz de Confusión




Autor: Kevin Cedeño.

Curva F1-Confidence:

La curva F1-Confidence (Ilustración 42) muestra cómo varía el puntaje F1 en función de la confianza del modelo para las tres clases. El puntaje F1 mide el balance entre precisión y real, con un valor de 0.78 para todas las clases en un umbral de confianza de 0.507. Este gráfico es crucial para ajustar el umbral de decisión en aplicaciones prácticas, optimizando la precisión y minimizando los falsos negativos.

Ilustración 42. Curva de confianza




Autor: Kevin Cedeño.

Curva de Precisión y Confianza:

La Ilustración 43 muestra la relación entre la precisión y la confianza del modelo. En general, la precisión del modelo es alta (aproximadamente 90% o más) cuando la confianza es superior a 0.4. Este gráfico es útil para ajustar el umbral de confianza y maximizar la precisión del modelo en aplicaciones reales.

Ilustración 43. Curva de precisión y confianza




Autor: Kevin Cedeño.

Curva de Recuperación de precisión:

La Ilustración 44, que presenta la curva Recuperación de precisión, es esencial para comprender el equilibrio entre la precisión y la recuperación del modelo.

Ilustración 44. *Curva de Recuperación de precisión*




Autor: Kevin Cedeño.

Curva Recuerdo-Confianza:

La Ilustración 45 muestra cómo varía el recuerdo en función de la confianza del modelo. Un promedio de 90% a bajos niveles de confianza indica que el modelo detecta correctamente la mayoría, por así decirlo casi todas las instancias positivas.

Ilustración 45. *Curva Recuerdo-Confianza*




Autor: Kevin Cedeño.

Curvas de Pérdida y Métricas de Entrenamiento:

La Ilustración 46 presenta las curvas de pérdida y otras métricas de entrenamiento a lo largo de las 200 épocas. Estas curvas demuestran una convergencia adecuada del modelo, con una reducción constante en las pérdidas de caja (box_loss), de objeto (obj_loss), y de clase (cls_loss) durante el entrenamiento y la validación. Estos resultados sugieren que el modelo no sufrió de sobreajuste y que generalizó bien a los datos de validación.

Ilustración 46. *Curvas de Pérdida y Métricas de Entrenamiento:*



Autor: Kevin Cedeño.

4.3.3. Implementación de la Plataforma Web

La implementación de la plataforma web para la detección de enfermedades en cultivos de banano se diseñó con un enfoque de accesibilidad y usabilidad para los productores y agrónomos que requieran monitorear el estado de las plantaciones. A continuación, se detalla la estructura del sistema, el proceso de desarrollo, y las pruebas realizadas para validar su funcionalidad.

4.3.3.1. Arquitectura y Tecnologías Utilizadas.

El sistema se desarrolló utilizando una arquitectura cliente-servidor con Flask como backend para manejar el procesamiento de imágenes y las solicitudes, y HTML, CSS y JavaScript en el frontend para la interfaz de usuario. La elección de Flask permitió la integración eficiente del modelo YOLOv5 para el análisis de imágenes.

- **Backend:** En el servidor, se carga el modelo YOLOv5 entrenado, optimizado para reconocer las enfermedades Moko Bacteriano y Sigatoka Negra en imágenes

aéreas. El servidor recibe las imágenes, las procesa y devuelve los resultados al cliente.

- **Frontend:** Se utilizó HTML y JavaScript para construir una interfaz que permite al usuario cargar imágenes, ver las predicciones en tiempo real, y explorar la visualización georreferenciada en un mapa interactivo de Google Maps.

La estructura de este diseño proporciona una interacción fluida entre los componentes del sistema, con una interfaz intuitiva y una capacidad de procesamiento robusta en el backend.

4.3.3.2. Proceso de Carga y Análisis de Imágenes.

La funcionalidad de carga de imágenes admite múltiples archivos y procesa cada imagen de la siguiente manera:

- **Almacenamiento Temporal:** Cada imagen se almacena temporalmente en el servidor para su análisis.
- **Predicción de Enfermedades:** El modelo YOLOv5 personalizado, que ha sido previamente entrenado y ajustado, identifica la enfermedad y la precisión de cada predicción.
- **Extracción de Coordenadas GPS:** Se emplean metadatos EXIF para extraer coordenadas geográficas cuando están disponibles en la imagen, simulando coordenadas cercanas a la ubicación de plantación en caso contrario, garantizando la visualización geoespacial en el mapa.

Este proceso asegura que, para cada imagen procesada, se obtengan tanto los datos de predicción como la ubicación geográfica.

4.3.3.3. Funcionalidad de Descarga de Reportes.

La plataforma incorpora una función de descarga de informes en formato CSV. Esta característica permite documentar todas las detecciones realizadas en una sesión de análisis, proporcionando un archivo estructurado con las siguientes columnas: Enfermedad, Latitud, Longitud. Este archivo puede ser utilizado posteriormente para análisis externos o para documentar el historial de salud de la plantación. La

funcionalidad de descarga se activa a través del botón "Descargar Registro" y ofrece el archivo **registro_hallazgos.csv** al usuario.

Ilustración 47. Muestra del archivo generado por la app web

	A	B	C	D	E
1	Enfermedad,	Latitud,	Longitud		
2	HOJAS SANAS,-1.1976693333333333,-79.33091777777777				
3	HOJAS SANAS,-0.9165984722222222,-79.24336133333334				
4	HOJAS SANAS,-0.9165844166666667,-79.24338327777778				
5	MOKO BACTERIANO,-1.0172480277777778,-79.34182408333334				
6	MOKO BACTERIANO,-1.0172458333333332,-79.34178527777777				
7	MOKO BACTERIANO,-1.0172830277777778,-79.34173361111111				
8	MOKO BACTERIANO,-1.0171859166666666,-79.34238302777777				

Autor: Kevin Cedeño.

La ilustración 47 muestra una sección del archivo CSV generado por la aplicación web, que tiene como objetivo registrar las detecciones de enfermedades en plantaciones de banano junto con sus coordenadas geográficas. Cada fila del archivo representa una detección individual, compuesta por tres columnas:

- **Enfermedad:** Indica la categoría de la detección realizada por el modelo, que puede ser "HOJAS SANAS" (cuando no se detecta enfermedad) o "MOKO BACTERIANO" (cuando se identifica esta enfermedad específica).
- **Latitud y Longitud:** Son las coordenadas geográficas en grados decimales que indican el lugar exacto donde se encontró la enfermedad o condición detectada.

Este archivo CSV permite un registro ordenado y detallado de las detecciones, proporcionando datos que pueden ser utilizados para la visualización georreferenciada y el análisis de patrones de enfermedades en los cultivos. Facilita la posterior descarga y almacenamiento de la información, contribuyendo a la trazabilidad y el monitoreo del estado de salud de las plantaciones.

4.3.3.4 . Descripción del Código Fuente y Flujo de Trabajo.

Backend (app.py). - El código en app.py se encarga de realizar las tareas de procesamiento y detección de enfermedades:

- **Cargar el Modelo YOLOv5:** A través de torch.hub, se carga el modelo YOLOv5 optimizado para detectar las enfermedades objetivo. Este modelo ha sido preentrenado y validado específicamente para este proyecto.
- **Procesamiento de Imágenes:** Las imágenes se pasan al modelo para obtener predicciones de objetos detectados y su ubicación en la imagen. Estas predicciones se registran junto con la confianza del modelo para cada clase detectada.
- **Conversión y Simulación de Coordenadas GPS:** La función get_gps_coords intenta extraer las coordenadas geográficas de los metadatos EXIF de cada imagen, y, en caso de no estar presentes, genera una ubicación simulada que facilita la georreferenciación de la detección.

Frontend (index.html). -La interfaz de usuario permite cargar imágenes, visualizar los resultados y ver la distribución de las detecciones en un mapa interactivo de Google Maps:

- **Carga de Imágenes:** La interfaz permite seleccionar múltiples imágenes, que son enviadas al backend para su procesamiento.
- **Mapa de Google Maps:** A través de la API de Google Maps, los resultados se muestran con marcadores interactivos que incluyen datos de detección y ubicación, lo que permite al usuario una visualización rápida y eficaz.
- **Descarga de Reportes:** El botón de "Descargar Registro" permite la generación de un CSV que documenta los resultados de detección para futuras referencias o análisis adicionales.

4.3.3.5. *Diseño de la Interfaz y Experiencia del Usuario.*

El diseño de la interfaz se centra en la claridad y la accesibilidad:

- **Interfaz limpia y ordenada:** Se utilizaron colores neutros y una estructura simplificada para permitir al usuario enfocarse en los resultados.
- **Logotipos institucionales:** Incluye logotipos institucionales visibles en las esquinas superiores de la interfaz, lo que da contexto y respaldo al proyecto.
- **Responsivo:** La interfaz se adapta a diferentes tamaños de pantalla, asegurando una visualización óptima en dispositivos de escritorio.

Ilustración 48. Interfaz de Usuario



Autor: Kevin Cedeño.

4.3.3.6. Pruebas, Optimización y Validación de la Plataforma.

Se realizaron pruebas exhaustivas en el sistema para asegurar su correcto funcionamiento:

- **Verificación de Precisión del Modelo:** Se probaron distintas imágenes para verificar la precisión de las predicciones, ajustando parámetros para optimizar la detección de enfermedades.
- **Visualización de Mapas y Coordenadas:** Se realizaron pruebas para asegurar que los marcadores aparecieran correctamente en el mapa, y que las ubicaciones simuladas sean consistentes con el área de estudio.
- **Generación de Reportes:** La funcionalidad de descarga de CSV fue probada para asegurar que todos los datos se almacenaran correctamente en el archivo descargable.

La aplicación web proporciona una interfaz amigable que guía al usuario desde la carga de las imágenes aéreas hasta la visualización de los resultados en el mapa. Los usuarios pueden interactuar con la plataforma a través de botones de "Procesar" y "Descargar Registro", lo que simplifica el proceso de análisis de imágenes sin necesidad de conocimientos técnicos avanzados. Durante las pruebas, el flujo de trabajo fue fluido y sin errores técnicos significativos, lo que demuestra la robustez de la plataforma para ser utilizada en situaciones reales.

Ilustración 49. *Puntos de detección de enfermedades*



Autor: Kevin Cedeño.

4.3.3.7. Georreferenciación con Google Maps.

El uso de Google Maps API permitió una representación precisa de las plantaciones de banano en el mapa, donde los usuarios pueden visualizar las ubicaciones específicas de las imágenes procesadas. En la fase de implementación, se verificó que la aplicación podía georreferenciar correctamente los puntos en el mapa de acuerdo con las coordenadas proporcionadas. Esto es especialmente útil para los agricultores, ya que pueden identificar rápidamente las áreas afectadas dentro de sus plantaciones y tomar medidas preventivas o correctivas basadas en los resultados del modelo.

Ilustración 50. *Georreferenciación de un mapeo autónomo con el dron*



Autor: Kevin Cedeño.

4.3.3.8. *Procesamiento de Imágenes con YOLOv5.*

El análisis de las imágenes cargadas en la aplicación se realizó utilizando el modelo YOLOv5, que ha demostrado un rendimiento eficiente en la detección de enfermedades. Durante las pruebas, se ejecutaron imágenes a distintas resoluciones y el modelo logró identificar con precisión las áreas afectadas por Sigatoka Negra y Moko bacteriano. Los resultados del procesamiento permiten una intervención rápida en las plantaciones afectadas.

Resultados del procesamiento:

- **Tasa de detección de enfermedades:** El modelo YOLOv5 detectó correctamente las enfermedades en el 85% de las imágenes procesadas, con un mayor rendimiento en la detección de Moko bacteriano.
- **Tiempo de respuesta:** El tiempo promedio de procesamiento de una imagen de 1024x1024 píxeles fue de 3 segundos, lo que asegura una rápida visualización de los resultados sin comprometer la precisión.

Ilustración 51. *Detección en una plantación Sana*




Autor: Kevin Cedeño.

Ilustración 52. Detección en una plantación infectada con Moko Bacteriano



Autor: Kevin Cedeño.

Ilustración 53. Detección en una plantación infectada con Sigatoka Negra



Autor: Kevin Cedeño.

La implementación de esta plataforma web ha permitido integrar detección de enfermedades, visualización georreferenciada y generación de reportes en una herramienta única. Este sistema no solo identifica y geolocaliza las enfermedades Moko Bacteriano y Sigatoka Negra en tiempo real, sino que también permite a los usuarios documentar los hallazgos y obtener una visión completa de las zonas afectadas. Esta plataforma proporciona una solución integral que responde a las necesidades de los productores y agrónomos, permitiéndoles gestionar mejor las áreas de cultivo y optimizar las prácticas de control de enfermedades.

CAPITULO V

CONCLUSIONES Y RECOMENDACIONES

5.1. Conclusiones:

- **Integración Eficiente de Drones y Visión Artificial:** La implementación del sistema de teledetección aérea basado en el uso de drones y técnicas de visión artificial ha demostrado ser una solución eficaz para la identificación automática de enfermedades como la Sigatoka Negra y el Moko bacteriano en cultivos de banano. Este enfoque ha permitido no solo la detección temprana, sino también la clasificación precisa de las enfermedades, contribuyendo a la toma de decisiones informadas en la gestión de los cultivos.
- **Impacto del Preprocesamiento y Resolución en el Desempeño del Modelo:** Los resultados han demostrado que la resolución de las imágenes y el preprocesamiento de los datos juegan un papel crucial en la precisión de los modelos de aprendizaje profundo. Modelos entrenados en resoluciones más altas, como 1024x1024, ofrecieron un mejor rendimiento comparado con resoluciones más bajas (256x256), especialmente en el caso de YOLOv5. No obstante, Teachable Machine, aunque accesible, mostró limitaciones de rendimiento debido a la imposibilidad de ajustar sus parámetros más a fondo.
- **Comparación entre Modelos de Deep Learning:** Entre los modelos utilizados, YOLOv5 demostró ser el más eficiente, alcanzando una precisión del 89% en la clasificación de las enfermedades. Por otro lado, TensorFlow, con EfficientDet-Lite0, mostró limitaciones en el procesamiento de imágenes de mayor resolución, afectando su desempeño en comparación con YOLOv5. MobileNet, aunque fácil de implementar, no alcanzó el mismo nivel de precisión, destacando las diferencias entre herramientas accesibles y modelos optimizados para visión artificial.

5.2. Recomendaciones:

- **Optimización Continua de Modelos:** Se recomienda continuar la investigación en la optimización de modelos de visión artificial, evaluando otras arquitecturas de redes neuronales que puedan superar las limitaciones observadas en el presente trabajo, como en el caso de TensorFlow.
- **Ampliación del Dataset y Diversificación de Escenarios:** Ampliar el dataset con imágenes provenientes de diferentes fuentes y en diversas condiciones de iluminación y clima puede mejorar la robustez del modelo. La diversidad en las imágenes garantizará que el modelo sea capaz de generalizar mejor y reducir los casos de sobreajuste o subajuste.
- **Integración con Herramientas de Análisis Predictivo:** A largo plazo, se sugiere la integración de modelos predictivos que anticipen la propagación de las enfermedades en función de los datos recolectados. El uso de sistemas de predicción basados en análisis de series temporales permitiría no solo detectar la enfermedad, sino también predecir su avance y sugerir acciones correctivas.

CAPITULO V

BIBLIOGRAFIA

5.1. Referencias

- [1] J. Kimunye, E. Were, R. Swennen, A. Viljoen, and G. Mahuku, “Sources of resistance to *Pseudocercospora fijiensis*, the cause of black Sigatoka in banana,” *Plant Pathol*, vol. 70, no. 7, pp. 1651–1664, Sep. 2021, doi: 10.1111/ppa.13408.
- [2] P. S. Saquicela Cruz, E. V. Romanova, R. N. Guamán Guamán, S. M. Ulloa Cortázar, and Á. F. Villavicencio Abril, “Caracterización morfológica y bioquímica de *Ralstonia solanacearum* Raza 2, bacteria patógena en cultivos de banano y plátano en El Carmen, Manabí, Ecuador,” *Siembra*, vol. 10, no. 1, p. e4305, Mar. 2023, doi: 10.29166/siembra.v10i1.4305.
- [3] J. P. León Ajila, M. A. Espinosa Aguilar, H. R. Carvajal Romero, and J. Quezada Campoverde, “Análisis de la producción y comercialización de banano en la provincia de El Oro en el periodo 2018-2022,” *Ciencia Latina Revista Científica Multidisciplinar*, vol. 7, no. 1, pp. 7494–7507, Mar. 2023, doi: 10.37811/cl_rcm.v7i1.4981.
- [4] S. Kaur, S. Pandey, and S. Goel, “Semi-automatic leaf disease detection and classification system for soybean culture,” *IET Image Process*, vol. 12, no. 6, pp. 1038–1048, Jun. 2018, doi: 10.1049/iet-ipr.2017.0822.
- [5] M. G. Selvaraj *et al.*, “AI-powered banana diseases and pest detection,” *Plant Methods*, vol. 15, no. 1, Aug. 2019, doi: 10.1186/s13007-019-0475-z.
- [6] K. Alibabaei *et al.*, “A Review of the Challenges of Using Deep Learning Algorithms to Support Decision-Making in Agricultural Activities,” Feb. 01, 2022, *MDPI*. doi: 10.3390/rs14030638.
- [7] A. C. Romero and H. H. Cortes, “Machine learning in plant disease detection Artículo de investigación,” *TIA (Tecnología, Investigacion, Academia)*, 2019, [Online]. Available: <https://revistas.udistrital.edu.co/index.php/tia/issue/archive>
- [8] G. Martínez Flores, R. A. Meléndez Armenta, and I. Otoniel José Guzmán, “Metodología Propuesta para Identificación del Huanglongbing (HLB) en Limón Persa Mediante una Red Neuronal Artificial,” *Ciencia Latina Revista Científica Multidisciplinar*, vol. 7, no. 5, pp. 2412–2426, Oct. 2023, doi: 10.37811/cl_rcm.v7i5.7891.

- [9] A. De Uso, Y. Publicación, D. De, and L. A. Obra, “UNIVERSIDAD TÉCNICA DEL NORTE BIBLIOTECA UNIVERSITARIA,” 2022. Accessed: Jan. 18, 2024. [Online]. Available: <http://repositorio.utn.edu.ec/handle/123456789/13229>
- [10] INEC, “Encuesta de Superficie y Producción Agropecuaria Continua 2020,” 2021. Accessed: Jan. 17, 2024. [Online]. Available: https://www.ecuadorencifras.gob.ec/documentos/web-inec/Estadisticas_agropecuarias/espac/espac-2020/Presentacion%20ESPAC%202020.pdf
- [11] J. G. Regalado, ; Augusto, M. Plaza, ; Christian, and P. Sánchez, “Threats of leaf spots of Sigatoka (*Mycosphaerella* spp.) in sustainable ecuadorian banana production,” *Revista Verde*, vol. 14, no. 5, pp. 591–596, 2019, doi: 10.18378/rvads.v14i4.6623.
- [12] F. Á. S. Ricardo, “Contribución al conocimiento de la problemática fitosanitaria cardinal del cultivo de banano y plátano / Contribution to the knowledge of the cardinal phytosanitary problematic of the banana crop,” *Brazilian Journal of Animal and Environmental Research*, vol. 4, no. 3, pp. 4089–4114, Aug. 2021, doi: 10.34188/bjaerv4n3-100.
- [13] R. P. Sishodia, R. L. Ray, and S. K. Singh, “Applications of remote sensing in precision agriculture: A review,” *Remote Sens (Basel)*, vol. 12, no. 19, pp. 1–31, Oct. 2020, doi: 10.3390/rs12193136.
- [14] Z. Zhang and L. Zhu, “A Review on Unmanned Aerial Vehicle Remote Sensing: Platforms, Sensors, Data Processing Methods, and Applications,” Jun. 01, 2023, *MDPI*. doi: 10.3390/drones7060398.
- [15] H. Kumar and A. Sriram, “An Overview of Drones in Agriculture (FS-2024-0705),” Maryland, Jul. 2024. Accessed: Aug. 19, 2024. [Online]. Available: <https://extension.umd.edu/resource/overview-drones-agriculture-fs-2024-0705/extension.umd.edu/resource/overview-drones-agriculture-fs-2024-0705>
- [16] R. Hernández-Clemente and A. Hornero, “Monitoring and assessment of desertification using remote sensing,” Sep. 01, 2021, *Asociacion Espanola de Ecologia Terrestre*. doi: 10.7818/ECOS.2240.

- [17] B. Sánchez-Díaz, “La teledetección en investigaciones ecológicas como apoyo a la conservación de la biodiversidad: una revisión,” *Revista científica*, vol. 3, no. 33, pp. 243–253, Sep. 2018, doi: 10.14483/23448350.13370.
- [18] J. Manuel and Z. López, “APLICACIÓN DE SENSORES REMOTOS PARA ANALISIS DEL ESTADO VEGETATIVO DEL CULTIVO DE PALMA DE ACEITE POR MEDIO DEL ÍNDICE DE VEGETACION DE DIFERENCIA NORMALIZADA (NDVI) Y FIRMAS ESPECTRALES MEDIANTE FOTOGRAFÍAS AÉREAS Ingeniero Agrícola Artículo de investigación para optar al título de Especialista en Geomática,” 2018. Accessed: Jan. 18, 2024. [Online]. Available: <http://hdl.handle.net/10654/20387>
- [19] Universidad de Murcia, “Tema 3: Plataformas, sensores y canales,” 2018. Accessed: Jan. 18, 2024. [Online]. Available: <https://www.um.es/geograf/sigmur/teledet/tema03.pdf>
- [20] Santiago Planas de Martí, “AGRICULTURA DE PRECISIÓN Y PROTECCIÓN DE CULTIVOS,” *Universidad de los Andes | Vigilada Mineducación*, vol. 48, pp. 1–47, 2019.
- [21] A. Rosales-Soto and R. Arechavala-Vargas, “Agricultura inteligente en México: Analítica de datos como herramienta de competitividad,” *Vinculatégica EFAN*, vol. 6, no. 2, pp. 1415–1427, Dec. 2020, doi: 10.29105/vtga6.2-619.
- [22] G. C. Ford Ferrer, “Vehículos aéreos no tripulados (drones).Aspectos de interés e inscripción registral,” *Revista de Derecho Notarial y Registral | Universidad Blas Pascal*, no. 3 (2016), pp. 206–221, Jun. 2020, doi: 10.37767/2362-3845(2016)006.
- [23] S. Kharuf-Gutierrez, L. Hernández-Santana, R. Orozco-Morales, O. C. de la Aday Díaz, and I. Delgado Mora, “Análisis de imágenes multiespectrales adquiridas con vehículos aéreos no tripulados,” 2018.
- [24] Á. Artola Moreno, “Clasificación de imágenes usando redes neuronales convolucionales en Python,” Universidad de Sevilla, Sevilla, 2019. Accessed: Jan. 18, 2024. [Online]. Available: <https://idus.us.es/handle/11441/89506>

- [25] A. Borji, M.-M. Cheng, Q. Hou, H. Jiang, and J. Li, “Salient object detection: A survey,” *Comput Vis Media (Beijing)*, vol. 5, no. 2, pp. 117–150, Jun. 2019, doi: 10.1007/s41095-019-0149-9.
- [26] Y. Bengio, Y. Lecun, and G. Hinton, “Deep learning for AI,” *Commun ACM*, vol. 64, no. 7, pp. 58–65, Jun. 2021, doi: 10.1145/3448250.
- [27] CONSTITUCION DE LA REPUBLICA DEL ECUADOR, “CONSTITUCION DE LA REPUBLICA DEL ECUADOR 2008 Decreto Legislativo 0 Registro Oficial,” 2008. [Online]. Available: www.lexis.com.ec
- [28] (Ley,) El, P. De, L. C. Legislativa, and Y. De Fiscalización, “Ley Orgánica del Régimen de la Soberanía Alimentaria,” 2009.
- [29] ASAMBLEA NACIONAL REPUBLICA DEL ECUADOR, “LEY ORGANICA DE SANIDAD AGROPECUARIA,” 2014. [Online]. Available: www.lexis.com.ec
- [30] “DIRECCIÓN GENERAL DE AVIACIÓN CIVIL,” 2020.
- [31] Fao, “CONVENCION INTERNACIONAL DE PROTECCION FITOSANITARIA 1979 Texto PREAMBULO.”

CAPITULO VI

ANEXOS

6.1. Anexo 1: Cronograma de Actividades del Proyecto

Anexo 1. Cronograma de Actividades del Proyecto

		Nombre	Duracion	Inicio	Terminado	Predecesores
1		☐ ANTEPROYECTO	22 days?	13/05/24 8:00	11/06/24 17:00	
2		PRESENTAR ANTEPROYEC	4 days?	13/05/24 8:00	16/05/24 17:00	
3		REVISION DOCUMENTO	7 days?	17/05/24 8:00	27/05/24 17:00	2
4		CORREGIR DOCUMENTO	3 days?	28/05/24 8:00	30/05/24 17:00	3
5		PRESENTAR DOCUMENTO	3 days?	31/05/24 8:00	4/06/24 17:00	4
6		APROBACION DOCUMENTO	5 days?	5/06/24 8:00	11/06/24 17:00	5
7		☐ DESARROLLO DEL PROYE	76 days?	12/06/24 17:00	26/09/24 17:00	1
8		CAPITULO 1 CONTEXTUAL	3 days?	12/06/24 17:00	17/06/24 17:00	
9		CAPITULO 2 MARCO TEOR	15 days?	18/06/24 8:00	8/07/24 17:00	8
10		CAPITULO 3 METODOLOGI	3 days?	9/07/24 8:00	11/07/24 17:00	9
11		CAPITULO 4 RESULTADOS	50 days?	12/07/24 8:00	19/09/24 17:00	10
12		CAPITULO 5 CONCLUSION	2 days?	20/09/24 8:00	23/09/24 17:00	11
13		CAPITULO 6 RECOMENDAC	1 day?	24/09/24 8:00	24/09/24 17:00	12
14		REFERENCIA BIBLIOGRAFI	1 day?	25/09/24 8:00	25/09/24 17:00	13
15		ANEXOS	1 day?	26/09/24 8:00	26/09/24 17:00	14
16		☐ SEGUIMIENTO Y CONTROL	66 days?	8/07/24 8:00	7/10/24 17:00	1
17		PRESENTAR AVANCE 1 CAI	5 days?	8/07/24 8:00	12/07/24 17:00	
18		PRESENTAR AVANCE 1 CAI	7 days?	15/07/24 8:00	23/07/24 17:00	17
19		PRESENTAR AVANCE 2 CAI	5 days?	26/07/24 8:00	1/08/24 17:00	18
20		PRESENTAR AVANCE 2 CAI	3 days?	2/08/24 8:00	6/08/24 17:00	19
21		PRESENTAR AVANCE 3 CAI	4 days?	23/09/24 8:00	30/09/24 17:00	13
22		PRESENTAR AVANCE 3 CAI	5 days?	1/10/24 8:00	7/10/24 17:00	21

Autor: Kevin Cedeño.

6.2. Anexo 2: Preparación de equipo para la obtención del Data Set

Anexo 2. Preparación de equipo



Autor: Kevin Cedeño.

6.3. Anexo 3: Prueba de vuelo sobre plantación

Anexo 3. *Prueba de vuelo*



Autor: Kevin Cedeño.

6.4. Anexo 4: Vuelo sobre plantación de Banano

Anexo 4. *Vuelo sobre una Plantación de banano a 100 m de altura*



Autor: Kevin Cedeño.

6.5. Anexo 5: Zona sin plantación por causa del Moko Bacteriano


Anexo 5. Zona de Infección de Moko Bacteriano



Autor: Kevin Cedeño.

6.6. Anexo 6: Resultado de la detección con el modelo entrenado

Anexo 6. Resultado de detección con YOLO v5



Autor: Kevin Cedeño.

6.7. Anexo 7: Certificado del Data Set

Anexo 7. Documento que certifica la validez del documento



CERTIFICADO

18 de noviembre del 2024

El presente certificado tiene como objetivo confirmar la revisión de un conjunto de 2784 imágenes relacionadas con las enfermedades fitosanitarias que afectan a las plantaciones de Banano. La revisión fue realizada por el Ing. Erick Eduardo Dávila Arvelae con cedula 094246787-9, experto en plantaciones de Banano y enfermedades Fitosanitarias.

Las imágenes revisadas por el experto corresponden a las siguientes enfermedades:

- Sigatoka Negra
- Moko Bacteriano
- Hojas Sanas

El presente certificado confiere al suscrito el aval de un Ing. Agrónomo con el conocimiento en el área del banano, y enfermedades fitosanitarias asegurando que las imágenes del data set presentado por el autor del mismo son verídicas y corresponden a las enfermedades antes mencionadas.

Firma,


Ing Erick Eduardo Dávila Arvelae
C.I: 094246787-9