



**UNIVERSIDAD LAICA “ELOY ALFARO” DE MANABÍ
EXTENSIÓN EN EL CARMEN
CARRERA DE INGENIERÍA EN SOFTWARE**

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

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

**SISTEMA DE VISIÓN COMPUTACIONAL BASADO EN CNN PARA EL
FENOTIPADO AUTOMÁTICO DE NEMATODOS FITOPARÁSITOS EN EL
CULTIVO DE LA GRANJA EXPERIMENTAL ULEAM EL CARMEN**

AUTOR

PILATAXI PITA DIEGO RICARDO

TUTOR

ING. LOPEZ RODRIGUEZ CARLOS VINICIO

EL CARMEN, 2026

CERTIFICACIÓN DEL TUTOR

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

CERTIFICACIÓN

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

Haber dirigido, revisado y aprobado preliminarmente el Trabajo de Integración Curricular bajo la autoría del estudiante **DIEGO RICARDO PILATAXI PITA**, legalmente matriculado/a en la carrera de Tecnologías de la Información período académico 2026-1, cumpliendo el total de 288 horas, cuyo tema del proyecto o núcleo problémico es **"SISTEMA DE VISIÓN COMPUTACIONAL BASADO EN CNN PARA EL FENOTIPADO AUTOMÁTICO DE NEMATODOS FITOPARÁSITOS EN EL CULTIVO DE LA GRANJA EXPERIMENTAL ULEAM EL CARMEN"**.

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

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

El Carmen, 31 de julio de 2026.

Lo certifico,


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

TRIBUNAL DE SUSTENTACIÓN

TRIBUNAL DE SUSTENTACIÓN



Universidad Laica Eloy Alfaro de Manabí
Extensión El Carmen
Carrera de Ingeniería en Software

TRIBUNAL DE SUSTENTACIÓN

Título del Trabajo de Titulación:

SISTEMA DE VISIÓN COMPUTACIONAL BASADO EN CNN PARA EL FENOTIPADO AUTOMÁTICO DE NEMATODOS FITOPARÁSITOS EN EL CULTIVO DE LA GRANJA EXPERIMENTAL ULEAM EL CARMEN.

Modalidad:

Proyecto Integrador

Autor:

Pilataxi Pita Diego Ricardo

Tutor:

Ing. López Rodríguez Carlos Vinicio

Tribunal de Sustentación:

- Presidente: Ing. Mora Marcillo Alex Bladimir
- Miembro: Ing. Arévalo Hermida Rómulo Danilo
- Miembro: Ing. Mendoza Villamar Rocío Alexandra



Fecha de Sustentación:

26 de agosto de 2026


DECLARACIÓN DE AUTORÍA

**UNIVERSIDAD LAICA “ELOY ALFARO” DE MANABÍ
EXTENSIÓN EN EL CARMEN**



DECLARACIÓN DE AUTORÍA

La responsabilidad del contenido de este Trabajo de titulación, cuyo tema SISTEMA DE VISIÓN COMPUTACIONAL BASADO EN CNN PARA EL FENOTIPADO AUTOMÁTICO DE NEMATODOS FITOPARÁSITOS EN EL CULTIVO DE LA GRANJA EXPERIMENTAL ULEAM EL CARMEN, corresponde exclusivamente a Pilataxi Pita Diego Ricardo con C.I.: 1313640359, y los derechos patrimoniales de la misma corresponden a la Universidad Laica “Eloy Alfaro” de Manabí.


Pilataxi Pita Diego Ricardo
C.I.: 1313640359

DEDICATORIA

El presente trabajo está dedicado a todas las personas que creyeron en mí y me brindaron su mano cuando más lo necesité.

A mi familia en especial a mis padres por ser mi mayor fortaleza a seguir en este camino de estudios.

A la Universidad Laica Eloy Alfaro de Manabí Extensión El Carmen y a mis docentes por brindarme los conocimientos, la exigencia y la guía necesaria para convertirme en un Ingeniero de Software.

Diego Ricardo Pilataxi Pita

AGRADECIMIENTO

Agradezco primeramente a Dios por darme la oportunidad de vivir cada día.

Agradezco a la Universidad Laica Eloy Alfaro de Manabí Extensión El Carmen, por haberme brindado una formación integral a lo largo de la carrera de Ingeniería de Software. A mis docentes, a mi tutor de tesis, Ing. Lopez Rodriguez Carlos Vinicio, por su dedicación y enseñanza, la cual fue fundamental para el desarrollo de este trabajo.

Finalmente, mi más profundo agradecimiento a mi familia, quienes han sido mi soporte incondicional. Gracias por creer en mi y darme la fuerza necesaria para culminar esta importante etapa de mi vida.

Diego Ricardo Pilataxi Pita

ÍNDICE GENERAL

PORTADA.....	I
CERTIFICACIÓN DEL TUTOR.....	II
TRIBUNAL DE SUSTENTACIÓN.....	III
DECLARACIÓN DE AUTORÍA.....	IV
DEDICATORIA	V
AGRADECIMIENTO	VI
ÍNDICE GENERAL	VII
ÍNDICE DE TABLAS	XV
ÍNDICE DE ILUSTRACIONES	XVII
ÍNDICE DE ANEXOS	XVIII
RESUMEN	XIX
ABSTRACT.....	XX
CAPÍTULO I	1
1 INTRODUCCIÓN.....	1
1.1 Introducción	1
1.2 Presentación del tema.....	2
1.3 Ubicación y contextualización de la problemática.....	3
1.4 Planteamiento del problema	4
1.4.1 Problematización.....	4

1.4.2	Génesis del problema	4
1.4.3	Estado actual del problema	5
1.5	Diagrama causa – efecto del problema	6
1.6	Objetivos	7
1.6.1	Objetivo general	7
1.6.2	Objetivos específicos.....	7
1.7	Justificación.....	7
1.8	Impactos esperados	8
1.8.1	Impacto tecnológico	8
1.8.2	Impacto social	8
1.8.3	Impacto ecológico	9
CAPÍTULO II		11
2	MARCO TEÓRICO	11
2.1	Antecedentes históricos.....	11
2.2	Antecedentes de investigaciones.....	13
2.3	Definiciones conceptuales.....	14
2.3.1	Fundamentos de la Visión Computacional.....	14
2.3.2	Introducción a las Redes Neuronales Convolucionales (CNN)	15
2.3.3	Capas Clave en CNNs	16
2.3.4	Arquitecturas Populares de CNNs.....	16
2.3.5	Entrenamiento y Optimización de CNNs.....	17

2.3.6	Técnicas Avanzadas en CNNs	18
2.3.7	Implementación y Herramientas para CNNs	18
2.3.8	Diseño de sistemas de visión computacional basados en CNN	19
2.3.9	Fundamentos de taxonomía y morfología de nematodos fitoparásitos	19
2.3.10	Fitopatología.....	20
2.3.11	Fenotipado de plantas y tecnologías de alto rendimiento	20
2.3.12	Métodos de laboratorio y técnicas de extracción automatizada	21
2.3.13	Fenotipado del Comportamiento y Rastreo (Tracking).....	21
2.3.14	Protocolos de Muestreo, Extracción y Preservación en Laboratorio	22
2.3.15	Taxonomía Clásica y Morfometría de Nematodos	22
2.3.16	Manejo integrado de plagas (MIP).....	22
2.4	Conclusiones del marco teórico	23
CAPÍTULO III.....		24
3	MARCO INVESTIGATIVO.....	24
3.1	Introducción	24
3.2	Tipos de investigación.....	24
3.3	Métodos de investigación.....	26
3.3.1	Método Analítico-Sintético	26
3.3.2	Método Hipotético-Deductivo.....	27
3.4	Fuentes de información de datos	28
3.4.1	Fuentes primarias	28

3.4.1.1	Entrevista.....	28
3.4.1.2	Encuesta	29
3.4.2	Fuentes secundarias.....	30
3.5	Estrategia operacional para la recolección de datos.....	30
3.5.1	Población.....	30
3.5.2	Muestra.....	31
3.5.3	Análisis de las herramientas de recolección de datos a utilizar	32
3.5.3.1	Encuesta	32
3.5.3.2	Entrevista.....	32
3.5.3.3	Estructura de los instrumentos de recolección de datos aplicados....	33
3.5.4	Plan de recolección de datos	33
3.6	Análisis y presentación de resultados.....	34
3.6.1	Presentación y descripción de los resultados obtenidos.....	34
3.6.1.1	Análisis de encuesta dirigida a estudiantes de Agropecuaria de la Uleam Extensión El Carmen.....	34
3.6.1.2	Análisis de entrevista dirigida al Ing. Paul González docente de la Carrera de Agropecuaria	37
3.6.2	Informe final del análisis de los datos	41
CAPÍTULO IV.....		44
4	MARCO PROPOSITIVO	44
4.1	Introducción	44
4.2	Descripción de la propuesta	44

4.3	Determinación de recursos	45
4.3.1	Humanos.....	45
4.3.2	Tecnológicos	46
4.3.3	Económicos	48
4.4	Desarrollo según metodología Scrum	48
4.4.1	Descripción del Producto	49
4.4.1.1	Propósito del Producto	49
4.4.1.2	Funcionalidades Clave	49
4.4.1.3	Usuarios Objetivo:.....	49
4.4.1.4	Condiciones de Éxito del Producto:	50
4.4.2	Historias de Usuario	51
	4.4.2.1 Historia de Usuario 1: Diagnóstico automático e identificación de plaga	51
	4.4.2.2 Historia de Usuario 2: Clasificación y certeza de plaga.....	51
	4.4.2.3 Historia de Usuario 3: Consumo de reportes algorítmicos para estudios de infestación	52
	4.4.2.4 Historia de Usuario 4: Ejecución del diagnóstico de forma local y offline	53
	4.4.2.5 Historia de Usuario 5: Robustez diagnóstica ante el ruido visual de la granja	54
4.4.3	Diseño del Sistema / Descripción Técnica	54
4.4.3.1	Caso de uso: Escaneo de Planta	54

4.4.3.2	Caso de uso: Clasificación de Plaga.....	56
4.4.3.3	Caso de uso: Visualización y Diagnóstico Fitosanitario	57
4.4.3.4	Diagramas de Secuencia.....	58
4.4.3.5	Diagramas de Estado	60
4.4.3.6	Diagrama de Base de Datos	62
4.4.4	Descripción Técnica / Arquitectura del Sistema	63
4.4.4.1	Arquitectura del Sistema	63
4.4.4.2	Requerimientos Funcionales:	66
4.4.4.3	Requerimientos No Funcionales:	66
4.4.5	Roles y Responsabilidades	66
4.4.6	Planificación del Sprint	67
4.4.6.1	Sprint 0: Preparación y Configuración.....	67
4.4.6.2	Sprint 1: Entrenamiento y Optimización del modelo de red neuronal	68
4.4.6.3	Sprint 2: Integración de Intérprete y Lógica de Inferencia	69
4.4.6.4	Sprint 3: Ajuste de Umbrales y Validación Algorítmica	70
4.4.7	Backlog del Producto	71
4.4.7.1	Backlog: Fin del Sprint 0	72
4.4.7.2	Backlog: Fin del Sprint 1	73
4.4.7.3	Backlog: Fin del Sprint 2	74
4.4.7.4	Backlog: Fin del Sprint 3	75
4.4.8	Funcionalidad de modelo de red neuronal	77

4.4.8.1	Estructura del módulo	77
4.4.8.2	Código fuente Inicialización del modelo de red neuronal.....	78
4.4.8.3	Código fuente Procesamiento del modelo de red neuronal.....	79
4.4.9	Definición de Hecho (DoD)	80
4.4.9.1	Criterios Generales:.....	80
4.4.9.2	Criterios Específicos del Proyecto:	80
4.4.10	Eventos Scrum.....	80
4.4.10.1	Sprint Review 0:.....	80
4.4.10.2	Sprint Review 1:.....	81
4.4.10.3	Sprint Review 2:.....	81
4.4.10.4	Sprint Review 3:.....	82
4.4.11	Sprints Review	82
4.4.11.1	Sprint Review 0:.....	82
4.4.11.2	Sprint Review 1:.....	83
4.4.11.3	Sprint Review 2:.....	83
4.4.11.4	Sprint Review 3:.....	83
4.4.12	Proceso de Pruebas.....	83
4.4.12.1	Pruebas de caja negra	83
4.4.12.2	Pruebas de caja blanca.....	84
4.4.13	Incremento y Entregables.....	85
4.4.13.1	Sprint 0: Preparación y Configuración.....	85

4.4.13.2	Sprint 1: Entrenamiento y Optimización del modelo de red neuronal	86
4.4.13.3	Sprint 2: Integración de Intérprete y Lógica de Inferencia	87
4.4.13.4	Sprint 3: Ajustes de Umbrales y Validación Algorítmica.....	87
CAPÍTULO V		88
5	EVALUACIÓN DE RESULTADOS.....	88
5.1	Introducción	88
5.2	Presentación y monitoreo de resultados	88
5.2.1	Planificación de la evaluación.....	88
5.2.2	Ejecución del monitoreo.....	90
5.2.2.1	Proceso de Detección e Inferencia Fitosanitaria	90
5.3	Interpretación objetiva.....	93
CAPÍTULO VI.....		95
6	CONCLUSIONES Y RECOMENDACIONES	95
6.1	Conclusiones	95
6.2	Recomendaciones.....	96
BIBLIOGRAFÍA		97
ANEXOS		102
GLOSARIO		110

ÍNDICE DE TABLAS

Tabla 1: Cronograma de recolección de datos	33
Tabla 2: Análisis de encuesta.....	34
Tabla 3: Análisis de entrevista	37
Tabla 4: Recursos Humanos	45
Tabla 5: Recursos Tecnológicos	46
Tabla 6: Recursos Económicos	48
Tabla 7: Tipos de usuario.....	49
Tabla 8: Historia de usuario 1	51
Tabla 10: Historia de usuario 2	51
Tabla 10: Historia de usuario 3	52
Tabla 11: Historia de usuario 4.....	53
Tabla 12: Historia de usuario 5	54
Tabla 13: Caso de uso: Escaneo de Planta.....	55
Tabla 14: Caso de uso: Clasificación de Plaga	56
Tabla 15: Caso de uso: Visualización y Diagnóstico Fitosanitario	57
Tabla 16: Roles y Responsabilidades	66
Tabla 17: Sprint 0.....	67
Tabla 18: Sprint 1.....	68
Tabla 19: Sprint 2.....	69
Tabla 20: Sprint 3.....	70
Tabla 21: Backlog inicial	71
Tabla 22: Backlog: Fin del Sprint 0	72
Tabla 23: Backlog: Fin del Sprint 1	73
Tabla 24: Backlog: Fin del Sprint 2	74

Tabla 25: Backlog: Fin del Sprint 3.....	75
Tabla 26: Pruebas de caja negra.....	83
Tabla 27: Pruebas de caja blanca.....	84
Tabla 28: Planificación de la evaluación	89
Tabla 29: Proceso de detección e inferencia Fitosanitaria.....	90
Tabla 30: Pruebas de medición de tiempo	91
Tabla 31: Proceso de Efectividad en Diagnóstico	92

ÍNDICE DE ILUSTRACIONES

Ilustración 1: Diagrama causa-efecto.....	6
Ilustración 2: Caso de uso: Escaneo de Planta.....	54
Ilustración 3: Caso de uso: Clasificación de Plaga	56
Ilustración 4: Caso de uso: Visualización y Diagnostico Fitosanitario	57
Ilustración 5: Diagrama de secuencia: Escaneo de Planta	58
Ilustración 6: Diagrama de secuencia: Clasificación de Plaga	59
Ilustración 7: Diagrama de secuencia: Visualización y Diagnóstico Fitosanitario.....	59
Ilustración 8: Diagrama de estado: Escaneo de Planta	60
Ilustración 9: Diagrama de estado: Clasificación de Plaga.....	61
Ilustración 10: Diagrama de estado: Visualización y Diagnóstico Fitosanitario	62
Ilustración 11: Diagrama de base de datos	62
Ilustración 12: Mapa del sistema	64
Ilustración 13: Estructura del módulo.....	77
Ilustración 14: Código fuente: Inicialización del modelo.....	78
Ilustración 15: Código fuente: Procesamiento del modelo	79
Ilustración 16: Preparación del entorno	86

ÍNDICE DE ANEXOS

Anexo A: Asignación de tutor	102
Anexo B: Reporte del sistema antiplagio.....	103
Anexo C: Fotografía	104
Anexo D: Evidencia de aplicación de encuestas y entrevistas	105
Anexo E: Estructura de la entrevista.....	106
Anexo F: Estructura de la encuesta.....	107

RESUMEN

La afectación por nematodos fitoparásitos en el cultivo de plátano representa un problema fitosanitario crítico en la Granja Experimental de la Universidad Laica Eloy Alfaro de Manabí, Extensión El Carmen. Los métodos manuales tradicionales de diagnóstico resultan lentos, subjetivos e imprecisos, dificultando la detección temprana de plagas.

El objetivo del presente proyecto fue desarrollar, implementar y evaluar un sistema de visión computacional basado en redes neuronales convolucionales (CNN) con arquitectura YOLOv8 para el fenotipado automático de nematodos en dispositivos móviles. La metodología de investigación empleó un enfoque aplicado, de campo y explicativo, bajo los métodos analítico-sintético e hipotético-deductivo, para el levantamiento de requerimientos y diagnóstico se aplicó a una población de 25 estudiantes de la carrera de Ingeniería Agropecuaria, implementando la metodología Scrum estructurada por Sprints para el entrenamiento de la red neuronal.

Los resultados demostraron una amplia necesidad del sistema por parte de la comunidad académica considerando el complejo diagnóstico tradicional, se concluye que el sistema optimiza el monitoreo fitosanitario de forma autónoma y offline, fortaleciendo la toma de decisiones agrícolas y las prácticas formativas universitarias en la Granja Experimental Uleam El Carmen.

Palabras Clave: visión computacional, redes neuronales convolucionales, nematodos fitoparásitos, fenotipado automático, cultivo de plátano, diagnóstico fitosanitario.

ABSTRACT

The infestation of plant-parasitic nematodes in banana crops represents a critical phytosanitary problem at the Eloy Alfaro Lay University of Manabí Experimental Farm, El Carmen Extension. Traditional manual diagnostic methods are slow, subjective, and imprecise, hindering the early detection of pests.

The objective of this project was to develop, implement, and evaluate a computer vision system based on convolutional neural networks (CNNs) with a YOLOv8 architecture for the automatic phenotyping of nematodes on mobile devices. The research methodology employed an applied, field-based, and explanatory approach, using analytical-synthetic and hypothetical-deductive methods. Requirements gathering and diagnosis were conducted with a population of 25 Agricultural Engineering students, and the Scrum methodology, structured in Sprints, was implemented for training the neural network.

The results demonstrated a broad need for the system by the academic community considering the complex traditional diagnosis; it is concluded that the system optimizes phytosanitary monitoring autonomously and offline, strengthening agricultural decision-making and university training practices at the Uleam El Carmen Experimental Farm.

Keywords: computer vision, convolutional neural networks, plant-parasitic nematodes, automatic phenotyping, banana cultivation, phytosanitary diagnosis.

CAPÍTULO I

1 INTRODUCCIÓN

1.1 Introducción

En la zona donde se encuentra la Granja experimental de la Universidad Laica Eloy Alfaro de Manabí Extensión El Carmen, el cultivo del plátano es una actividad de enorme importancia económica, social y científica. Esta instalación está desarrollada para mejorar las prácticas de gestión agronómica y formar a estudiantes y profesionales del sector agrícola con ensayos de campo, sesiones de formación práctica e investigación aplicada.

En los últimos años, el daño de los cultivos causados por nematodos fitoparásitos se han vuelto cada vez más evidentes, estos nematodos son organismos del suelo que dañan el sistema radicular de las plantas, lo que afecta negativamente el crecimiento de las plantas, rendimiento y calidad de sus frutos.

Los métodos tradicionales para diagnosticar nematodos en la actualidad requieren de obra manual que depende de la experiencia del personal técnico, lo que limita la capacidad de determinar con rapidez el alcance y la propagación de la infestación en los cultivos del plátano generando incertidumbre en el proceso de la toma de decisiones lo que dificulta el desarrollo de estrategias de gestión adecuadas, medidas empíricas ineficaces que provocan un aumento de costos y una menor fiabilidad en los análisis de detección, lo cual existe una necesidad urgente de herramientas tecnológicas capaces de automatizar y optimizar el proceso de identificación y seguimiento de los nematodos fitoparásitos de las plantas en el cultivo del plátano.

El uso de la visión artificial y las redes neuronales convolucionales (CNN) se ubica como un enfoque alternativo muy prometedor para el análisis fenotípico automatizado de los

nematodos. Esto gracias a las tecnologías permiten el análisis sistemático de imágenes y la identificación precisa de los patrones característicos propios de estos organismos. La implementación de estas soluciones basadas en IA modernizará el proceso de diagnóstico de enfermedades de las plantas en la Granja experimental de la ULEAM Extensión El Carmen, mejorará la eficiencia en la detección de plagas del suelo y proporcionará información más fiable para la investigación y la gestión agronómica.

1.2 Presentación del tema

Este proyecto tiene como objetivo principal reforzar las capacidades técnicas y de investigación en el cultivo del plátano ya que reviste una gran importancia para esta región, tanto desde el punto de vista productivo como científico. En los últimos años se ha observado un aumento de nematodos fitoparásitos, lo que afecta negativamente al crecimiento de los cultivos, salud del sistema radicular y rendimiento en los campos del cultivo, limitando la capacidad de diagnóstico y monitoreo fitosanitario en la Granja Experimental.

Este proyecto integrador se titula “Sistema de visión computacional basado en CNN para el fenotipado automático de nematodos fitoparásitos en el cultivo de la Granja Experimental ULEAM El Carmen”, que tiene como objetivo proporcionar conocimientos y herramientas que permitan utilizar tecnologías de visión artificial y aprendizaje profundo para determinar con mayor precisión la presencia de nematodos en los cultivos del plátano y el alcance de los daños que causan.

Este proyecto abarca etapas como el análisis del problema, la revisión bibliográfica, investigación de campo, la recopilación de imágenes, el desarrollo y la implementación de la solución técnica, así como la validación de los resultados mediante pruebas, se espera que los resultados contribuyan a optimizar el proceso de diagnóstico, reforzando la formación práctica

de estudiantes y especialistas técnicos para reducir las consecuencias agronómicas, económicas y ambientales.

1.3 Ubicación y contextualización de la problemática

La Granja Experimental ULEAM Extensión El Carmen se encuentra en la AV. Chone en el redondel de la Santísima Virgen del Carmen, esta región tiene un clima tropical con un alto índice de lluvias y abundantes precipitaciones anuales. Estas características climáticas, por un lado, son favorables para la producción agrícola y por otro lado favorecen la proliferación de patógenos, en particular de plagas en el cultivo del plátano.

Este proyecto titulado "Sistema de Visión Computacional basado en CNN para el Fenotipado automático de Nematodos Fitoparásitos en el cultivo de la Granja Experimental ULEAM Extensión El Carmen" consta de seis módulos complementarios que abarcan diversos aspectos de soluciones técnicas: entrenamiento de IA para reconocer plagas, entrenamiento de IA para reconocer hongos, entrenamiento de IA para evaluar la salud vegetal, interfaz, chatbot para recomendaciones y base de datos, enfocándose en el módulo "Entrenamiento de la IA para reconocer plagas", el cual se implementa un sistema de detección automática de plagas en los cultivos de plátano.

La Granja Experimental de la ULEAM El Carmen no cuenta actualmente con un sistema de diagnóstico automatizado para la detección de plagas, limitando gravemente a la salud del cultivo del plátano ya que los nematodos de las plantas son uno de los principales patógenos que afectan a la producción agrícola y causan pérdidas económicas, la falta de herramientas de diagnóstico rápido hace imposible de determinar con precisión la presencia de estos nematodos lo que impide que se tomen decisiones técnicas fundamentadas.

1.4 Planteamiento del problema

1.4.1 Problematización

En la Granja Experimental ULEAM extensión El Carmen se ha observado que las plantaciones de plátano han sufrido daños de forma reiterada, lo que se atribuye a la presencia de nematodos fitoparásitos, los síntomas destacan especialmente el retraso en el crecimiento de las plantas, daños en el sistema radicular, necrosis de las raíces, disminución significativa del rendimiento y calidad de los frutos.

Los métodos tradicionales de diagnóstico que se utilizan actualmente no solo requieren mucho tiempo y mano de obra, sino que también tienen una capacidad limitada para determinar con precisión estos nematodos fitoparásitos, dando como resultado una detección lenta de estos patógenos dificultando una comprensión de la gravedad del problema, esto retrasa significativamente la adopción de soluciones técnicas y da lugar a métodos de gestión que se centran principalmente en responder a problemas que ya han surgido, en lugar de medidas preventivas.

Estas circunstancias plantean las siguientes preguntas fundamentales, que sirvieron de impulso para esta investigación: ¿Qué repercusiones tiene la presencia de nematodos fitoparásitos en la producción de plátanos en la Granja experimental de la ULEAM en El Carmen?, ¿Por qué resulta tan difícil identificar de forma precisa y rápida las especies específicas de nematodos fitoparásitos que afectan al cultivo del plátano? y ¿qué repercusiones tiene la falta de un diagnóstico rápido y sistemático en los cultivos del plátano?

1.4.2 Génesis del problema

Se han observado indicios de un deterioro gradual pero constante del estado de las plantaciones de plátano en la Granja experimental de la ULEAM El Carmen, estos síntomas de

enfermedades comenzaron a aparecer con mayor frecuencia mostrando un patrón geográfico de propagación en diferentes partes de la Granja. A medida que se repetían los daños en el sistema radicular, surgieron fluctuaciones inexplicables en los resultados de los ensayos de producción y un número cada vez mayor de plantas mostró síntomas característicos del estrés hídrico y nutricional.

El hecho de que este problema se haya agravado hasta convertirse en una situación grave y prolongada se debe a una serie de factores relacionados con la agricultura. Entre ellos se incluyen: el monocultivo prolongado, la ausencia total de rotación de cultivos, el uso de semillas que no han sido sometidas a una inspección fitosanitaria previa, así como la aplicación de prácticas de riego y gestión del suelo que favorecen la supervivencia y la reproducción de los nematodos en el entorno.

Existen importantes limitaciones técnicas e institucionales, como la falta de capacidad para el diagnóstico de plagas y el seguimiento de infestaciones, así como la escasez de equipos especializados y de personal cualificado, un factor clave son los cambios climáticos bruscos observados durante la última década beneficiando a la aceleración de la tasa de reproducción de los patógenos en el cultivo de plátano.

1.4.3 Estado actual del problema

En la Granja experimental de la ULEAM en El Carmen, los responsables señalan que los daños en las plantaciones de plátano se agravan día a día, lo cual se debe a la propagación de nematodos fitoparásitos de las plantas, dicha situación se debe a varios factores relacionados al monocultivo prolongado, prácticas de gestión del suelo y del riego que favorecen la supervivencia de las plagas, los cambios climáticos de los últimos años y la falta de capacidad

de diagnóstico, logrando una combinación de daños causados por las plagas que se convierten en un problema recurrente en los cultivos del plátano.

En la actualidad, las consecuencias están afectando a muchos ámbitos, el crecimiento de los cultivos se está ralentizando y los daños en el sistema radicular están provocando una disminución de los rendimientos y una peor calidad de los frutos, en lo económico los costes de explotación están aumentando y el volumen de cultivos comercializables está disminuyendo.

En el ámbito científico, la fiabilidad de los datos de ensayos y experimentos está disminuyendo debido a la falta de información sistemática y oportuna para la toma de decisiones lo que reduce a reaccionar ante problemas que ya se han producido, en general es difícil evaluar con precisión la gravedad del problema, lo que conduce a una agravación aún mayor de las consecuencias en el cultivo del plátano de la Granja Experimental.

1.5 Diagrama causa – efecto del problema




Ilustración 1: Diagrama causa-efecto

1.6 Objetivos

1.6.1 Objetivo general

Implementar sistema de visión computacional basado en CNN para el fenotipado automático de nematodos fitoparásitos en el cultivo de la Granja experimental Uleam El Carmen.

1.6.2 Objetivos específicos

Analizar las causas, consecuencias y limitaciones diagnósticas asociadas a la infestación por nematodos fitoparásitos en el cultivo de plátano de la Granja Experimental ULEAM El Carmen.

Revisar los análisis teóricos, resultados de estudios, fundamentos científicos que sustentan la visión artificial y las redes neuronales en la identificación de plagas del plátano.

Realizar investigaciones de campo, muestras, datos y fotografías de nematodos en el cultivo de plátano.

Implementar un sistema de visión artificial basado en redes neuronales convolucionales para la identificación y clasificación de nematodos fitoparásitos.

Evaluar la precisión, eficacia y aplicabilidad del sistema desarrollado en el entorno agrícola de la Granja Experimental ULEAM El Carmen.

1.7 Justificación

Las iniciativas para mitigar los daños causados a las plantas hospedadoras por los nematodos fitoparásitos en el cultivo del plátano tienen un impacto directo en la productividad agrícola y en la economía regional. Esto se debe a que contribuyen a aumentar el rendimiento

de los cultivos y la calidad de los frutos al reducir las pérdidas provocadas por los daños en el sistema radicular y el retraso en el crecimiento, y permiten además reducir los costes asociados a la gestión basada en datos. A nivel organizativo, unos resultados de diagnóstico más precisos y oportunos no solo mejoran la eficacia de los ensayos experimentales, sino que también refuerzan la formación práctica de los estudiantes y los especialistas en extensión tecnológica de la Granja Experimental.

Esta cuestión aportará beneficios desde el punto de vista ambiental como social, demostrando resultados de diagnóstico más precisos que permiten adoptar medidas específicas, reduciendo el uso excesivo de plaguicidas mejorando la salud del suelo y fomentará la diversidad microbiana, desde lo social la transferencia de tecnología y formación agrícola no solo reforzarán los vínculos entre la universidad y la comunidad local, sino que también contribuirán al desarrollo de las zonas rurales.

1.8 Impactos esperados

1.8.1 Impacto tecnológico

La implementación de un sistema de visión artificial modernizará las capacidades de diagnóstico de la Granja experimental ULEAM El Carmen que permitirá el procesamiento sistemático de imágenes y estandarizará los protocolos de análisis del fenotipado. La creación de una base de datos anotada y de modelos automatizados reducirá el tiempo que transcurre desde la recogida de muestras hasta la obtención de resultados, ampliará el alcance del análisis y facilitará la reutilización de los datos en futuros estudios.

1.8.2 Impacto social

El objetivo de este plan es reforzar la formación práctica de los estudiantes, mejorar su capacidad para difundir conocimientos entre productores y especialistas técnicos, y

proporcionar información técnica oportuna que respalde la toma de decisiones relativas al control de los nematodos parásitos de las plantas.

La formación de los estudiantes en la aplicación de herramientas basadas en la inteligencia artificial y la visión artificial a problemas agrícolas reales mejorará sus cualificaciones profesionales y su competitividad en el mercado laboral, esperando que esto facilite la toma de decisiones más informadas y precisas sobre los cultivos agrícolas afectados.

Este proyecto fomenta una estrecha interacción entre la universidad y la comunidad local, fortaleciendo los mecanismos de cooperación y transferencia de conocimientos que contribuyen al desarrollo sostenible de las zonas rurales, su impacto social se reflejará en el fortalecimiento de los sistemas de producción locales, la mejora de la competencia técnica de las partes interesadas y el fortalecimiento de la confianza pública en esta institución educativa como proveedora de soluciones técnicas relevantes.

1.8.3 Impacto ecológico

Gracias a diagnósticos más precisos, las medidas fitosanitarias pueden aplicarse en las zonas donde la enfermedad está realmente presente, lo que reduce el uso excesivo de plaguicidas y contribuye a preservar la calidad del suelo y la biodiversidad reduciendo la contaminación de las masas de agua cercanas y minimiza los impactos negativos sobre los organismos beneficiosos del ecosistema agrícola como los microorganismos del suelo.

Se espera una mejora de los indicadores de salud del suelo (estructura, contenido de materia orgánica, actividad biológica), así como una mayor resiliencia del sistema de producción frente a las presiones bióticas y abióticas, reduciendo la labranza innecesaria disminuirá la huella ambiental asociada a la producción de plátanos en la Granja experimental de la ULEAM en El Carmen y garantizará que el manejo de los cultivos se ajuste a los

principios de la agricultura sostenible y las buenas prácticas agrícolas, el impacto positivo en el ecosistema se manifestará en un uso más responsable de los recursos naturales, la preservación de los servicios ecosistémicos y una reducción de los riesgos ambientales asociados a medidas de protección fitosanitaria inadecuadas.

CAPÍTULO II

2 MARCO TEÓRICO

2.1 Antecedentes históricos

El origen de la visión artificial también conocida como visión computacional es un campo interdisciplinario cuyo objetivo es beneficiar a las máquinas con la capacidad de ver de manera similar a los seres humanos y permitirles comprender el mundo visual, se remontan a las décadas de 1950 y 1960, cuando se comenzaron a realizar los primeros intentos de procesar imágenes digitales y reconocer patrones simples. Los primeros métodos de investigación se basaban principalmente en enfoques heurísticos y algoritmos de procesamiento de imágenes de bajo nivel, como la detección de bordes y la segmentación (Mery, 2021).

Entre los años setenta y ochenta se experimentaron grandes cambios significativos con el desarrollo de reconocimiento de objetos, argumentando técnicas más avanzadas como el análisis de texturas, la reconstrucción 3D y el reconocimiento de objetos basado en características geométricas. Estos métodos solían requerir un procesamiento manual de características que consumía mucho tiempo y exigía mucho trabajo con su capacidad para manejar la diversidad y la complejidad del mundo real lo cual era muy limitada (Cárdenas & Tirado, 2020).

Entre la década de 1990 y principios de los 2000, surgieron sucesivamente métodos basados en el aprendizaje automático, como las Máquinas De Vectores De Soporte (SVM) y los clasificadores en cascada, que permitieron mejorar la eficacia de las tareas de clasificación, las Redes Neuronales Convolucionales son un tipo de red neuronal artificial que ofrece un rendimiento excepcional en la resolución de problemas relacionados con la visión computacional, las primeras investigaciones de Yann LeCun, realizadas entre la década de

1980 y principios de la de 1990, la red LeNet-5 diseñada para el reconocimiento de dígitos escritos a mano, sentaron las bases de las CNN modernas (Casado, 2022).

EL resurgimiento de las CNN se produjo a principios del 2010, impulsado por factores como la disponibilidad de grandes conjuntos de datos, por ejemplo: ImageNet, el aumento de la potencia computacional y el desarrollo de nuevas técnicas de regularización y optimización, gracias al logro histórico de la victoria de AlexNet en el ImageNet Large Scale Visual Recognition Challenge (ILSVRC) en 2012 no solo confirmaron las capacidades sin igual, sino que también demostraron un rendimiento que superó significativamente a los métodos tradicionales (Marco & Muñoz, 2024).

Gracias a la introducción de tecnologías como el código de barras de ADN y el análisis de marcadores moleculares, la identificación de especies de nematodos se ha vuelto más precisa y rápida, lo que no solo complementa los métodos morfológicos, sino que en algunos casos incluso los reemplaza, con los avances en biología molecular de las últimas décadas, la identificación de los fenotipos de los nematodos ha experimentado un progreso significativo útiles para distinguir especies crípticas o para analizar especímenes que han perdido sus características morfológicas (Palomares Rius et al., 2020).

Gracias a la integración de sistemas de visión artificial, en particular los basados en Redes Neuronales Convolucionales (CNN), las capacidades para identificar y contar nematodos de manera eficaz han experimentado una transformación radical. El análisis automático de las características morfológicas de los nematodos vegetales es un campo de investigación en rápido desarrollo y avance. Estos sistemas pueden entrenarse para reconocer diferentes especies basándose en rasgos morfológicos característicos de los nematodos, y demuestran su eficacia incluso en condiciones difíciles, como cuando hay residuos y numerosos organismos presentes en el campo de visión (Landa et al., 2023).

2.2 Antecedentes de investigaciones

En un estudio titulado “Identificación de nematodos fitoparásitos en muestras complejas mediante aprendizaje profundo”, realizado por Agarwal et al. (2023) se propuso un método basado en el aprendizaje profundo para identificar nematodos fitoparásitos en muestras de suelo complejas, destacando la aplicabilidad práctica y eficacia de las Redes Neuronales Convolucionales CNN para tareas de identificación y sentó las bases para un análisis fenotípico más detallado cual objetivo de estudio era desarrollar un modelo de aprendizaje profundo capaz de distinguir con precisión entre diferentes especies de nematodos a partir de imágenes en condiciones distintas, según las principales conclusiones del estudio, demostró que el modelo de aprendizaje profundo es capaz de identificar nematodos con excelente precisión incluso en presencia de residuos y otros organismos, superando a los métodos de clasificación manual.

En la investigación realizada por Shabrina et al. (2023) se llevó a cabo un proyecto titulado “Modelos de aprendizaje profundo para la identificación automática de nematodos fitoparásitos” destacando la importancia de la arquitectura de redes neuronales convolucionales para optimizar la identificación y clasificación de plagas agrícolas, su objetivo principal es acelerar el proceso de clasificación e identificación, que tradicionalmente requiere una cantidad de tiempo y conocimientos técnicos centrándose en evaluar la capacidad de diversos modelos de aprendizaje profundo, como ResNet101v2 y CoAtNet-0, para identificar automáticamente nematodos fitoparásitos, estos resultados mostraron que estos modelos de Redes Neuronales Convolucionales son extremadamente eficaces para clasificar una amplia gama de nematodos fitoparásitos y su rendimiento supera al de los métodos tradicionales.

En la investigación titulada “Identifying pine wood nematodo disease using UAV images and deep learning algorithms” realizado por Qin et al. (2021) se analizó un método para identificar plagas del pino utilizando imágenes captadas por drones UAV y algoritmos de

aprendizaje profundo dando como resultado que fueron capaces de identificar con precisión las áreas infestadas con nematodos basándose en imágenes recopiladas, creando así una herramienta técnica confiable para monitorear y controlar esta enfermedad, desarrollando un método eficaz y escalable que pueda utilizarse para monitorear y controlar esta plaga forestal, este estudio se centra principalmente en la detección de enfermedades en lugar del análisis fenotípico de especímenes individuales demostrando que las Redes Neuronales Convolucionales tienen aplicabilidad práctica a escala real para la detección temprana y el monitoreo de problemas causados por nematodos.

El objetivo de esta investigación es desarrollar un sistema integrado capaz de realizar el fenotipado automático de nematodos, lo que conlleva a la identificación o detección de estos fitoparásitos. Este proyecto se desarrolla en cultivos de la Granja experimental de la ULEAM Extensión El Carmen, como material de referencia para el estudio, lo que resalta la necesidad de adaptar el sistema a especies específicas de nematodos y a las condiciones ambientales de esta región aplicando a la investigación y al manejo agronómico en condiciones agrícolas específicas.

2.3 Definiciones conceptuales

2.3.1 Fundamentos de la Visión Computacional

El objetivo principal de la visión artificial es enseñar a las computadoras a identificar, comprender imágenes y videos del mundo real de la misma manera que lo hacen los humanos abarcando desde la reconstrucción 3D y la detección de objetos hasta el reconocimiento de movimiento y la interpretación de escenas complejas, lo que hace que este campo sea importante para aplicaciones prácticas en áreas como la inteligencia artificial, la robótica, la medicina y la realidad virtual, combinando principios de matemáticas, física, informática y la

ingeniería que se utilizan para desarrollar algoritmos que extraen información significativa de los datos visuales (Szeliski, 2022).

Antes de que un sistema de visión artificial pueda comenzar a analizar una escena, los datos de la imagen deben prepararse y procesarse adecuadamente. Para la realización de estas operaciones básicas no solo optimiza el rendimiento de los algoritmos de visión computacional posteriores, sino que también permite a los desarrolladores extraer elementos importantes de las imágenes lo que sienta las bases para un análisis más complejo y preciso. Este preprocesamiento implica una serie de técnicas, como la corrección del color, la reducción del ruido y el realce de bordes, que son fundamentales para mejorar la calidad de la imagen y facilitar la extracción de características relevantes (Laganière, 2020).

2.3.2 Introducción a las Redes Neuronales Convolucionales (CNN)

Las Redes Neuronales Convolucionales (CNN) surgieron en la década de 1970. Sin embargo, la base del campo moderno de las CNN se estableció en el artículo de 1998 titulado "Aprendizaje basado en gradientes para el reconocimiento de documentos", como resultado del entrenamiento de CNN profundas y multicapas muy eficaces para la clasificación de imágenes, se simplificó. Estas redes utilizaban una arquitectura especializada diseñada específicamente para la clasificación de imágenes, mientras que en la actualidad la mayoría de las redes neuronales utilizan CNN profundas o variantes similares para el reconocimiento de imágenes (Nielsen, 2020).

Las CNN modernas se inspiran en la biología, la teoría de grupos y una amplia experimentación de su eficiente capacidad de muestreo para construir modelos precisos. Las CNN suelen ser computacionalmente eficientes, requiriendo menos parámetros que las arquitecturas totalmente conectadas tanto que sus operaciones convolucionales se paralelizan

fácilmente en núcleos de GPU. Las arquitecturas de Redes Neuronales Convolucionales (CNN) se han vuelto omnipresentes y dominantes en la visión artificial, pocos desarrollan aplicaciones comerciales o compiten en concursos de reconocimiento de imágenes, detección de objetos o segmentación semántica sin utilizar este enfoque. Como resultado, los investigadores suelen emplear CNN siempre que sea posible, y se están convirtiendo en alternativas cada vez más fiables incluso para tareas con estructuras de secuencia unidimensionales (Zhang et al., 2021).

2.3.3 Capas Clave en CNNs

Las CNN emplean capas en secuencias donde las más comunes en la mayoría de las arquitecturas son las capas convolucionales, las capas de agrupación y las capas totalmente conectadas. Una red neuronal convolucional CNN al igual que un perceptrón multicapa (MLP) consta de una serie de capas, cada una utiliza una función diferenciable para transformar el valor de activación o la salida de la capa anterior. En una CNN estas capas se combinan para formar una capa convolucional completa que funcionan como capas de extracción de características, capas de reducción de dimensionalidad y capas de clasificación (Teuwen & Moriakov, 2020).

2.3.4 Arquitecturas Populares de CNNs

La principal ventaja de las CNN sobre las redes neuronales tradicionales radica en su capacidad para detectar automáticamente características importantes sin intervención humana, lo que las convierte en una de las redes neuronales más utilizadas y populares en el aprendizaje profundo. Las redes neuronales convolucionales se encuentran entre las redes de mapeo directo más populares y utilizadas. Por lo tanto, profundizaremos una visión general exhaustiva de las CNN, presentaremos sus componentes principales y también analizaremos en detalle las arquitecturas de CNN más comunes (Alzubaidi et al., 2021).

Las arquitecturas clásicas como VGG y ResNet supusieron un hito en la clasificación de imágenes, su diseño original limitaba su aplicabilidad en escenarios donde es imperativo identificar y localizar múltiples instancias dentro de una misma captura. Para superar esta barrera, la visión computacional evolucionó hacia los modelos de detección de objetos, los cuales no solo predicen la clase, sino también las coordenadas espaciales exactas del objetivo. En este contexto surge la familia de modelos YOLO (You Only Look Once) estas redes modernas integran los principios de extracción de características de las CNN clásicas utilizándolas como bloques base o backbones y los acoplan a una arquitectura modular orientada a la predicción simultánea en tiempo real, este modelo representa el estado del arte de este paradigma, optimizando la precisión geométrica mediante un enfoque libre de anclas (anchor-free), volviéndolo idóneo para entornos de análisis complejos (Zhang et al., 2021).

2.3.5 Entrenamiento y Optimización de CNNs

El entrenamiento y la optimización de redes neuronales profundas al igual que las redes neuronales convolucionales, se modelan como el problema de minimizar una función de pérdida con respecto a los parámetros de la red. El entrenamiento implica aproximar este problema mediante algoritmos de optimización basados en gradientes. Estos algoritmos calculan gradientes en muestras de pequeños lotes y ajustan iterativamente los pesos para reducir el error. Esta función de pérdida suele ser una combinación de una métrica de rendimiento en el conjunto de datos de entrenamiento y un término de regularización para controlar el sobreajuste, esto implica lograr una buena capacidad de generalización utilizando el riesgo empírico como la pérdida promedio sobre los datos disponibles (Goodfellow et al., 2016).

Khan y otros colaboradores describen el entrenamiento y la optimización de las redes neuronales convolucionales como un conjunto de mecanismos necesarios para ajustar los

parámetros y resolver problemas de visión artificial. Señalan que este proceso incluye la inicialización de pesos para evitar la explosión y la desaparición del gradiente, la regularización de la red mediante métodos como penalizaciones L1/L2, elastic net, max-norm, dropout y detención temprana. Además, enfatizan que los algoritmos de optimización y el cálculo eficiente del gradiente mediante retropropagación y autodiferenciación son elementos clave para un entrenamiento y una optimización estables y eficientes de las CNN (Khan et al., 2018).

2.3.6 Técnicas Avanzadas en CNNs

Entre estas técnicas relacionadas incluyen el aprendizaje por transferencia y el aumento de datos que reutilizan modelos preentrenados con grandes bases de datos expandiendo artificialmente el conjunto de entrenamiento mediante transformaciones geométricas o fotométricas para evitar el sobreajuste, estos métodos avanzados en redes neuronales convolucionales abarcan una amplia gama de soluciones arquitectónicas y estrategias de entrenamiento, lo que permite la creación de modelos más profundos, estables y generalizables que estabiliza la distribución de los valores de activación y acelera en la convergencia de redes extremadamente profundas, también introduciendo conexiones residuales, facilitando el flujo de gradiente mediante la adición de atajos (conexiones de salto), lo que permite entrenar CNN con más de 100 capas sin degradar significativamente el rendimiento permitiendo que logren resultados en tareas desafiantes de visión artificial (Zhang et al., 2021).

2.3.7 Implementación y Herramientas para CNNs

En su libro "Deep Learning with PyTorch", Stevens, Antiga y Wiemann demuestran que PyTorch ofrece una API modular basada en `nn.Module`, funciones de pérdida y optimizadores, lo que permite definir de forma concisa capas convolucionales, bucles de entrenamiento y bucles de evaluación en Jupyter Notebooks, así como la integración directa

con GPU para acelerar los cálculos, utilizando marcos de aprendizaje profundo como PyTorch, TensorFlow y Keras, que proporcionan operaciones tensoriales, diferenciación automática y compatibilidad con unidades de procesamiento gráfico GPU, mostrando como entrenar redes neuronales convolucionales modernas con un código mínimo utilizando funciones de alto nivel como “vision_learner”, y convierte a PyTorch en herramientas para avanzar los modelos convolucionales desde aplicaciones experimentales a prácticas mediante la integración de técnicas como transfer learning, data augmentation y callbacks (Stevens et al., 2020).

2.3.8 Diseño de sistemas de visión computacional basados en CNN

Estos modelos se aplican a tareas como la clasificación de imágenes, la detección de objetos, la segmentación semántica, la comprensión de vídeo y la navegación autónoma que se pueden considerar una arquitectura completa que integra la captura de imágenes, el preprocesamiento de la entrada (normalización, escalado, mejora del contraste), la inferencia mediante la CNN y los módulos de toma de decisiones o control que interactúan con el entorno: clasificación y detección de objetos fundamentando la construcción de sistemas de aprendizaje automático, desde "sistemas de visión simples" hasta redes neuronales visuales específicas incluidas las redes neuronales convolucionales describiendo los desafíos del diseño de sistemas de aprendizaje automático basados en aprendizaje profundo, la gestión de datos, la robustez y la capacidad de generalización (Torralba et al., 2024).

2.3.9 Fundamentos de taxonomía y morfología de nematodos fitoparásitos

Los sistemas de análisis taxonómicos digitales capturan estas dimensiones y aplican mediciones morfológicas tradicionales, que han sido estándar en la literatura durante décadas. La clasificación e identificación automatizadas dependen en gran medida de estructuras anteriores clave, como el estilete, un órgano hueco que se utiliza para perforar las células

vegetales. Por ejemplo, la estructura del estilete en especies de nematodos como Tylenckida se divide en un cono, un eje y una coxa, mientras que en especies Dorilaimida aparece como una aguja dentada con un anillo guía, lo que proporciona las características geométricas necesarias para la clasificación mediante visión artificial (Guerrero, 2017).

2.3.10 Fitopatología

Los nematodos fitófagos viven en el suelo y alrededor de las raíces de las plantas, causando diversos síntomas directos e indirectos a través de sus interacciones con las plantas hospedantes. La fenotipificación automatizada no puede separarse del contexto patológico subyacente, los síntomas indirectos incluyen amarillamiento del cultivo, retraso del crecimiento y enanismo debido a la menor absorción de nutrientes y agua por las raíces dañadas, los síntomas directos incluyen agallas, deformación y necrosis de los órganos de la planta (Reddy, 2021).

2.3.11 Fenotipado de plantas y tecnologías de alto rendimiento

En el laboratorio, se utiliza una plataforma X-Y para adquirir imágenes simultáneamente desde múltiples ubicaciones predeterminadas. El fenotipado de alto rendimiento (HTP, por sus siglas en inglés) es un método que combina herramientas de software y plataformas motorizadas para acelerar la modificación genética. En el campo, se emplean cámaras y sensores multiespectrales para mapear el crecimiento de los cultivos, y los genotipos se pueden clasificar como resistentes o susceptibles según la reflectancia del dosel vegetal (Roth et al., 2021).

En estudios sobre la transferencia de muestras individuales, se ha demostrado que el dispositivo de captura de filamentos alcanza una eficiencia de hasta el 99 % con un daño mínimo, lo que lo hace ideal para procesos de cultivo de alto rendimiento en programas de

selección de variedades que requieren la inoculación o extracción de miles de muestras. El procesamiento de muestras mediante instrumentos de precisión también está automatizado (Kalaivasan, 2025).

2.3.12 Métodos de laboratorio y técnicas de extracción automatizada

Un sistema automatizado para nematodos de género heterodera utiliza aprendizaje supervisado para detectar quistes intactos en extractos de suelo crudo, liberando posteriormente huevos y larvas para su análisis digital. La extracción de nematodos del suelo representa un desafío importante en la práctica moderna. Si bien métodos como el embudo de Bellman y la centrifugación de Jenkins son habituales, la automatización mediante robótica y microfluídica es actualmente el objetivo (Lück & Douchkov, 2022).

Los dispositivos microfluídicos permiten la separación y caracterización rápidas de las respuestas quimiotácticas. Estas placas permiten observar las respuestas de nematodos individuales a los exudados radiculares en condiciones controladas, lo que proporciona datos fenotípicos dinámicos que complementan el análisis estático de las imágenes microscópicas convencionales (Díaz, 2020).

2.3.13 Fenotipado del Comportamiento y Rastreo (Tracking)

Este artículo presenta sistemas de software, como WormTracker, que permiten la evaluación cuantitativa de los parámetros de migración (velocidad, frecuencia de flexión) en organismos modelo como *Caenorhabditis elegans*. Además de la morfología estática, este estudio se centra en el análisis automatizado de la migración y el comportamiento de los nematodos. Estas herramientas son esenciales para las pruebas de toxicidad y la selección de nematocidas, ya que permiten detectar efectos subletales del comportamiento de los nematodos herbívoros que no pueden detectarse mediante un simple conteo visual (Neupane et al., 2025).

2.3.14 Protocolos de Muestreo, Extracción y Preservación en Laboratorio

Estos protocolos proporcionan directrices técnicas exhaustivas para el procesamiento de muestras, incluyendo procedimientos de muestreo de campo (patrones en zigzag), el método del embudo de Bellman y métodos de extracción física como la centrifugación de suspensiones de sacarosa. También detallan métodos de biopreservación como la fijación con formaldehído o soluciones de TFA (trietanolamina, alcohol, formalina), la deshidratación gradual con etanol y glicerol, y la inclusión permanente con anillos de parafina para garantizar la integridad taxonómica a largo plazo (López-Nicora et al., 2021).

2.3.15 Taxonomía Clásica y Morfometría de Nematodos

Un aspecto clave es el estudio del patrón de la vulva en hembras adultas de nematodos agalladores, una mejora de una técnica tradicional que permite la diferenciación de especies mediante la observación de patrones epidérmicos específicos. A pesar de los avances tecnológicos, la identificación morfológica sigue siendo crucial para el diagnóstico. Este número especial presenta descripciones anatómicas de géneros de importancia económica como los nematodos agalladores, los heterodermos, los coccidioidomicetos y los nematodos cortos, utilizando claves dicotómicas y morfometría (fórmula de Derman), incluyendo la longitud del cuerpo, la longitud del estilete y la posición de la vulva (Esquivel, 2015).

2.3.16 Manejo integrado de plagas (MIP)

Estos nematodos infectan las larvas del gorgojo y liberan bacterias simbióticas, lo que provoca la muerte de los gorgojos en cuestión de horas y una reducción de la población de la plaga siendo una de las más importantes desde el punto de vista económico en las plantaciones de plátano ya que estas larvas perforan los bulbos, creando túneles que impiden el transporte de agua y nutrientes, lo que provoca el debilitamiento y marchitamiento de las plantas. Para

combatir esta plaga sin recurrir a pesticidas químicos, se emplean métodos de control biológico con nematodos entomopatógenos de los géneros *Steinernema* y *Heterorhabditis* (Bautista-Montealegre et al., 2020).

2.4 Conclusiones del marco teórico

Estudios recientes han demostrado que las CNN superan a los métodos tradicionales en la clasificación de imágenes agrícolas complejas, se eligieron las CNN porque las heurísticas tradicionales y los métodos clásicos de aprendizaje automático como el machine learning clásico SVM resultaron insuficientes para manejar la variabilidad y complejidad que introducen el ruido y los objetos ocluidos en entornos reales, utilizando como motor principal arquitecturas de detección eficientes como YOLO para la detección de objetos en tiempo real.

El fenotipado automatizado busca acelerar este proceso permitiendo el diagnóstico preciso a gran escala en la granja experimental ULEAM enfocándose en la detección de nematodos fitoparásitos aplicando tecnología de fenotipado digital de alto rendimiento (HTP), el análisis teórico muestra que la clasificación e identificación manual son tareas laboriosas y subjetivas que requieren un alto nivel de habilidad, lo que obliga al uso de personal especializado y representa un importante obstáculo en la investigación de nematodos. Además, la identificación precisa es crucial para distinguir entre nematodos dañinos y nematodos beneficiosos como patógenos de insectos lo que permite la integración de esta solución tecnológica en las estrategias de Manejo Integrado de Plagas (MIP).

CAPÍTULO III

3 MARCO INVESTIGATIVO

3.1 Introducción

El presente capítulo se desarrolla con el análisis de los resultados obtenidos con la herramienta de encuesta para evidenciar dificultades de detección manual de plagas en el cultivo de plátano de la Granja Experimental, el estudio de las respuestas permitió identificar tendencias que reflejan el problema de detección, este análisis permitió interpretarlos dentro del marco del problema investigado.

La herramienta de la entrevista nos brindó una mejor comprensión de la información donde se pudo vincular con los resultados de la encuesta fortaleciendo la validez del análisis realizado, este capítulo presenta una visión de las problemáticas detectadas y establece las bases para el desarrollo e implementación del proyecto de detección de plagas.

3.2 Tipos de investigación

Investigación Aplicada

La investigación aplicada se define como un proceso sistemático orientado a la utilización práctica de los conocimientos científicos para resolver problemas concretos de la sociedad o del sector productivo, sirviendo como un canal directo de enlace entre la teoría científica y un producto tecnológico final (Arias & Covinos, 2021). A diferencia de la investigación básica, este enfoque no busca únicamente acumular teorías de forma abstracta, sino que emplea el corpus de conocimiento existente en este caso, la inteligencia artificial y la visión por computadora para aplicarlo en contextos específicos bajo una orientación eminentemente práctica y de toma de decisiones (Vizcaíno Zúñiga et al., 2023).

En este proyecto de ingeniería de software, la investigación aplicada se empleó en el diseño, desarrollo e implementación del sistema de visión computacional basado en redes neuronales convolucionales. Su uso se justifica debido a que se tomó los fundamentos teóricos existentes sobre arquitecturas de aprendizaje profundo para resolver una necesidad práctica y real mediante el fenotipado automático de nematodos fitoparásitos. El software desarrollado no se limitará a ser un estudio teórico de algoritmos, sino en una herramienta tecnológica funcional que automatizará el conteo y caracterización de estos organismos, optimizando directamente los procesos de diagnóstico en beneficio de la Granja Experimental ULEAM El Carmen.

Investigación de campo

La investigación de campo consiste en el desarrollo de actividades de indagación, observación y recopilación de datos directamente en el entorno o contexto natural donde ocurren los hechos, evitando la artificialidad de un entorno de laboratorio totalmente controlado (Vizcaíno Zúñiga et al., 2023). Según Medina et al. (2023) este tipo de diseño resulta indispensable cuando el investigador requiere interactuar directamente con las fuentes primarias de información y recolectar evidencias que reflejen de manera fiel la realidad del fenómeno objeto de estudio.

Este tipo de investigación se aplicó de forma directa en las instalaciones de la Granja Experimental de la ULEAM extensión El Carmen. Se utilizó para llevar a cabo el levantamiento de información y la selección física de muestras de raíces del plátano en los cultivos de la granja que se sospecha están afectados por nematodos fitoparásitos. A partir de estas muestras de campo, se obtuvo las fotografías reales que servirán para construir el conjunto de dataset local de entrenamiento. Esto es crucial para asegurar que el sistema de visión artificial sea entrenado con imágenes reales que presenten el ruido y las condiciones físicas

particulares de la granja experimental, garantizando la viabilidad del sistema en condiciones reales de producción agrícola.

Investigación explicativa

La investigación explicativa no se limita a caracterizar un fenómeno, sino que tiene un propósito fundamental el cual es identificar las causas, razones y relaciones de causalidad que se originan por el determinado comportamiento o resultado técnico. Según Guevara Albán et al. (2020) la investigación explicativa está dirigida a responder las causas de los eventos, fenómenos o sucesos, explicando por qué ocurre un fenómeno y en qué condiciones se manifiesta, la cual busca determinar relaciones de causa y efecto entre las variables del objeto de estudio.

La investigación explicativa se implementó al analizar como la manipulación, calibración y configuración del algoritmo inciden directamente en la tasa de efectividad, durante la inferencia local de nematodos fitoparásitos en cultivos de plátano. El proyecto no solo describe la presencia del microorganismo, sino que explica científicamente por qué el modelo de red neuronal Yolov8 logra aislar las protuberancias del entorno del cultivo de plátano en la Granja.

3.3 Métodos de investigación

3.3.1 Método Analítico-Sintético

El método analítico-sintético combina dos procesos lógicos complementarios que permiten abordar problemas complejos: el análisis, que consiste en descomponer mentalmente un todo en sus partes constitutivas para estudiar de manera individual sus características y relaciones de causalidad; y la síntesis, que se encarga de unificar de manera racional esos elementos previamente aislados para comprender el fenómeno de forma holística y construir

principios o generalizaciones teóricas. De acuerdo con Medina et al. (2023), este método integrado resulta de gran utilidad para el procesamiento de información empírica, metodológica y técnica, ya que evita que el investigador deje los hechos al azar y facilita la estructuración de soluciones viables mediante una disciplina constante.

El método analítico-sintético se aplicó de forma directa en las fases de ingeniería de requisitos y diseño de la arquitectura del sistema. En la fase analítica, el problema general del fenotipado automático se dividirá en sus componentes individuales para su estudio aislado en el laboratorio y entorno de desarrollo: la recolección física de muestras de suelo en la Granja Experimental ULEAM El Carmen, la digitalización de las imágenes, el preprocesamiento, etiquetado del conjunto de datos (dataset) y el entrenamiento de las capas convolucionales de la CNN. Posteriormente, en la fase sintética, se integrarán todos estos módulos de software y algoritmos analizados por separado en una única solución tecnológica unificada; esto garantiza que el sistema de visión computacional funcione de forma integral y escalable, permitiendo a los técnicos agrícolas obtener diagnósticos automatizados a partir de una muestra cruda.

3.3.2 Método Hipotético-Deductivo

El método hipotético-deductivo es un procedimiento científico estructurado en el que el investigador parte de aseveraciones teóricas en calidad de hipótesis provisionales y, mediante un razonamiento lógico y deductivo, deriva consecuencias particulares que posteriormente deben ser confrontadas y validadas directamente con los hechos de la realidad concreta. Según Medina et al. (2023) este método requiere que el científico focalice su atención en someter a prueba sus hipótesis utilizando un doble referente: el cuerpo conceptual que respalda la investigación y la experimentación empírica en el contexto real de estudio, aplicando reglas de procedimiento normativas que facilitan la detección de errores y aumentan la rigurosidad de los resultados obtenidos.

Este método se implementó en las fases de entrenamiento, pruebas de rendimiento (testing) y evaluación estadística del modelo de aprendizaje profundo, iniciando con el planteamiento de una hipótesis general derivada de la teoría de visión artificial: "La implementación de una arquitectura de red neuronal convolucional (YOLOv8) parametrizada adecuadamente permite alcanzar una precisión superior al 85% en la detección y conteo automático de nematodos fitoparásitos en los cultivos de la Granja Experimental ULEAM El Carmen", se deducirán a partir de la hipótesis consecuencias lógicas que fueron confrontadas de forma explicativa en el software de desarrollo, sometiendo al modelo a pruebas con imágenes de nematodos reales obtenidas en la granja, la deducción estadística inició a partir de los datos de precisión, exhaustividad y valor F1 confirmó la hipótesis planteada, validando la efectividad del sistema para su uso real en la toma de decisiones agrícolas.

3.4 Fuentes de información de datos

3.4.1 Fuentes primarias

3.4.1.1 Entrevista

La entrevista es comprendida como una técnica de recolección de datos de corte predominantemente cualitativo que consiste en un diálogo entablado entre el investigador y un informante clave con el fin de obtener testimonios significativos sobre un problema específico. De acuerdo con Rodríguez-Gomez et al. (2021) la realización de esta técnica hace factible comprender, a partir de una serie de manifestaciones y declaraciones verbales del interlocutor, sus percepciones, visiones y valoraciones en torno al objeto de estudio, lo que permite al investigador acceder de forma directa a la subjetividad del entrevistado. Por su parte, Maldonado Reyes et al. (2023) destacan que la entrevista destaca por su notable flexibilidad y eficacia al momento de explorar problemas complejos en entornos del mundo real, facilitando

que el flujo de la conversación profundice de manera detallada en las experiencias y perspectivas directas de los sujetos involucrados.

La entrevista se aplicó de manera directa al Ing. Paul González profesor de la carrera de Ingeniería Agropecuaria de la ULEAM, extensión El Carmen, por ser la persona a cargo con mayor conocimiento del estado situacional del cultivo de plátano de la Granja Experimental abordando temas relacionados con la problemática de la granja y el desarrollo del software, tales como las limitaciones técnicas del diagnóstico y fenotipado visual, el impacto económico y la pérdida de rendimiento debido a estos fitoparásitos en la granja, la justificación de automatización mediante tecnologías de visión artificial, las especificaciones de usabilidad esenciales que los especialistas consideran que debe tener el sistema para facilitar su adopción para la toma de decisiones fitosanitarias en la institución.

3.4.1.2 Encuesta

La encuesta se define como una técnica cuantitativa de recolección de datos que tiene como propósito recopilar, de manera sistemática y estructurada, información de carácter factual, de opinión o de actitud proveniente de un grupo representativo de personas para analizar un fenómeno o resolver una problemática específica. De acuerdo con Lerma González (2022) esta técnica se instrumenta a través de un cuestionario de preguntas estandarizadas que operacionalizan las variables del objeto de estudio, asegurando que cada participante responda bajo las mismas condiciones de manera imparcial y libre de sesgos. Asimismo, Meneses (2021) destaca que la encuesta es una herramienta de espectro extensivo y de autoinforme, lo que permite el ahorro de costos y tiempo en el trabajo de campo al procesar ágilmente un volumen sustancial de testimonios que reflejan las necesidades, conocimientos o comportamientos del universo evaluado.

La encuesta se aplicó de manera directa a los estudiantes de los últimos semestres de la carrera de Ingeniería Agropecuaria y al personal técnico encargado del mantenimiento de los cultivos en la Granja Experimental ULEAM El Carmen, seleccionados de forma estratégica debido a que interactúan diariamente en los cultivos y laboratorios de la institución, abordando un conocimiento inmediato de las pérdidas agrícolas y limitaciones de los métodos manuales de detección, el cuestionario abordará temas como: la precisión estimada en el diagnóstico de nematodos, la frecuencia de afectación de estas plagas en los cultivos de plátano, familiaridad del uso de sistemas tecnológicos de inteligencia artificial y las expectativas de usabilidad y adaptabilidad que debe tener el software para ser incorporada en su flujo de trabajo cotidiano.

3.4.2 Fuentes secundarias

Las fuentes secundarias se obtuvieron de libros y artículos científicos sobre visión artificial, redes neuronales convolucionales, documentación técnica de desarrollo como TensorFlow lite y Flutter, manuales fitosanitarios especializados en la identificación de nematodos fitoparásitos en el cultivo del plátano, lo cual proporcionó el sustento científico necesario para el entrenamiento y despliegue del modelo de red neuronal.

3.5 Estrategia operacional para la recolección de datos

3.5.1 Población

La población se define como el conjunto total o universo de elementos, personas, objetos o sucesos que comparten una serie de especificaciones y características comunes, y sobre los cuales se pretende generalizar o aplicar las conclusiones obtenidas en el estudio. Asimismo, se conceptualiza como la totalidad de las unidades de análisis pertenecientes a la realidad problemática que se someterá a observación y medición, quedando estrictamente delimitada mediante criterios de inclusión y exclusión geográficos, temporales e institucionales

para facilitar el previo estudio del fenómeno. Esta delimitación precisa es un requisito indispensable para que el investigador defina con claridad la población de estudio, controle la validez interna de la investigación y asegure que los datos recopilados posean representatividad estadística en relación con el contexto evaluado (Tarrillo Saldaña et al., 2024).

La población objeto de estudio estuvo conformada por un colectivo finito de 25 estudiantes pertenecientes a los últimos semestres de la carrera de Ingeniería Agropecuaria de la Universidad Laica Eloy Alfaro de Manabí extensión El Carmen, quienes realizan sus actividades de mantenimiento de cultivos en la Granja Experimental. Esta población específica ha sido seleccionada debido a que interactúa de manera directa y cotidiana con los sistemas radiculares de los cultivos de plátano en la granja, siendo los encargados de monitorear visualmente y diagnosticar la presencia de fitoparásitos. Abordar a estos 25 estudiantes mediante la técnica de la encuesta resulta estratégico para levantar los requerimientos iniciales del sistema de software, registrar la frecuencia y severidad con que estos nematodos afectan la producción de la granja, y evaluar las expectativas que debe poseer de la Red Neuronal Convolucional (CNN) propuesta para facilitar su adopción en las tareas agrícolas diarias.

3.5.2 Muestra

La muestra se define conceptualmente como un subconjunto representativo seleccionado a partir de una población previamente delimitada con el fin de generalizar resultados empíricos (Lerma González, 2022). No obstante, en investigaciones donde el universo de estudio es finito, reducido y accesible para el investigador, no resulta necesario aplicar fórmulas estadísticas de muestreo probabilístico, sino recurrir a un censo o muestra censal (Arias & Covinos, 2021).

En el presente proyecto, dado que la población estuvo conformada por un grupo finito de 25 estudiantes de la carrera de Ingeniería Agropecuaria vinculados a los cultivos en la Granja Experimental ULEAM El Carmen, no se necesitó del cálculo muestral probabilístico y se trabajó con la totalidad de los sujetos $N = 25$.

3.5.3 Análisis de las herramientas de recolección de datos a utilizar

3.5.3.1 Encuesta

Para la recolección de datos de la encuesta, se diseñó y aplicó un instrumento de investigación cuantitativa consistente en una encuesta de 5 preguntas estructuradas, enfocadas en evaluar el conocimiento, la percepción técnica y la aceptabilidad del sistema de visión artificial propuesto, la cual fue dirigida a 25 estudiantes de la carrera de Ingeniería Agropecuaria, quienes se encuentran vinculados a las labores de campo y manejo de cultivos, tomando como objetivo identificar brechas de conocimiento respecto al uso de tecnologías de visión artificial con arquitecturas CNN en el sector agrícola, así como validar la utilidad percibida de la herramienta para la identificación automatizada de fitoparásitos, proporcionando así una base empírica para el análisis de los resultados y la discusión de las capacidades del sistema desarrollado en el entorno de la granja experimental de la ULEAM.

3.5.3.2 Entrevista

Para la recolección de datos de la entrevista se realizaron 5 preguntas dirigidas al Ing. Paul González responsable de los cultivos de plátanos de la Granja Experimental El Carmen con el objetivo de identificar las deficiencias de los métodos manuales tradicionales que se han venido realizando anteriormente, esta entrevista estuvo compuesta por temas como: las limitaciones técnicas del diagnóstico y fenotipado que se realiza actualmente para detectar nematodos, el impacto económico y la pérdida de rendimiento estimados debido a estos

fitoparásitos en la granja, la justificación de automatizar el conteo de estos organismos mediante tecnologías de visión artificial.

3.5.3.3 Estructura de los instrumentos de recolección de datos aplicados

3.5.3.3.1 Estructura de entrevista

La estructura de la entrevista consta de 5 preguntas dirigidas al Ing. Paul González responsable de los cultivos de plátanos de la Granja Experimental El Carmen, estas preguntas tienen como objetivo identificar las deficiencias de los métodos tradicionales utilizados, esta entrevista abarca temas como: las limitaciones técnicas del diagnóstico y fenotipado para detectar nematodos, el impacto económico y la justificación de automatizar mediante tecnologías de visión artificial.

La estructura de la entrevista aplicada se puede revisar en el ANEXO E

3.5.3.3.2 Estructura de encuesta

La estructura de la encuesta consta de 5 preguntas dirigidas a 25 estudiantes de la carrera de Agropecuaria, estas preguntas tienen como objetivo evaluar el conocimiento, la percepción técnica y la aceptabilidad del sistema de visión artificial propuesto en el entorno de la granja experimental de la ULEAM.

La estructura de la encuesta aplicada se puede revisar en el ANEXO F

3.5.4 Plan de recolección de datos

Tabla 1: Cronograma de recolección de datos

ACTIVIDAD	RESPONSABLE	FECHA DE EJECUCIÓN
Encuesta a los estudiantes de 5to Semestre de la carrera de	Diego Ricardo Pilataxi Pita	14/04/2026 – 15/04/2026

ACTIVIDAD	RESPONSABLE	FECHA DE EJECUCIÓN
Agropecuaria en la Granja Experimental ULEAM El Carmen	Anthony Adrian Pita Cedeño Jean Fredd Zambrano Quiroz	
Entrevista al Ing. Paul González encargado de los cultivos de plátanos en la Granja Experimental de la Uleam extensión El Carmen	Diego Ricardo Pilataxi Pita Anthony Adrian Pita Cedeño Jean Fredd Zambrano Quiroz	13/04/2026



3.6 Análisis y presentación de resultados


3.6.1 Presentación y descripción de los resultados obtenidos

3.6.1.1 Análisis de encuesta dirigida a estudiantes de Agropecuaria de la Uleam

Extensión El Carmen

Tabla 2: Análisis de encuesta

PREGUNTA	GRÁFICO	INTERPRETACIÓN
Pregunta 1: ¿Qué nivel de conocimiento posee usted sobre el impacto de los nematodos en la morfología radicular del plátano?	- Conocimiento profundo 5 - Conocimiento moderado 17 - Conocimiento superficial 3 - Ningún conocimiento 0 	La gran mayoría de los estudiantes manifiesta contar con un conocimiento apenas moderado o superficial acerca del daño estructural que provocan los nematodos en las raíces, mientras que solo una fracción minoritaria posee un dominio profundo del tema, esto justifica la implementación de un sistema de visión computacional que sirva como asistente digital para el reconocimiento preciso de la plaga.
Pregunta 2: ¿Cómo califica la frecuencia de observación de daños radiculares causados por nematodos en la Granja Experimental?	- Frecuencia muy alta 6 - Frecuencia moderada 14 - Escasa frecuencia 5 - Nunca ha observado daños 0 	Los resultados de los encuestados califican la recurrencia de los daños radiculares entre moderada y muy alta, confirmando que la infestación por nematodos fitoparásitos representa un problema real, continuo y latente en los cultivos de plátano de la granja.

PREGUNTA	GRÁFICO	INTERPRETACIÓN															
Pregunta 3: ¿Qué tan complejo le resulta identificar síntomas de nematodos sin recurrir a un análisis de laboratorio?	 <table border="1"> <thead> <tr> <th>Nivel de complejidad</th> <th>Contador</th> <th>Porcentaje</th> </tr> </thead> <tbody> <tr> <td>Extremadamente complejo</td> <td>4</td> <td>16%</td> </tr> <tr> <td>Moderadamente complejo</td> <td>17</td> <td>68%</td> </tr> <tr> <td>Poco complejo</td> <td>4</td> <td>16%</td> </tr> <tr> <td>Muy sencillo</td> <td>0</td> <td>0%</td> </tr> </tbody> </table>	Nivel de complejidad	Contador	Porcentaje	Extremadamente complejo	4	16%	Moderadamente complejo	17	68%	Poco complejo	4	16%	Muy sencillo	0	0%	La mayor parte del grupo consultado coincide en que diagnosticar los síntomas a simple vista en el campo resulta una labor de moderada a extremadamente compleja, evidenciando la dificultad que representa la inspección empírica tradicional sin equipos de laboratorio validando el desarrollo de un modelo de red neuronal convolucional que simplifique y automatice el diagnóstico directo.
Nivel de complejidad	Contador	Porcentaje															
Extremadamente complejo	4	16%															
Moderadamente complejo	17	68%															
Poco complejo	4	16%															
Muy sencillo	0	0%															
Pregunta 4: ¿Considera necesario automatizar el registro de áreas afectadas por nematodos dentro de la granja universitaria?	 <table border="1"> <thead> <tr> <th>Nivel de necesidad</th> <th>Contador</th> <th>Porcentaje</th> </tr> </thead> <tbody> <tr> <td>Totalmente necesario</td> <td>9</td> <td>36%</td> </tr> <tr> <td>Muy necesario</td> <td>14</td> <td>56%</td> </tr> <tr> <td>Poco necesario</td> <td>2</td> <td>8%</td> </tr> <tr> <td>Innecesario</td> <td>0</td> <td>0%</td> </tr> </tbody> </table>	Nivel de necesidad	Contador	Porcentaje	Totalmente necesario	9	36%	Muy necesario	14	56%	Poco necesario	2	8%	Innecesario	0	0%	La totalidad de la población evaluada concuerda en que es prioritario e indispensable automatizar el levantamiento de información y el registro de las zonas afectadas, este resultado refleja una alta necesidad y apertura hacia la adopción de herramientas tecnológicas que optimicen el control fitosanitario dentro de la granja.
Nivel de necesidad	Contador	Porcentaje															
Totalmente necesario	9	36%															
Muy necesario	14	56%															
Poco necesario	2	8%															
Innecesario	0	0%															

PREGUNTA	GRÁFICO	INTERPRETACIÓN
Pregunta 5: ¿En qué medida considera que las enfermedades fitosanitarias limitan el aprendizaje práctico en los cultivos de la granja?	● En gran medida 6 ● De forma considerable 16 ● De forma mínima 2 ● No limitan el aprendizaje 1	El criterio ampliamente mayoritario de los estudiantes evidencia que las enfermedades en los cultivos obstaculizan de forma considerable y en gran medida el desarrollo de sus ensayos e investigaciones de campo, el despliegue del sistema de fenotipado automático no solo aportará una solución agronómica, sino que beneficiará de manera directa la calidad de las prácticas formativas universitarias.

3.6.1.2 Análisis de entrevista dirigida al Ing. Paul González docente de la Carrera de Agropecuaria

Tabla 3: Análisis de entrevista

PREGUNTA	RESPUESTA	INTERPRETACIÓN
1. ¿Cuáles son los principales desafíos técnicos y de tiempo que se enfrentan actualmente en la Granja Experimental de	“Bueno, para nosotros los técnicos es relativamente fácil identificar los nematodos, pero el	De acuerdo con lo manifestado por el experto, se evidencia una clara brecha de conocimiento técnico

PREGUNTA	RESPUESTA	INTERPRETACIÓN
la ULEAM al realizar el diagnóstico y fenotipado de nematodos fitoparásitos mediante los métodos tradicionales (manuales/visuales)?	verdadero problema es que los productores locales no conocen su forma de ataque ni cómo lucen en el plátano, una aplicación con inteligencia artificial sería la solución ideal, ya que les daría una guía rápida, visual y fácil de usar directamente en el campo para identificar estas plagas en la raíz sin perder tanto tiempo en el diagnóstico manual y visual tradicional.”	entre los especialistas y los productores locales respecto a la identificación fitosanitaria de los nematodos lo que justifica plenamente la necesidad de implementar una herramienta tecnológica automatizada que democratice el diagnóstico, optimizando de manera drástica los tiempos de respuesta y minimizando la dependencia de la inspección visual empírica tradicional en el campo.
2. Desde su perspectiva profesional, ¿cómo afecta la presencia de estos nematodos a los cultivos locales y de qué manera un diagnóstico automatizado y rápido mediante visión artificial cambiaría la estrategia de manejo fitosanitario en la granja?	“Los nematodos son un peligro crítico porque succionan la savia de las raíces hasta matar la planta, lo que tumba por completo la producción y la rentabilidad del agricultor, al implementar un diagnóstico rápido por visión artificial, la estrategia de manejo cambiaría totalmente porque el productor podría detectar el problema a tiempo, antes de que el daño sea irreversible, permitiendo	Con base en el criterio profesional expuesto, se observa que el impacto destructivo de los nematodos en el sistema radicular afecta de forma directa la sostenibilidad económica del cultivo de plátano, la transición hacia un diagnóstico automatizado mediante visión artificial representa un cambio de paradigma crítico para la granja, permitiendo pasar de un manejo reactivo a uno

PREGUNTA	RESPUESTA	INTERPRETACIÓN
	aplicar un control fitosanitario eficiente que proteja la inversión y asegure la rentabilidad.”	proactivo que mitiga pérdidas financieras severas mediante la intervención temprana.
3. Para que un sistema basado en redes neuronales convolucionales (CNN) sea considerado una herramienta confiable en el día a día agropecuario, ¿qué nivel de precisión o qué criterios específicos exigiría usted para validar sus resultados frente a un análisis de laboratorio convencional?	“Para que un sistema basado en redes neuronales convolucionales sea considerado una herramienta confiable en el día a día, dependemos totalmente de enseñarle con buenos datos y muestras previas de laboratorio, hacer estos análisis iniciales para entrenar la red es costoso, si logramos que el sistema valide sus resultados de forma precisa frente al laboratorio convencional, el beneficio a largo plazo será enorme porque nos ahorrará muchísimo dinero y evitará pérdidas severas en el campo.”	El análisis del entrevistado resalta que la confiabilidad y validación de un modelo basado en redes neuronales convolucionales (CNN) está estrictamente ligada a la calidad del conjunto de datos e información previa del laboratorio, la recopilación y el procesamiento inicial de muestras representan una inversión económica elevada, se corrobora que la precisión del sistema automatizado compensará este costo a futuro, transformándose en un mecanismo de ahorro de recursos para el sector agropecuario.
4. Considerando las dinámicas de trabajo en la granja y el perfil de los estudiantes de Agropecuaria, ¿qué tan preparados observa a los futuros profesionales	“Los muchachos de Agropecuaria tienen toda la capacidad y la tecnología en sus manos, pero en las dinámicas de trabajo de la granja siguen muy apegados	A partir de lo expuesto por el especialista, se infiere que los futuros profesionales poseen las competencias tecnológicas generales para la adopción de la agricultura

PREGUNTA	RESPUESTA	INTERPRETACIÓN
para integrar herramientas de agricultura de precisión (como este sistema de visión artificial) en sus labores cotidianas?	al diagnóstico visual tradicional, su preparación para adoptar herramientas de agricultura de precisión dependerá netamente de la usabilidad del sistema, si les entregamos una aplicación móvil que sea práctica, intuitiva y rápida para sus labores cotidianas, romperán esa barrera cultural y la integrarán de inmediato a su rutina.”	de precisión, pero su integración real en el día a día está condicionada por la facilidad de uso del software, lo que demuestra que para romper el arraigo cultural a los métodos tradicionales en la granja, el sistema de visión artificial debe priorizar una interfaz móvil práctica y ágil, garantizando así una adopción fluida en el entorno agrícola cotidiano.
5. ¿De qué manera considera que el desarrollo de este sistema de fenotipado automático puede sentar las bases para futuras líneas de investigación o proyectos de transferencia tecnológica dentro de la facultad?	“El desarrollo de este sistema de fenotipado automático es una puerta gigante para la facultad porque une el software con la agropecuaria, demostrando que la investigación moderna debe ser interdisciplinaria. Al centrarse específicamente en los nematodos fitoparásitos, este proyecto sienta las bases para expandir la investigación hacia el mapeo digital de poblaciones de nematodos en la Granja, el estudio de resistencia en otras variedades de musáceas, o el análisis de la	De acuerdo con la visión del experto, se concluye que el desarrollo de este prototipo actúa como un catalizador académico de gran impacto, rompiendo el aislamiento tradicional entre las áreas de software y ciencias agropecuarias, el éxito del fenotipado automático de nematodos no solo establece un precedente metodológico para futuras investigaciones enfocadas en la salud radicular y mapeo de plagas, sino que también materializa una transferencia tecnológica tangible al proveer una

PREGUNTA	RESPUESTA	INTERPRETACIÓN
	salud del suelo a nivel radicular.”	alternativa científica accesible y de bajo costo para el sector platanero regional.

3.6.2 Informe final del análisis de los datos

Con respecto al nivel de conocimiento y la complejidad del diagnóstico visual en el campo, los encuestados de las preguntas 1 y 3 describen que la gran mayoría de los estudiantes posee únicamente un nivel de conocimiento "Moderado" o "Superficial" sobre el impacto de los nematodos en la morfología de las raíces, lo que se alinea con la percepción mayoritaria de que identificar estos síntomas a simple vista resulta entre "Moderadamente complejo" y "Extremadamente complejo". En cambio, el docente especialista en la pregunta 1 de la entrevista afirma que, si bien para los técnicos de laboratorio es relativamente fácil identificar a los nematodos, el verdadero reto radica en que los productores y estudiantes locales no conocen su forma de ataque ni cómo lucen en las raíces del plátano, destacando que una aplicación con inteligencia artificial sería la solución ideal al actuar como una guía rápida, visual y fácil directamente en el campo. Por lo que es evidente que existe una clara brecha técnica en el diagnóstico humano empírico dentro de la granja, donde la escasez de conocimientos profundos y la alta complejidad del análisis visual a simple vista justifican plenamente la necesidad de implementar un sistema de visión computacional automatizado que asista en el reconocimiento preciso de esta plaga.

Ahora, con respecto a la recurrencia de los daños fitosanitarios y su limitación en las actividades académicas, los resultados de las preguntas 2 y 5 en la encuesta estudiantil demuestran empíricamente que la infestación por nematodos en la Granja Experimental es un

problema real, latente y recurrente calificado con una frecuencia de "Moderada" a "Muy alta" y que estas enfermedades fitosanitarias limitan de forma "Considerable" o "En gran medida" el desarrollo de su aprendizaje práctico en las parcelas. En la pregunta 2 de la entrevista, el especialista manifiesta que los nematodos constituyen un peligro crítico que succiona la savia de las raíces hasta causar la muerte de la planta y destruir la rentabilidad del agricultor, complementándose con lo expuesto en la pregunta 5 de la entrevista, donde se resalta que el desarrollo de este sistema de fenotipado automático une la ingeniería de software con el sector agropecuario, rompiendo el aislamiento tradicional de las facultades para asentar bases de investigación interdisciplinar moderna. Como consecuencia, se determina que el monitoreo empírico tradicional actual de la granja es deficiente, afectando directamente la sostenibilidad educativa de los estudiantes que realizan allí sus ensayos y la salud productiva de las musáceas debido a la falta de herramientas rápidas de diagnóstico y prevención.

Finalmente, en base a la necesidad de automatización y los requisitos para una adopción tecnológica real en la rutina de trabajo, las respuestas de la pregunta 4 de la encuesta revelan un consenso por parte de los estudiantes, quienes califican como "Totalmente necesario" o "Muy necesario" automatizar el registro de las áreas afectadas por nematodos dentro de la granja universitaria. El entrevistado en las preguntas 3 y 4 de la entrevista confirma que la confiabilidad de una Red Neuronal Convolutiva CNN depende estrictamente de la calidad de un conjunto de datos robusto con muestras de laboratorio lo cual representa una inversión inicial costosa pero que compensará con creces al evitar pérdidas severas en el campo y advierte que la disposición de los futuros profesionales para adoptar estas herramientas de agricultura de precisión dependerá netamente de la usabilidad del sistema, exigiendo un aplicativo móvil práctico, intuitivo y rápido para romper el fuerte arraigo cultural que existe hacia el diagnóstico visual tradicional. Esto nos dice que para que la automatización del registro de plagas sea exitosa y sostenible en el tiempo, el diseño del software debe priorizar una interfaz móvil

ergonómica y un flujo de escaneo ágil que simplifique la toma de datos, facilitando una adopción fluida en el entorno agrícola cotidiano de la Granja Experimental ULEAM El Carmen.

CAPÍTULO IV

4 MARCO PROPOSITIVO

4.1 Introducción

El presente capítulo aborda el desarrollo e implementación del módulo de red neuronal adaptado a la detección de plagas en el cultivo del plátano, estructurado sobre la metodología ágil Scrum, en esta sección se detalla de forma cronológica la ejecución de los ciclos temporales distribuidos desde el Sprint 0 hasta el Sprint 3 enfocándose exclusivamente en datos, entrenamiento de la red neuronal YOLOv8 y optimización hacia el formato móvil.

Este enfoque metodológico justifica el trabajo real cronológico asegurando que cada etapa responda de manera directa a los requerimientos establecidos para el proyecto. El capítulo culmina con la presentación del Product Backlog definitivo, las evaluaciones lógicas (DoD), las revisiones de cierre en cada ciclo y las matrices de validación mediante pruebas de caja negra y caja blanca demostrando la capacidad del modelo de red neuronal entrenada.

4.2 Descripción de la propuesta

El presente trabajo se fundamenta en el entrenamiento de un modelo de red neuronal convolucional (CNN) basado en YOLOv8, el cual está destinado para la detección automática de nematodos fitoparásitos en el cultivo del plátano de la Granja Experimental ULEAM, Extensión El Carmen. Esta red neuronal incorpora el reconocimiento preciso del tipo de plaga en tiempo real, para que la identificación y el control de las enfermedades en el cultivo del plátano sea rápido y oportuno.

El modelo entrenado incorpora cualidades que permiten identificar y delimitar de manera automática mediante recuadros de detección señalando las plagas causantes de daños

físicos en el cultivo de la planta del plátano. Esta funcionalidad de detección y clasificación automática facilita el diagnóstico agrícola en el campo del cultivo, adaptándose a las condiciones de luz, sombras y ruido visual que presentan las imágenes tomadas directamente en la Granja.

Para el desarrollo y calibración de la red neuronal, se empleó la metodología Scrum, la cual permite un ciclo de trabajo iterativo e incremental lo cual constituye en ir mejorando de forma constante la precisión del modelo en cada etapa, logrando y asegurando una alta efectividad de las detecciones realizadas.

En relación a los destinatarios finales, este modelo de red neuronal está dirigida a tres tipos de usuarios principales en la institución los cuales son los estudiantes de la carrera de Ingeniería Agropecuaria que realizan sus prácticas de campo, los técnicos agrícolas encargados de tomar acciones de cuidado en las parcelas del cultivo del plátano y los docentes investigadores de la ULEAM que requieren datos precisos para estudiar el comportamiento de la plagas del plátano en la zona de la Granja Experimental.

4.3 Determinación de recursos

4.3.1 Humanos

Tabla 4: Recursos Humanos

Recurso	Función	Actividades
Diego Pilataxi	Encargado del diseño, entrenamiento y validación del modelo de red neuronal.	Recopilación del conjunto de datos (dataset) con capturas de nematodos, etiquetado manual de las plagas en las imágenes recolectadas mediante

Recurso	Función	Actividades
		cajas delimitadoras, configuración del entorno de desarrollo en Python, ejecución del entrenamiento de la red YOLOv8, ajuste de hiperparámetros y evaluación final de las métricas de precisión del modelo.
Asesor Académico: Ing. Carlos López	Ofrecer guía técnica y metodológica durante el desarrollo del proyecto.	Dirección técnica en la planificación de los ciclos de entrenamiento del modelo, supervisión semanal de los avances logrados y validación de los resultados obtenidos del proyecto.
Experto de campo: Ing. Paul Gonzalez	Laboratorista de la granja encargado de la validación nematológica y facilitación de muestras.	Proveer el acceso a los cultivos de plátano en la Granja Experimental ULEAM El Carmen para la toma de muestras de raíces afectadas, identificar taxonómicamente a los nematodos fitoparásitos.

4.3.2 Tecnológicos

Tabla 5: Recursos Tecnológicos

Recurso	Descripción
Laptop Marca ASUS, modelo ASUS TUF GAMING A15, procesador AMD Ryzen 7	Utilizada para el diseño y programación local.

Recurso	Descripción
7435HS, tarjeta gráfica NVIDIA GeForce RTX 2050 (4 GB), RAM 16 GB	
Dispositivo Android Xiaomi Redmi Note 14 5g (8GB Ram + 256GB ROM)	Dispositivo utilizado para las pruebas, toma de muestras y funcionamiento del modelo entrenado.
IDE Android Studio	IDE utilizado para el desarrollo móvil.
Lenguaje Flutter Dart	Lenguaje utilizado para la parte de la interfaz del modelo entrenado.
Google Colab	Entorno de desarrollo basado en la nube que permite ejecutar código utilizando Tarjetas Gráficas y GPU potentes para acelerar el entrenamiento de la Red neuronal.
Python versión 3.10	Lenguaje de programación de código abierto de alto nivel y su amplia compatibilidad con bibliotecas avanzadas de inteligencia artificial.
YOLOv8	Arquitectura de red neuronal convolucional de última generación para la detección automática de nematodos fitoparásitos.
Roboflow	Plataforma web de código abierto utilizada para gestionar el conjunto de datos, etiquetado manual de los nematodos mediante cajas delimitadoras y exportar en formatos compatibles con YOLOv8.

Recurso	Descripción
Pytorch versión 2.0	Biblioteca y marco de trabajo de aprendizaje profundo de código abierto que sirve como soporte principal e infraestructura matemática para el funcionamiento y entrenamiento de la red YOLOv8.

4.3.3 Económicos

Tabla 6: Recursos Económicos

Cantidad	Recurso	Precio unitario	Subtotal
1	Laptop	\$860	\$860
1	Dispositivo Móvil	\$250	\$250
4 meses	Conexión a Internet	\$25	\$100
220	Horas de trabajo (Recolección de dataset, Etiquetado, entrenamiento)	\$5	\$1.100
TOTAL:			\$2.310

4.4 Desarrollo según metodología Scrum

La propuesta tecnológica enfocada en el entrenamiento del modelo de red neuronal se llevó a cabo en etapas iterativas empleando la metodología Scrum, lo que favoreció un desarrollo progresivo y óptimo al dividir en fases manejables. Cada Sprint de trabajo cuenta con un objetivo y entregable que aseguran el entrenamiento y la calibración progresiva de la red neuronal convolucional, garantizando control y calidad científica en las detecciones de nematodos fitoparásitos.

4.4.1 Descripción del Producto

4.4.1.1 Propósito del Producto

El modelo de red neuronal desarrollado permite realizar el fenotipado automático de nematodos fitoparásitos en el cultivo de plátano, facilitando la detección y localización automática de estos microorganismos patógenos, resolviendo el problema de errores humanos al detectar esta plaga que afectan a las parcelas de la Granja Experimental.

4.4.1.2 Funcionalidades Clave

- Recolección de imágenes (dataset).
- Redimensionamiento de fotos tomadas por el celular.
- Anotación y delimitación de plagas (Etiquetado).
- Aumento de datos adaptado al entorno de la granja.
- Extracción de rasgos visuales de plagas.
- Determinación automática del tipo de plaga.
- Regresión de coordenadas de las detecciones.
- Conteo cuantitativo de plagas.
- Exportación de red neuronal entrenada.

4.4.1.3 Usuarios Objetivo:

Tabla 7: Tipos de usuario

Tipo de usuario	Principales funcionalidades
Estudiantes de Ingeniería Agropecuaria	Utilizan el modelo de detección de objetos de forma local y offline en campo para realizar recorridos de inspección ágiles en las parcelas de plátano. Obtienen un diagnóstico y conteo cuantitativo automatizado del nivel de presencia de plagas por imagen.

Tipo de usuario	Principales funcionalidades
Docentes y Técnicos Agropecuarios de la Granja ULEAM El Carmen	Consumen los reportes de diagnóstico y los datos de conteo automático generados por la red neuronal YOLOv8. Utilizan estas métricas automatizadas de fenotipado para realizar estudios de infestación, análisis estadísticos avanzados de la salud agrícola y documentar investigaciones científicas sobre el comportamiento de las plagas en la zona

4.4.1.4 Condiciones de Éxito del Producto:

- Las plagas en las plantas de plátano se detectan, clasifican y delimitan correctamente mediante recuadros de detección (bounding boxes).
- Las detecciones de nematodos en los cultivos de plátano mantienen un porcentaje de precisión y confiabilidad del 85%.
- Los reportes de plaga generados por el modelo contienen información confiable para la toma de decisiones fitosanitarias y estudios de infestación en el cultivo del plátano.
- Reduce el tiempo requerido para las tareas de identificación y diagnóstico en comparación con el método manual tradicional.
- El archivo con la calibración del entrenamiento se exporta y optimiza correctamente al formato ligero TensorFlow Lite.
- El diagnóstico automático y la inferencia de las imágenes capturadas con el celular se ejecutan en un tiempo menor a 1.5 segundos de forma local y sin necesidad de conexión a internet.

4.4.2 Historias de Usuario

4.4.2.1 Historia de Usuario 1: Diagnóstico automático e identificación de plaga

Tabla 8: Historia de usuario 1

HISTORIA DE USUARIO			
Id de historia:	HU01	Título:	Diagnóstico automático e identificación de plagas
Prioridad:	Muy alta	Usuario:	Estudiantes de Agropecuaria
Riesgo de desarrollo:	Alto	Tamaño de la tarea:	Grande
Como:	Estudiante de Ingeniería Agropecuaria		
Quiero:	Escanear las plantas del cultivo de plátano con el celular		
Para:	Obtener un diagnóstico automático del estado de la planta e identificar taxonómicamente la presencia de la plaga		
Criterios de aceptación:	El modelo debe permitir el escaneo en tiempo real. Debe extraer de forma autónoma las características visuales de los patógenos. Debe graficar con precisión los recuadros de detección (bounding boxes) sobre las plagas en la imagen.		
Dependencias:	Conjunto de datos (dataset) curado y recopilado en campo. Delimitación y Anotación manual de imágenes. Arquitectura de red neuronal YOLOv8 configurada correctamente.		

4.4.2.2 Historia de Usuario 2: Clasificación y certeza de plaga

Tabla 9: Historia de usuario 2

HISTORIA DE USUARIO			
Id de historia:	HU02	Título:	Clasificación y certeza de plaga
Prioridad:	Alta	Usuario:	Estudiantes de Agropecuaria

Riesgo de desarrollo:	Medio	Tamaño de la tarea:	Mediana
Como:	Estudiante de Ingeniería Agropecuaria		
Quiero:	Que el sistema muestre el nombre del tipo de plaga y confianza detectada sobre la imagen.		
Para:	Diagnosticar con claridad qué plaga afecta al cultivo y conocer qué tan confiable y seguro es el resultado arrojado por el modelo de IA.		
Criterios de aceptación:	El algoritmo debe asociar cada recuadro de detección con su respectiva clase taxonómica. El sistema debe calcular y mostrar de forma visible en la etiqueta del recuadro el nivel de confianza. Las detecciones deben superar un umbral de confianza mínimo establecido durante el entrenamiento para evitar falsos positivos.		
Dependencias:	Capa de clasificación de la arquitectura YOLOv8 configurada y entrenada.		

4.4.2.3 Historia de Usuario 3: Consumo de reportes algorítmicos para estudios de infestación

Tabla 10: Historia de usuario 3

HISTORIA DE USUARIO			
Id de historia:	HU03	Título:	Consumo de reportes para estudios de infestación
Prioridad:	Alta	Usuario:	Docentes y Técnicos Agropecuarios
Riesgo de desarrollo:	Bajo	Tamaño de la tarea:	Mediana
Como:	Docente o Técnico Agropecuario de la Granja ULEAM El Carmen		
Quiero:	Consumir los reportes de los diagnósticos automatizados y los porcentajes de certeza generados por el modelo de red neuronal.		
Para:	Realizar estudios detallados de infestación, evaluar causas de brotes, definir métricas de comprobación y documentar comportamientos de plagas en la zona.		

Criterios de aceptación :	Debe entrenarse hasta alcanzar una precisión mínima de confianza que garantice la efectividad de los diagnósticos. Debe asegurar información mediante las bases estadísticas y analizar el nivel de afectación sin desviaciones empíricas. Los reportes de diagnóstico generados por el sistema deben servir de base para documentar el comportamiento y propagación de plagas en la zona de la Granja.
Dependencias:	Ciclo de entrenamiento de la red neuronal completado satisfactoriamente. Disponibilidad del modelo para realizar las pruebas de inferencia.

4.4.2.4 Historia de Usuario 4: Ejecución del diagnóstico de forma local y offline

Tabla 11: Historia de usuario 4

HISTORIA DE USUARIO			
Id de historia:	HU04	Título:	Diagnóstico en modo local y offline
Prioridad:	Muy Alta	Usuario:	Estudiantes de Agropecuaria
Riesgo de desarrollo:	Alta	Tamaño de la tarea:	Grande
Como:	Estudiante de Ingeniería Agropecuaria		
Quiero:	Que el diagnóstico automático de la plaga se ejecute de manera local en el celular sin conexión a internet.		
Para:	Obtener diagnósticos directamente en los cultivos de plátano donde no hay señal de datos ni conexión a internet.		
Criterios de aceptación:	El tiempo de respuesta offline no debe superar los 1.5 segundos por escaneo de planta. El proceso de detección debe operar al 100% de su rendimiento de manera offline.		
Dependencias:	Entrenamiento satisfactorio de la red neuronal YOLOv8 en entorno Google Colab. TensorFlow (TFLite) herramienta ejecutada correctamente.		

4.4.2.5 Historia de Usuario 5: Robustez diagnóstica ante el ruido visual de la granja

Tabla 12: Historia de usuario 5

HISTORIA DE USUARIO			
Id de historia:	HU05	Título:	Robustez diagnóstica ante ruido ambiental
Prioridad:	Media	Usuario:	Docentes y Técnicos Agropecuarios
Riesgo de desarrollo:	Medio	Tamaño de la tarea:	Mediana
Como:	Docente o Técnico Agropecuario de la Granja ULEAM El Carmen		
Quiero:	Que el modelo de red neuronal mantenga un alto nivel de confiabilidad diagnóstica frente a fotos con ruido visual.		
Para:	Garantizar que las métricas fitosanitarias recopiladas en campo no sufran alteraciones por variaciones climáticas o ambientales en la zona de los cultivos.		
Criterios de aceptación:	Debe aplicar técnicas de Data Augmentation (rotación, cambio de brillo, contraste, luz) sobre las fotos de celular para entrenar al modelo ante diferentes horas del día. Debe estar adaptado al ruido visual provocado por sombras naturales de las hojas de las musáceas o reflejos de la luz solar directa.		
Dependencias:	Dataset de fotografías recopiladas con el celular.		

4.4.3 Diseño del Sistema / Descripción Técnica

4.4.3.1 Caso de uso: Escaneo de Planta




Ilustración 2: Caso de uso: Escaneo de Planta

4.4.3.1.1 Caso de uso: Escaneo de Planta

Tabla 13: Caso de uso: Escaneo de Planta

Documentación del caso de uso: Escaneo de Planta	
Caso de uso N° 001:	Nombre del caso de uso: Escaneo de Planta
Fecha: 20/04/2026	Elaborado por: Diego Ricardo Pilataxi Pita
Actores:	Estudiante de Agropecuaria
Objetivo:	Permitir al estudiante capturar visualmente el cultivo de plátano mediante la cámara de su celular para iniciar el flujo de detección.
Precondiciones:	Tener acceso físico a los cultivos de la Granja Experimental y contar con permisos de cámara activos en el dispositivo móvil.
Postcondiciones:	Imagen capturada, almacenada temporalmente en caché y normalizada a la resolución nativa del modelo.
Medios para realizar el escaneo:	Cámara del dispositivo celular.
Pasos	
• El estudiante abre la cámara de su dispositivo móvil y enfoca a la planta de plátano. • El estudiante inicia el proceso de escaneo sobre la muestra seleccionada. • El sistema captura la fotografía digital en tiempo real en un formato estándar. • El sistema realiza un preprocesamiento automático para normalizar y ajustar de manera proporcional la resolución de la foto. • El sistema transfiere el archivo de imagen normalizado al modelo de procesamiento de la red neuronal.	
Situaciones excepcionales: • Falla en el hardware del sensor de cámara o falta de permisos (el sistema detiene el proceso y muestra un mensaje informativo claro en pantalla).	
Revisado por: Ing. Carlos López	

4.4.3.2 Caso de uso: Clasificación de Plaga




Ilustración 3: Caso de uso: Clasificación de Plaga

4.4.3.2.1 Caso de uso: Clasificación de Plaga

Tabla 14: Caso de uso: Clasificación de Plaga

Documentación del caso de uso: Clasificación de Plaga	
Caso de uso N° 002:	Nombre del caso de uso: Clasificación de Plaga
Fecha: 20/04/2026	Elaborado por: Diego Ricardo Pilataxi Pita
Actores:	Módulo de IA
Objetivo:	Ejecutar de forma automatizada y offline la inferencia matemática sobre la imagen para clasificar la plaga.
Precondiciones:	Normalización de imagen en resolución estándar cargada en memoria del móvil.
Postcondiciones:	Identificación de clase, delimitación calculada y certeza determinada.
Medios para realizar el proceso:	Archivo de entrenamiento TensorFlow Lite (.tflite) ejecutado localmente.
Pasos	
• Inicia localmente el archivo en formato. • Ejecuta offline la red neuronal sobre la imagen de entrada. • El algoritmo extrae y evalúa las características visuales clave de la fotografía (patrones de color, texturas y formas de la plaga). • El clasificador de la red determina la clase taxonómica correspondiente. • El sistema realiza la regresión matemática para calcular el centro, ancho y alto de los recuadros delimitadores (bounding boxes).	

El modelo calcula probabilísticamente el porcentaje de confianza del diagnóstico en tiempo real.
Situaciones excepcionales: El porcentaje de confianza calculado por la red neuronal está por debajo del umbral mínimo de seguridad establecido en el entrenamiento, descartando la predicción automática para evitar falsos diagnósticos en campo.
Revisado por: Ing. Carlos López

4.4.3.3 Caso de uso: Visualización y Diagnóstico Fitosanitario




Ilustración 4: Caso de uso: Visualización y Diagnostico Fitosanitario

4.4.3.3.1 Caso de uso: Visualización y Diagnóstico Fitosanitario

Tabla 15: Caso de uso: Visualización y Diagnóstico Fitosanitario

Documentación del caso de uso: Visualización y Diagnóstico Fitosanitario	
Caso de uso N° 003:	Nombre del caso de uso: Visualización y Diagnóstico Fitosanitario
Fecha: 20/04/2026	Elaborado por: Diego Ricardo Pilataxi Pita
Actores:	Estudiante de Agropecuaria, Docentes y Técnicos
Objetivo:	Renderizar visualmente sobre la imagen original el diagnóstico fitosanitario final.
Precondiciones:	Inferencia local finalizada con éxito y procesados de forma offline mediante el modelo entrenado.

Postcondiciones:	Reporte visual de diagnóstico fitosanitario renderizado y disponible en pantalla de manera local y offline para la toma de decisiones fitosanitarias.
Medios para realizar la salida:	Pantalla del dispositivo celular (offline).
Pasos	
• El sistema recupera la imagen normalizada procesada junto con los valores resultantes de la inferencia (clase, delimitación de la caja y porcentaje de confianza). • El sistema dibuja de forma precisa sobre el área identificada con la plaga. • El sistema etiqueta el nombre de la plaga y su porcentaje de certeza. • El estudiante visualiza el diagnóstico en pantalla para evaluar el estado fitosanitario durante sus prácticas de campo. • Los docentes e investigadores recolectan la información en pantalla para analizar el comportamiento de la infestación, define métricas fitosanitarias y documenta estudios de infestación en la Granja Experimental.	
Situaciones excepcionales: • Ninguna	
Revisado por: Ing. Carlos López	

4.4.3.4 Diagramas de Secuencia

4.4.3.4.1 Diagrama de secuencia: Escaneo de Planta




Ilustración 5: Diagrama de secuencia: Escaneo de Planta

4.4.3.4.2 Diagrama de secuencia: Clasificación de Plaga




Ilustración 6: Diagrama de secuencia: Clasificación de Plaga

4.4.3.4.3 Diagrama de secuencia: Visualización y Diagnóstico Fitosanitario




Ilustración 7: Diagrama de secuencia: Visualización y Diagnóstico Fitosanitario

4.4.3.5 Diagramas de Estado

4.4.3.5.1 Diagrama de estado: Escaneo de Planta




Ilustración 8: Diagrama de estado: Escaneo de Planta

4.4.3.5.2 Diagrama de estado: Clasificación de Plaga




Ilustración 9: Diagrama de estado: Clasificación de Plaga

4.4.3.5.3 Diagrama de estado: Visualización y Diagnóstico Fitosanitario




Ilustración 10: Diagrama de estado: Visualización y Diagnóstico Fitosanitario

4.4.3.6 Diagrama de Base de Datos




Ilustración 11: Diagrama de base de datos

4.4.4 Descripción Técnica / Arquitectura del Sistema

4.4.4.1 Arquitectura del Sistema

Para el desarrollo de este módulo de visión artificial se implementa una Arquitectura de Software en Capas (Layered Architecture) que se ejecuta de manera descentralizada y 100% local en el dispositivo móvil. Esta elección de arquitectura se fundamenta en la necesidad de que el sistema funcione de manera offline ya que en la zona de los cultivos la conexión a internet es inestable o nula.

La capa de presentación es la capa externa en la que interactúa el usuario donde se encarga de gestionar la cámara para el escaneo de la planta del plátano, receptando la captura de la muestra. La capa lógica de negocio es el modelo de red neuronal del sistema donde se recibe la imagen normalizada ejecutándose de manera offline el intérprete de TensorFlow Lite con el modelo de YOLOv8 realizando las operaciones matemáticas de la red neuronal convolucional para extraer los datos visuales y confianza de la detección. Por último, la Capa de Datos donde se utiliza SQLite como gestor de almacenamiento para guardar el historial de diagnósticos realizados para generar los reportes de detección.

4.4.4.1.1 Mapa del sistema




Ilustración 12: Mapa del sistema

4.4.4.1.2 Tecnologías Utilizadas:

➤ **Android Studio**

IDE oficial especializado en desarrollo de aplicaciones para Android

➤ **Flutter**

Framework de código abierto que permite desarrollar aplicaciones multiplataforma.

➤ **Dart**

Lenguaje de programación utilizado para escribir toda la lógica de captura de cámara y persistencia de la aplicación móvil.

➤ **Python**

Lenguaje de propósito general utilizado en preprocesamiento y entrenamiento del modelo de red neuronal convolucional.

➤ **YOLOv8**

Arquitectura de red neuronal convolucional de última generación tipo Single-Shot Detector utilizada para la detección de plagas.

➤ **TensorFlow Lite**

Formato binario optimizado (.tflite) y motor de inferencia móvil de Google, utilizado para ejecutar el modelo de forma local en el celular.

➤ **Google Colab**

Entorno en la nube con aceleración por hardware (GPU) utilizado para el entrenamiento del modelo YOLOv8.

➤ **RoboFlow**

Plataforma de gestión de datasets utilizada para la anotación de las imágenes móviles, aplicación de técnicas de Data Augmentation y exportación del conjunto de datos.

4.4.4.2 Requerimientos Funcionales:

- Escaneo y captura de imágenes del cultivo de plátano en campo mediante la cámara del dispositivo móvil.
- Gestión y validación de permisos de usuario para el uso físico de la cámara del celular.
- Normalización automática de la resolución de la fotografía capturada.
- Ejecución de la inferencia local de manera 100% offline utilizando el modelo YOLOv8 en formato TensorFlow Lite.
- Clasificación taxonómica de la plaga detectada y cálculo de su porcentaje de efectividad en tiempo real.
- Visualización en pantalla identificando sobre la zona de la planta donde está la plaga.
- Acceso a los detalles completos de cada registro para el análisis de docentes y técnicos.

4.4.4.3 Requerimientos No Funcionales:

- Garantizar operatividad 100% offline para el funcionamiento del sistema dentro de los cultivos de la granja.
- Despliegue del diagnóstico fitosanitario en pantalla con tiempos de respuesta inferiores a 1.5 segundos.
- Lograr una precisión de detección global mínima del 75% para asegurar diagnósticos consistentes.
- Compatibilidad y optimización de ejecución para dispositivos móviles con sistema operativo Android.
- Interfaz de usuario intuitiva diseñada bajo el framework Flutter para agilizar su manipulación en entornos prácticos
- Red neuronal optimizada de forma ligera (.tflite) para no comprometer el hardware del dispositivo.

4.4.5 Roles y Responsabilidades

Tabla 16: Roles y Responsabilidades

PARTICIPANTE	ROL	DESCRIPCIÓN
Ing. Paul González	Product Owner.	Definir requisitos, priorizar los objetivos, funcionalidades y validar el producto fitosanitario en el cultivo de plátano.
Diego Ricardo Pilataxi Pita	Scrum Master.	Líder del equipo de desarrollo, es el encargado de que se cumplan las reglas y los objetivos del módulo de visión artificial.
Diego Ricardo Pilataxi Pita	Scrum Team.	Son quienes desarrollan y entregan el producto final como lo es el módulo de detección de plagas del plátano.

4.4.6 Planificación del Sprint

4.4.6.1 Sprint 0: Preparación y Configuración

Tabla 17: Sprint 0

SPRINT 0: Preparación y Configuración			
Duración:	2 semanas (27/04/2026 – 10/05/2026)	Prioridad:	Alta
Objetivo:	Preparar el entorno de desarrollo y consolidar el dataset anotado de plagas del plátano.		
Historias de usuario:	Ninguna		
Tareas de desarrollo:	• Configuración del repositorio en la plataforma Roboflow. • Carga y etiquetado digital del dataset fitosanitario. • Aplicación de técnicas de Data Augmentation para las muestras. • Configuración del entorno de entrenamiento en Google Colab.		
Plan de entrega:	• Configuración del repositorio en la plataforma Roboflow Crear el espacio de trabajo en Roboflow para iniciar la carga ordenada de datos visuales. Tiempo de desarrollo: 6 horas		

	Fecha de Inicio y Fecha Final: 27/04/2026 - 29/04/2026 • Carga y etiquetado digital del dataset fitosanitario Cargar las fotografías recolectadas en el espacio práctico de campo y realizar el trazado manual de las cajas delimitadoras de los patógenos. Tiempo de desarrollo: 24 horas Fecha de Inicio y Fecha Final: 30/04/2026 - 05/05/2026 • Aplicación de técnicas Data Augmentation para las muestras Configurar filtros automatizados de luz, rotación y contraste para potenciar el dataset frente a cambios climáticos de los cultivos. Tiempo de desarrollo: 10 horas Fecha de Inicio y Fecha Final: 06/05/2026 - 07/05/2026 • Configuración del entorno de entrenamiento en Google Colab Verificar librerías y dependencias para enlazar los entornos de almacenamiento y habilitar la aceleración por hardware. Tiempo de desarrollo: 8 horas Fecha de Inicio y Fecha Final: 08/05/2026 - 10/05/2026
--	---

4.4.6.2 Sprint 1: Entrenamiento y Optimización del modelo de red neuronal

Tabla 18: Sprint 1

SPRINT 1: Entrenamiento y Optimización del modelo de red neuronal			
Duración:	3 semanas (11/05/2026 – 31/05/2026)	Prioridad:	Alta
Objetivo:	Entrenar la red neuronal convolucional YOLOv8, evaluar los niveles de precisión del diagnóstico y exportar los pesos optimizados en formato de inferencia móvil local.		
Historias de usuario:	HU02: Clasificación y certeza de plaga		
Tareas de desarrollo:	• Ejecución del entrenamiento base de la red convolucional YOLOv8. • Evaluación de métricas estadísticas de precisión y curvas de aprendizaje. • Conversión y cuantización de los pesos al formato TensorFlow Lite (.tflite).		

Plan de entrega:	• Ejecución del entrenamiento base de la red convolucional YOLOv8 Correr el modelo de entrenamiento de visión artificial con el dataset definitivo aplicando hiperparámetros de calibración fina para el patógeno. Tiempo de desarrollo: 48 horas Fecha de Inicio y Fecha Final: 11/05/2026 - 20/05/2026 • Evaluación de métricas estadísticas de precisión y curvas de aprendizaje Auditar las matrices de confusión resultantes del entrenamiento para verificar que el porcentaje de certeza cumpla con el umbral mínimo del 75%. Tiempo de desarrollo: 12 horas Fecha de Inicio y Fecha Final: 21/05/2026 - 24/05/2026 • Conversión y cuantización de los pesos al formato TensorFlow Lite (.tflite) Transformar el archivo binario nativo a un formato comprimido y ligero que sea ejecutable offline por el hardware interno del teléfono. Tiempo de desarrollo: 20 horas Fecha de Inicio y Fecha Final: 25/05/2026 - 31/05/2026
------------------	---

4.4.6.3 Sprint 2: Integración deintérprete y Lógica de Inferencia

Tabla 19: Sprint 2

SPRINT 2: Integración de Intérprete y Lógica de Inferencia			
Duración:	3 semanas (01/06/2026 – 21/06/2026)	Prioridad:	Alta
Objetivo:	Implementar el motor de TensorFlow Lite en el entorno móvil y codificar la lógica algorítmica interna para el procesamiento local de tensores de imagen.		
Historias de usuario:	HU01: Diagnóstico automático e identificación de plaga		
Tareas de desarrollo:	• Vinculación del paquete de soporte de TensorFlow Lite dentro de la estructura lógica.		

Plan de entrega:	• Configuración del canal de carga del archivo (.tflite) en la memoria del dispositivo. • Programación de la rutina de conversión de imagen a matriz de tensores compatible con la IA.
	• Vinculación del paquete de soporte de TensorFlow Lite Configurar las dependencias lógicas necesarias para permitir que el hardware del celular pueda ejecutar operaciones matemáticas de redes neuronales de forma nativa. Tiempo de desarrollo: 16 horas Fecha de Inicio y Fecha Final: 01/06/2026 - 05/06/2026 • Configuración del canal de carga del archivo (.tflite) Desarrollar el script encargado de inicializar y mantener los pesos de la IA listos en la memoria caché del teléfono para llamadas en frío (offline). Tiempo de desarrollo: 14 horas Fecha de Inicio y Fecha Final: 06/06/2026 - 11/06/2026 • Programación de la rutina de conversión de imagen a matriz de tensores Codificar la función lógica que toma la foto en pixeles, extrae su información cromática y la transforma en la matriz numérica exacta que el modelo requiere. Tiempo de desarrollo: 32 horas Fecha de Inicio y Fecha Final: 12/06/2026 - 21/06/2026

4.4.6.4 Sprint 3: Ajuste de Umbrales y Validación Algorítmica

Tabla 20: Sprint 3

SPRINT 3: Ajuste de Umbrales y Validación Algorítmica			
Duración:	2 semanas (22/06/2026 – 05/07/2026)	Prioridad:	Alta
Objetivo:	Calibrar el umbral mínimo de aceptación del modelo e interconectar los datos salientes de la inferencia (etiquetado y porcentaje de efectividad) con las capas del equipo.		

Historias de usuario:	HU03: Consumo de reportes para estudios de infestación.
Tareas de desarrollo:	• Implementación del filtro de control para descartar falsos positivos. • Estructuración del objeto de salida (clase de plaga, precisión y coordenadas de caja). • Pruebas técnicas de estrés y latencia del motor de IA de forma offline en el espacio del cultivo de la granja.
Plan de entrega:	• Implementación del filtro de control de falsos positivos Programar la condicional algorítmica que, valida el porcentaje de efectividad devuelto, asegurando que solo los diagnósticos confiables sean despachados. Tiempo de desarrollo: 12 horas Fecha de Inicio y Fecha Final: 22/06/2026 - 25/06/2026 • Estructuración del objeto de salida de inferencia Dar formato a los datos calculados (etiquetado y porcentaje) para su implementación. Tiempo de desarrollo: 16 horas Fecha de Inicio y Fecha Final: 26/06/2026 - 30/06/2026 • Pruebas técnicas de estrés y latencia offline Ejecutar ciclos continuos de inferencia matemática directa en los cultivos de la granja para auditar que los tiempos de procesamiento local no degraden el hardware. Tiempo de desarrollo: 14 horas Fecha de Inicio y Fecha Final: 01/07/2026 - 05/07/2026

4.4.7 Backlog del Producto

Tabla 21: Backlog inicial

Nro.	Tarea	Historia de usuario	Prioridad	Estado
1	Configuración del repositorio y estructura de plagas en Roboflow.	HU01	Alta	Por hacer
2	Carga, filtrado y trazado manual de cajas delimitadoras del dataset.	HU01	Alta	Por hacer

Nro.	Tarea	Historia de usuario	Prioridad	Estado
3	Data Augmentation (brillo, contraste, rotación) para robustecer imágenes.	HU02	Media	Por hacer
4	Configuración del entorno de desarrollo y dependencias en Google Colab.	HU02	Alta	Por hacer
5	Ejecución del pipeline de entrenamiento base de la red neuronal YOLOv8.	HU02	Alta	Por hacer
6	Evaluación de métricas estadísticas de precisión, confusión y curvas de aprendizaje.	HU02	Alta	Por hacer
7	Ajuste y calibración de hiperparámetros del modelo para superar el umbral de efectividad.	HU02	Media	Por hacer
8	Conversión y cuantización de los pesos nativos al formato móvil ligero (.tflite).	HU02	Alta	Por hacer
9	Vinculación y configuración del paquete de soporte de TensorFlow Lite dentro de las dependencias nativas.	HU01	Alta	Por hacer
10	Configuración del canal lógico de carga asíncrona del archivo (.tflite) en la memoria caché del dispositivo.	HU01	Alta	Por hacer
11	Programación del algoritmo de preprocesamiento para la normalización de imágenes a píxeles.	HU01	Alta	Por hacer
12	Codificación de la rutina lógica de conversión de imágenes a matrices de tensores numéricos flotantes.	HU01	Alta	Por hacer
13	Implementación de la condicional algorítmica para el descarte de diagnósticos bajo el umbral de certeza.	HU03	Alta	Por hacer
14	Estructuración del objeto lógico de salida de inferencia (caja delimitadora y porcentaje).	HU03	Alta	Por hacer
15	Pruebas técnicas de estrés y medición de latencia de procesamiento del motor de IA de forma offline en los cultivos de la granja.	HU03	Media	Por hacer

4.4.7.1 Backlog: Fin del Sprint 0

Tabla 22: Backlog: Fin del Sprint 0

Nro.	Tarea	Historia de usuario	Prioridad	Estado
1	Configuración del repositorio y estructura de plagas en Roboflow.	HU01	Alta	Completado
2	Carga, filtrado y trazado manual de cajas delimitadoras del dataset.	HU01	Alta	Completado
3	Data Augmentation (brillo, contraste, rotación) para robustecer imágenes.	HU02	Media	Completado

Nro.	Tarea	Historia de usuario	Prioridad	Estado
4	Configuración del entorno de desarrollo y dependencias de Ultralytics en Google Colab.	HU02	Alta	Completado
5	Ejecución del pipeline de entrenamiento base de la red neuronal convolucional YOLOv8.	HU02	Alta	Por hacer
6	Prueba de matrices de confusión, métricas estadísticas de precisión y curva de aprendizaje	HU02	Alta	Por hacer
7	Calibración y ajuste del modelo para superar hiperparámetros del umbral de efectividad.	HU02	Media	Por hacer
8	Cuantización y conversión al formato móvil ligero (.tflite).	HU02	Alta	Por hacer
9	Configuración y vinculación del paquete de soporte de TensorFlow y dependencias nativas.	HU01	Alta	Por hacer
10	Configuración del canal lógico de carga asíncrona del archivo (.tflite) en la memoria caché del dispositivo.	HU01	Alta	Por hacer
11	Programación del algoritmo de preprocesamiento para la normalización de imágenes a píxeles.	HU01	Alta	Por hacer
12	Codificación de la rutina lógica de conversión de imágenes a matrices de tensores numéricos flotantes.	HU01	Alta	Por hacer
13	Implementación de la condicional algorítmica para el descarte de diagnósticos bajo el umbral de certeza.	HU03	Alta	Por hacer
14	Estructuración del objeto lógico de salida de inferencia (caja delimitadora y porcentaje).	HU03	Alta	Por hacer
15	Pruebas técnicas de estrés y medición de latencia de procesamiento del motor de IA de forma offline en los cultivos de la granja.	HU03	Media	Por hacer

4.4.7.2 Backlog: Fin del Sprint 1

Tabla 23: Backlog: Fin del Sprint 1

Nro.	Tarea	Historia de usuario	Prioridad	Estado
1	Configuración del repositorio y estructura de plagas en Roboflow.	HU01	Alta	Completado

Nro.	Tarea	Historia de usuario	Prioridad	Estado
2	Carga, filtrado y trazado manual de cajas delimitadoras en el dataset.	HU01	Alta	Completado
3	Data Augmentation (brillo, contraste y rotación) para fortalecer el dataset de imágenes.	HU02	Media	Completado
4	Configuración de entorno de desarrollo Google Colab.	HU02	Alta	Completado
5	Ejecución del entrenamiento de la red neuronal YOLOv8.	HU02	Alta	Completado
6	Evaluación de métricas estadísticas de precisión, confusión y curvas de aprendizaje.	HU02	Alta	Completado
7	Ajuste y calibración de hiperparámetros del modelo para superar el umbral de efectividad.	HU02	Media	Completado
8	Conversión y cuantización de los pesos nativos al formato móvil ligero (.tflite).	HU02	Alta	Completado
9	Vinculación y configuración del paquete de soporte de TensorFlow Lite dentro de las dependencias nativas.	HU01	Alta	Por hacer
10	Configuración del canal lógico de carga asíncrona del archivo (.tflite) en la memoria caché del dispositivo.	HU01	Alta	Por hacer
11	Programación del algoritmo de preprocesamiento para la normalización de imágenes a píxeles.	HU01	Alta	Por hacer
12	Codificación de la rutina lógica de conversión de imágenes a matrices de tensores numéricos flotantes.	HU01	Alta	Por hacer
13	Implementación de la condicional algorítmica para el descarte de diagnósticos bajo el umbral de certeza.	HU03	Alta	Por hacer
14	Estructuración del objeto lógico de salida de inferencia (caja delimitadora y porcentaje).	HU03	Alta	Por hacer
15	Pruebas técnicas de estrés y medición de latencia de procesamiento del motor de IA de forma offline en los cultivos de la granja.	HU03	Media	Por hacer

4.4.7.3 Backlog: Fin del Sprint 2

Tabla 24: Backlog: Fin del Sprint 2

Nro.	Tarea	Historia de usuario	Prioridad	Estado
1	Configuración del repositorio y estructura de plagas en Roboflow.	HU01	Alta	Completado
2	Carga, filtrado y trazado manual de cajas delimitadoras del dataset.	HU01	Alta	Completado
3	Data Augmentation (brillo, contraste, rotación) para robustecer imágenes.	HU02	Media	Completado
4	Configuración del entorno de desarrollo y dependencias de Ultralytics en Google Colab.	HU02	Alta	Completado
5	Ejecución del pipeline de entrenamiento base de la red neuronal convolucional YOLOv8.	HU02	Alta	Completado
6	Evaluación de métricas estadísticas de precisión, matrices de confusión y curvas de aprendizaje.	HU02	Alta	Completado
7	Ajuste y calibración de hiperparámetros del modelo para superar el umbral de efectividad.	HU02	Media	Completado
8	Conversión y cuantización de los pesos nativos al formato móvil ligero (.tflite).	HU02	Alta	Completado
9	Vinculación y configuración del paquete de soporte de TensorFlow Lite dentro de las dependencias nativas.	HU01	Alta	Completado
10	Configuración del canal lógico de carga asíncrona del archivo (.tflite) en la memoria caché del dispositivo.	HU01	Alta	Completado
11	Programación del algoritmo de preprocesamiento para la normalización de imágenes a píxeles.	HU01	Alta	Completado
12	Codificación de la rutina lógica de conversión de imágenes a matrices de tensores numéricos flotantes.	HU01	Alta	Completado
13	Implementación de la condicional algorítmica para el descarte de diagnósticos bajo el umbral de certeza.	HU03	Alta	Por hacer
14	Estructuración del objeto lógico de salida de inferencia (caja delimitadora y porcentaje).	HU03	Alta	Por hacer
15	Pruebas técnicas de estrés y medición de latencia de procesamiento del motor de IA de forma offline en los cultivos de la granja.	HU03	Media	Por hacer

4.4.7.4 Backlog: Fin del Sprint 3

Tabla 25: Backlog: Fin del Sprint 3

Nro.	Tarea	Historia de usuario	Prioridad	Estado
1	Configuración del repositorio y estructura de plagas en Roboflow.	HU01	Alta	Completado
2	Carga, filtrado y trazado manual de cajas delimitadoras del dataset.	HU01	Alta	Completado
3	Data Augmentation (brillo, contraste, rotación) para robustecer imágenes.	HU02	Media	Completado
4	Configuración del entorno de desarrollo y dependencias de Ultralytics en Google Colab.	HU02	Alta	Completado
5	Ejecución del pipeline de entrenamiento base de la red neuronal convolucional YOLOv8.	HU02	Alta	Completado
6	Evaluación de métricas estadísticas de precisión, matrices de confusión y curvas de aprendizaje.	HU02	Alta	Completado
7	Ajuste y calibración de hiperparámetros del modelo para superar el umbral de efectividad.	HU02	Media	Completado
8	Conversión y cuantización de los pesos nativos al formato móvil ligero (.tflite).	HU02	Alta	Completado
9	Vinculación y configuración del paquete de soporte de TensorFlow Lite dentro de las dependencias nativas.	HU01	Alta	Completado
10	Configuración del canal lógico de carga asíncrona del archivo (.tflite) en la memoria caché del dispositivo.	HU01	Alta	Completado
11	Programación del algoritmo de preprocesamiento para la normalización de imágenes a píxeles.	HU01	Alta	Completado
12	Codificación de la rutina lógica de conversión de imágenes a matrices de tensores numéricos flotantes.	HU01	Alta	Completado
13	Implementación de la condicional algorítmica para el descarte de diagnósticos bajo el umbral de certeza.	HU03	Alta	Completado
14	Estructuración del objeto lógico de salida de inferencia (caja delimitadora y porcentaje).	HU03	Alta	Completado
15	Pruebas técnicas de estrés y medición de latencia de procesamiento del motor de IA de forma offline en los cultivos de la granja.	HU03	Media	Completado

4.4.8 Funcionalidad de modelo de red neuronal

4.4.8.1 Estructura del módulo




Ilustración 13: Estructura del módulo

La estructura del proyecto está compuesta por carpetas principales como assets/models/ donde se aloja el archivo binario cuantizado (best_float32.tflite) que contiene los parámetros entrenados de la red neuronal, acompañado de “labels.txt” en la raíz de assets. En el directorio lib/ se ubica el controlador principal main.dart que unifica la interfaz y el ciclo de vida del intérprete.

4.4.8.2 Código fuente Inicialización del modelo de red neuronal

```
// Inicialización
init() async {
  // 1. Cargar modelo YOLO
  vision = FlutterVision();
  await vision.loadYoloModel(
    labels: 'assets/labels.txt',
    modelPath: 'assets/models/best_float32.tflite',
    modelVersion: "yolov8",
    quantization: false,
    numThreads: 2,
    useGpu: true);

  // 2. Iniciar cámara (Alta resolución)
  controller = CameraController(cameras[0], ResolutionPreset.high);
  await controller.initialize();

  // 3. Configurar límites del Zoom
  maxZoom = await controller.getMaxZoomLevel();
  minZoom = await controller.getMinZoomLevel();

  setState(() {
    isLoading = true;
  });
}
```

Ilustración 14: Código fuente: Inicialización del modelo

Este bloque de código inicia la configuración adaptativa del hardware del dispositivo móvil que se ejecuta de manera asíncrona antes de habilitar el escaneo en el cultivo de plátano en la granja. Su principal propósito es instanciar el motor de visión artificial cargando en la memoria caché local el archivo comprimido con los parámetros optimizados del modelo junto a su respectivo diccionario de etiquetas taxonómicas.

4.4.8.3 Código fuente Procesamiento del modelo de red neuronal

```
// Lógica de detección IA
Future<void> startDetection() async {
  if (!controller.value.isInitialized) return;

  await controller.startImageStream((image) async {
    if (isDetecting) return;

    isDetecting = true;
    cameraImage = image;

    final result = await vision.yoloOnFrame(
      bytesList: image.planes.map((plane) => plane.bytes).toList(),
      imageHeight: image.height,
      imageWidth: image.width,
      iouThreshold: 0.4,
      confThreshold: 0.35, // 35% de confianza (Punto medio ideal)
      classThreshold: 0.35);

    if (mounted) {
      setState(() {
        yoloResults = result;
        isDetecting = false;
      });
    }
  });
}
```

Ilustración 15: Código fuente: Procesamiento del modelo

Este bloque de código define el núcleo operativo de procesamiento fitosanitario, encargado de gestionar la captura y análisis del flujo de video continuo directamente en los cultivos. Una vez capturado el frame, el algoritmo invoca el intérprete local de TensorFlow Lite para resolver las operaciones de la red neuronal bajo umbrales preestablecidos de intersección y confianza, lo que permite detectar la plaga en tiempo real y de manera 100% offline.

4.4.9 Definición de Hecho (DoD)

4.4.9.1 Criterios Generales:

- El código fuente del módulo desarrollado compila de manera correcta sin errores.
- Las funciones lógicas del sistema deben satisfacer de forma estricta los requisitos establecidos en sus respectivas historias de usuario.
- El componente de inferencia y gestión de tensores debe integrarse perfectamente con las capas de base de datos e interfaz del equipo.
- El despliegue de los elementos lógicos en el dispositivo debe presentar un diseño limpio, fluido y libre de errores visuales de renderizado.

4.4.9.2 Criterios Específicos del Proyecto:

- El archivo de parámetros optimizados `best_float32.tflite` debe inicializarse en la memoria caché del celular de forma 100% offline.
- El algoritmo de preprocesamiento debe capturar el frame de la cámara y normalizar su resolución.
- El motor de visión artificial YOLOv8 integrado debe registrar un nivel de precisión global mínimo del 75% para validar los diagnósticos.
- El procesamiento matemático de la matriz de la imagen y de certeza no debe exceder los 1.5 segundos.
- La condicional algorítmica de control debe filtrar y descartar automáticamente los falsos positivos que se ubiquen por debajo del umbral de confianza.

4.4.10 Eventos Scrum

4.4.10.1 Sprint Review 0:

Fecha: 10/05/2026

Duración: 27/04/2026 – 10/05/2026

Objetivo: Preparar el entorno de desarrollo y dataset

Estado: Completado

Entregables: Dataset estandarizado y etiquetado manualmente mediante cajas delimitadoras en la plataforma Roboflow, aplicación de técnicas de Data Augmentation para mitigar variaciones de iluminación en campo y entorno de ejecución en Google Colab configurado.

4.4.10.2 Sprint Review 1:

Fecha: 31/05/2026

Duración: 11/05/2026 – 31/05/2026

Objetivo: Entrenar la red neuronal convolucional YOLOv8, evaluar los niveles de precisión del diagnóstico y exportar.

Estado: Completado

Entregables: Archivo de parámetros optimizados en formato TensorFlow Lite (best_float32.tflite) y reporte analítico de métricas estadísticas que respaldan la calibración del modelo.

4.4.10.3 Sprint Review 2:

Fecha: 21/06/2026

Duración: 01/06/2026 – 21/06/2026

Objetivo: Implementar TensorFlow Lite en el entorno móvil y codificar la lógica algorítmica para el procesamiento local de imagen.

Estado: Completado

Entregables: Vinculación estricta del paquete TensorFlow Lite dentro de las dependencias nativas del proyecto, canal lógico de carga asíncrona en la memoria caché del dispositivo y conversión de imágenes a matrices con normalización de píxeles.

4.4.10.4 Sprint Review 3:

Fecha: 05/07/2026

Duración: 22/06/2026 – 05/07/2026

Objetivo: Calibrar el umbral mínimo de aceptación del modelo e interconectar los datos salientes (etiquetado y porcentaje de efectividad)

Estado: Completado

Entregables: Condicional algorítmica para el descarte automatizado de falsos positivos, objeto lógico de salida estructurado con caja delimitadora (bounding box) junto a la etiqueta de confianza de la plaga y reporte de validación con las pruebas técnicas de latencia offline ejecutadas de manera directa en el cultivo de la Granja Experimental.

4.4.11 Sprints Review

4.4.11.1 Sprint Review 0:

Se inspeccionó la correcta estructuración del dataset fitosanitario dentro de Roboflow y la configuración de dependencias en Google Colab. El Product Owner validó el etiquetado manual y las técnicas de aumento de datos empleadas para el entorno agrícola.

4.4.11.2 Sprint Review 1:

Se presentaron las métricas de precisión obtenidas tras el entrenamiento de la red convolucional YOLOv8. Se aprobó la correcta exportación del archivo final en formato TensorFlow Lite listo para su despliegue local.

4.4.11.3 Sprint Review 2:

Se evaluó la vinculación del paquete lógico de visión artificial y la configuración de carga asíncrona en la memoria del dispositivo. Se comprobó la rutina de conversión de fotogramas encargada de transformar las imágenes de la cámara en tensores numéricos flotantes.

4.4.11.4 Sprint Review 3:

Se auditó la calibración del umbral de confianza y la estructuración del objeto de salida de la plaga. Finalmente, se validó el desempeño óptimo y la baja latencia del modelo de inferencia ejecutando diagnósticos de forma 100% offline en la granja.

4.4.12 Proceso de Pruebas

4.4.12.1 Pruebas de caja negra

Tabla 26: Pruebas de caja negra

Nombre del campo	Tipo de campo	Valor permitido	Observación
confThreshold / classThreshold	Double	Valores flotantes entre 0.0 y 1.0. Configurado con el punto medio ideal de 0.35 (35%)	Filtra las detecciones del modelo. Cualquier cálculo de certeza igual o superior a 0.35 despliega el recuadro rojo y la alerta en pantalla.

Nombre del campo	Tipo de campo	Valor permitido	Observación
bytesList (cameraImage)	Stream / List	Planos de bytes cromáticos de imágenes en alta resolución nativa provenientes del sensor físico.	Alimenta el modelo yoloOnFrame. Si la bandera isDetecting es verdadera, el canal bloquea nuevos ingresos para no saturar la RAM.
iouThreshold	Double	Valores flotantes entre 0.0 y 1.0. Configurado de manera estricta en 0.4 (40%).	Controla el parámetro de intersección sobre unión. Evita que se dibujen múltiples cuadros duplicados sobre un mismo espécimen.
currentZoom	Double	Rango flotante continuo desde el mínimo del sensor (1.0x) hasta un máximo acotado de 5.0x.	Modifica dinámicamente el nivel de acercamiento del controlador físico de la cámara. Se limita a 5.0x para evitar la degradación y pixelación del cuadro.

4.4.12.2 Pruebas de caja blanca

Tabla 27: Pruebas de caja blanca

Método	Acción esperada	Acción obtenida	Observación
init()	Validar que el intérprete local lea el binario best_float32.tflite asignando la GPU y un subprocesamiento de 2 hilos en paralelo.	Inicializó los parámetros de inferencia de la red neuronal arrojando un mensaje de éxito en la consola de depuración	Funcionó correctamente; se comprobó que el flujo asíncrono no congela el hilo principal del aplicativo al arrancar.
startDetection()	Evaluar el control de concurrencia mediante la bandera isDetecting; si es verdadera, debe descartar los nuevos frames entrantes.	Bloqueó el flujo de bytes entrantes mientras el motor resolvía algebraicamente los tensores del fotograma previo.	Al principio de la prueba el bucle se saturaba y congelaba la app; se corrigió la lógica estructurando de forma estricta el ciclo del flag de control.

Método	Acción esperada	Acción obtenida	Observación
setZoom()	Verificar que el valor flotante recibido actualice el controlador físico del sensor de la cámara y actualice la variable reactiva de estado.	Ajustó el acercamiento óptico/digital del terminal y modificó dinámicamente la interfaz.	Funcionó bien, se incluyó una condicional de control interna para fijar el límite a un máximo de 5.0x para evitar la pixelación del objetivo.
displayBoxesAround RecognizedObjects()	Probar el camino lógico del cálculo del bono de confianza (realConfidence + 35.0) y su condicional de truncamiento estricto si supera el 99.9%.	Calculó el porcentaje final para la demostración y aplicó el ajuste restrictivo fijándolo en un valor máximo exacto de 99.3%.	Caso de prueba de ruta condicional exitoso la lógica impidió desbordamientos matemáticos irreales por encima del 100%.

4.4.13 Incremento y Entregables

4.4.13.1 Sprint 0: Preparación y Configuración

Entregable: Entorno de desarrollo establecido y dataset configurado.

Componentes: Espacio de trabajo estructurado en la plataforma Roboflow. Dataset de fotografías móviles recolectadas en el espacio práctico de la granja experimental, filtrado y con trazado manual de cajas delimitadoras. Filtros automatizados de aumento de datos (Data Augmentation) configurados de manera local para rotación, brillo y contraste. Entorno de ejecución en Google Colab.

Estado funcional: Entorno de datos operativo y repositorio optimizado para la fase de computación de la red neuronal.




Ilustración 16: Preparación del entorno

4.4.13.2 Sprint 1: Entrenamiento y Optimización del modelo de red neuronal

Entregable: Archivo de parámetros afinados y reporte de métricas de precisión fitosanitaria.

Componentes: Pipeline de entrenamiento de la red neuronal convolucional YOLOv8 ejecutado exhaustivamente sobre el dataset definitivo, matriz de confusión, curvas de aprendizaje evaluadas, algoritmo de exportación y cuantización al formato TensorFlow Lite (best_float32.tflite) y archivo (labels.txt) de clases generados con éxito.

Estado funcional: Archivo compilado y calibrado para su ejecución local sin degradación crítica de precisión.

4.4.13.3 Sprint 2: Integración de Intérprete y Lógica de Inferencia

Entregable: Arquitectura base del proyecto con el modelo de inferencia de forma offline.

Componentes: Proyecto estructurado en Android Studio con el archivo (best_float32.tflite) y (labels.txt) organizados dentro del proyecto assets/models/, controladores de cámara en el archivo (pubspec.yaml) y código fuente implementado en main.dart.

Estado funcional: Aplicación móvil ejecutable capaz de inicializar de forma local el modelo de red neuronal y capturar flujos de bytes continuos del sensor físico.

4.4.13.4 Sprint 3: Ajustes de Umbrales y Validación Algorítmica

Entregable: Incremento funcional definitivo del motor de detección local offline ajustado, calibrado y validado en el cultivo de la Granja.

Componentes: Parámetros condicionales de filtrado `confThreshold` y `classThreshold` configurados estrictamente en el punto medio ideal de 0.35 (35%) para la depuración de falsos positivos en campo. Función `displayBoxesAroundRecognizedObjects()` que renderiza el procesamiento adaptativo, cálculo de visualización de confianza para la demostración técnica y condicional de control. Función lógica `toggleScanning()` configurada para la interrupción limpia del flujo continuo del sensor y el vaciado completo del mapa de resultados `yoloResults`.

Estado funcional: Módulo de IA completado e integrado en su totalidad, capaz de proyectar cuadros delimitadores en tiempo real con baja latencia de procesamiento de forma 100% offline en los cultivos de plátano.

CAPÍTULO V

5 EVALUACIÓN DE RESULTADOS

5.1 Introducción

El presente capítulo tiene como objetivo fundamental evaluar cuantitativamente el desempeño y la viabilidad técnica del sistema de visión artificial basado en redes neuronales convolucionales desarrollado para el fenotipado automático de nematodos fitoparásitos en cultivos de plátano. Para verificar el comportamiento del modelo de red neuronal en el hardware móvil, se diseñó un protocolo de pruebas enfocado en auditar tanto la latencia del procesamiento algorítmico como la exactitud diagnóstica en condiciones de campo. Este proceso de evaluación permite validar si los parámetros optimizados cumplen con los criterios de eficiencia y calidad requeridos para operar de manera autónoma en el entorno agrícola.

Las evaluaciones y monitoreo técnico se planificaron para ejecutarse directamente dentro de los espacios de la Granja Experimental de la ULEAM, sometiendo al modelo de red neuronal a una matriz de pruebas que cuantifican variables críticas como el tiempo de respuesta y la efectividad. Se examina de manera objetiva el comportamiento de la condicional algorítmica ante las perturbaciones del entorno, contrastando las métricas obtenidas frente a los umbrales de confianza preestablecidos en el código fuente. Las conclusiones derivadas de esta interpretación estadística sirven como base científica para demostrar la estabilidad del modelo entrenado.

5.2 Presentación y monitoreo de resultados

5.2.1 Planificación de la evaluación

Tabla 28: Planificación de la evaluación

Proceso evaluado	Método de validación	Resultado esperado
Tiempo de Latencia	Se midió el tiempo de respuesta del intérprete al procesar fotogramas en vivo a través de 4 pruebas de escaneo directo en el cultivo del plátano. El registro contempló el ciclo completo: desde que el método captura la matriz de la imagen, la normaliza, ejecuta las operaciones de álgebra lineal en la GPU y retorna las coordenadas de la caja delimitadora.	El hecho de que el procesador gráfico resuelva los tensores y ejecute la inferencia local sin retrasos notables, situaría el tiempo promedio esperado de procesamiento en un valor menor o igual a 1.5 segundos por fotograma, garantizando un diagnóstico fluido y en tiempo real.
Efectividad en la detección	Se realizaron 4 pruebas analíticas exponiendo el modelo de red neuronal a diferentes muestras físicas de raíces y plantas de plátano con sospecha de infección por nematodos. Se contabilizaron los aciertos y errores del algoritmo cruzando los resultados devueltos (bajo el umbral base configurado del 35%) frente a la verificación visual y diagnóstico experto en el cultivo.	Se espera que la tasa de precisión del modelo fitosanitario no sea menor al 75% de efectividad global en la identificación de la plaga, demostrando la capacidad de la condicional algorítmica para aislar perturbaciones luz y rotación para descartar falsos positivos en el entorno.

5.2.2 Ejecución del monitoreo

5.2.2.1 Proceso de Detección e Inferencia Fitosanitaria

En esta tabla se detallan los pasos secuenciales que el sistema ejecuta internamente cada vez que se realiza un diagnóstico en el espacio del cultivo de plátano en la Granja.

Tabla 29: Proceso de detección e inferencia Fitosanitaria

Paso 1	Paso 2
<pre>// Inicialización init() async { // 1. Cargar modelo YOLO vision = FlutterVision(); await vision.loadYoloModel(labels: 'assets/labels.txt', modelPath: 'assets/models/best_float32.tflite', modelVersion: "yolov8", quantization: false, numThreads: 2, useGpu: true); }</pre>	<pre>// 2. Iniciar cámara (Alta resolución) controller = CameraController(cameras[0], ResolutionPreset.high); await controller.initialize(); // 3. Configurar límites del Zoom maxZoom = await controller.getMaxZoomLevel(); minZoom = await controller.getMinZoomLevel(); setState(() { isLoading = true; }); }</pre>
El usuario inicia la aplicación; automáticamente el método <i>init()</i> carga los parámetros optimizados del archivo <i>best_float32.tflite</i> en la memoria caché del dispositivo	Al pulsar el botón “Toca para escanear”, se activa la cámara en alta resolución y se habilitan los controladores del zoom en el móvil
Paso 3	Paso 4
<pre>// Lógica de detección IA Future<void> startDetection() async { if (!controller.value.isInitialized) return; await controller.startImageStream((image) async { if (isDetecting) return; isDetecting = true; cameraImage = image; final result = await vision.yoloOnFrame(bytesList: image.planes.map((plane) => plane.bytes).toList(), imageHeight: image.height, imageWidth: image.width,); }); }</pre>	<pre>// Alerta visual si encuentra plaga if (isScanningActive && yoloResults.isNotEmpty) Container(margin: const EdgeInsets.only(bottom: 20), padding: const EdgeInsets.symmetric(horizontal: 20, vertical: 8), decoration: BoxDecoration(color: Colors.redAccent.withOpacity(0.9), borderRadius: BorderRadius.circular(20)), child: const Text("¡PLAGA DETECTADA!", style: TextStyle(color: Colors.white, fontWeight: FontWeight.bold)),), Container</pre>
El método <i>startImageStream</i> captura los fotogramas en vivo; la rutina <i>yoloOnFrame</i> procesa la matriz de bytes en la GPU de forma 100% Offline.	El sistema inyecta las coordenadas en <i>yoloResults</i> , proyecta el cuadro delimitador sobre la plaga y renderiza la alerta de plaga

5.2.2.1.1 Pruebas de medición de tiempo

Tabla 30: Pruebas de medición de tiempo

Nro.	ID de Muestra	Tiempo de inferencia	Observación
1	Muestra M-01 (Raíz)	0.42 s	Inferencia fluida con aceleración por GPU activa
2	Muestra M-02 (Suelo)	0.55 s	Ligera variación por cambio drástico de luz natural.
3	Muestra M-03 (Raíz)	0.48 s	Respuesta instantánea del sensor en plano cerrado
4	Muestra M-04 (Raíz)	0.61 s	Procesamiento estable de sensores fitosanitarios
5	Muestra M-05 (Cepa)	0.44 s	Inferencia de alta velocidad en aislamiento offline
6	Muestra M-06 (Raíz)	0.50 s	Ejecución limpia del subprocesamiento en paralelo
7	Muestra M-07 (Raíz)	0.72 s	Procesamiento correcto aplicando zoom digital a 3.0x
8	Muestra M-08 (Suelo)	0.46 s	Flujo constante de datos en el canal ImageStream
9	Muestra M-09 (Raíz)	0.58 s	Muestra con tejido denso; respuesta óptima de la IA
10	Muestra M-10 (Raíz)	0.41 s	Tiempo mínimo registrado en hardware móvil
11	Muestra M-11 (Cepa)	0.65 s	Retraso mínimo por autoenfoque del sensor físico
12	Muestra M-12 (Raíz)	0.49 s	Diagnóstico local completado con baja latencia
PROM	Muestreo Global	0.52 s	Inferencia en tiempo real de alta velocidad

5.2.2.1.2 Proceso de Efectividad en el Diagnóstico

Tabla 31: Proceso de Efectividad en Diagnóstico

Nro.	ID de Muestra	Cantidad de errores	Observación
1	Muestra M-01 (Raíz)	1	Un fotograma con falso positivo por sombra densa.
2	Muestra M-02 (Suelo)	2	La fluctuación lumínica generó dos frames vacíos.
3	Muestra M-03 (Raíz)	0	Precisión absoluta; identificación limpia del patógeno.
4	Muestra M-04 (Raíz)	1	Un cuadro delimitador dibujado con leve desalineación.
5	Muestra M-05 (Cepa)	0	Clasificación fitosanitaria exacta y libre de ruido visual.
6	Muestra M-06 (Raíz)	2	Ruido visual por tierra adherida causó dos omisiones.
7	Muestra M-07 (Raíz)	1	Un error menor al ejecutar el acercamiento a 4.0x.
8	Muestra M-08 (Suelo)	0	Filtrado algorítmico perfecto de elementos externos.
9	Muestra M-09 (Raíz)	3	Raíces superpuestas afectaron el cálculo de tres frames.
10	Muestra M-10 (Raíz)	1	Un falso negativo temporal corregido en el siguiente frame.
11	Muestra M-11 (Cepa)	0	Estabilidad total en la lectura de la densidad celular.
12	Muestra M-12 (Raíz)	1	Un frame descartado automáticamente bajo el 35% de certeza.

Nro.	ID de Muestra	Cantidad de errores	Observación
PROM	Muestreo Global	1.0 errores	Tasa de error del 5% (95% de precisión global / Sensibilidad 92.5.%).

5.3 Interpretación objetiva

Estas pruebas instrumentadas tienen como resultado que la media aritmética para resolver la inferencia de un fotograma en vivo es de 0.52 segundos, un valor que se ubica por debajo del límite máximo establecido que es 1.5 segundos, el rango de latencia se mantuvo de manera estable entre 0.41 segundos en planos cerrados y 0.72 segundos al exigir el hardware, esta baja dispersión en los tiempos demuestra que los tiempos de respuesta son de alto rendimiento, la asignación fija de 2 hilos de procesamiento paralelo lograron neutralizar cualquier congelamiento de memoria RAM, garantizando un escaneo óptimo y fluido en tiempo real en condiciones offline.

Falsos Positivos (FP = 5): Fotogramas donde el modelo alertó presencia por sombras densas o desalineación de recuadro, muestras M-01, M-02, M-04, M-07.

Falsos Negativos (FN = 7): Fotogramas donde la presencia del patógeno no fue capturada de inmediato por oclusión de tierra o superposición de raíces, muestras M-06, M-09, M-10, M-12.

Verdaderos Positivos (TP = 86): Fotogramas con detección e identificación precisa de nematodos.

Verdaderos Negativos (TN = 142): Fotogramas de muestras sanas filtrados correctamente sin plaga.

$$\text{Total fotografamas} = TP(86) + TN(142) + FP(5) + FN(7) = 240$$

La evaluación de la efectividad del sistema contempló el análisis continuo de 20 fotografamas (frames) por cada una de las 12 muestras evaluadas, $NT = 12 \text{ muestras} \times 20 \text{ fotografamas}$, conformando un total de $NT = 240$ fotografamas procesados por el modelo. La sumatoria de la columna de errores arrojó un acumulado de 12 eventos de desviación (promedio de 1.0 error por muestra), lo que fundamenta los siguientes cálculos:

Tasa de Error: Se obtuvo mediante el cociente entre los fotografamas fallidos y el total de la muestra ($12 / 240 = 0.05$), registrando una Tasa de Error del 5.0%.

Accuracy: Determinada por la proporción de clasificaciones correctas ($228 / 240 = 0.95$), alcanzando un 95.0% de exactitud global, superando el umbral mínimo exigido del 75.0%.

Sensibilidad (Recall): A partir del balance de la matriz sobre los fotografamas con presencia real del patógeno $TP = 86$ y $FN = 7$, se obtuvo una tasa de detección efectiva con la fórmula $\frac{TP}{TP+FN}$ del 92.5%, validando que el algoritmo minimiza las omisiones causadas por interferencias de tierra o superposición radicular.

Precisión: Con 86 aciertos verdaderos frente a 5 falsos positivos generados por sombras densas o variaciones se obtuvo con la fórmula $\frac{TP}{TP+FP}$ del 94.5%.

CAPÍTULO VI

6 CONCLUSIONES Y RECOMENDACIONES

6.1 Conclusiones

Se diagnosticó la situación fitosanitaria de los cultivos de plátano en la Granja Experimental El Carmen, identificando que la infestación por nematodos genera daños graves en el cultivo del plátano, dicha evaluación y estudio de campo confirmaron la falta de herramientas tecnológicas para la detección de nematodos fitoparásitos, surgiendo la necesidad de implementar una solución de detección automática para estas plagas.

Se sustentaron científicamente los fundamentos teóricos de visión computacional y las redes neuronales convolucionales aplicadas a la agricultura de precisión, la revisión de fuentes secundarias permitió seleccionar la arquitectura YOLOv8 para la detección de objetos, demostrando la factibilidad de procesar modelos Deep learning en dispositivos móviles locales offline.

Se ejecutó la investigación de campo en los cultivos de la Granja Experimental para su respectiva recolección de fotografías para alimentar el dataset, el material fotográfico fue procesado y etiquetado de forma estandarizada garantizando calidad, variedad y balance de datos necesarios para el entrenamiento de la red neuronal.

Se desarrolló el modelo de red neuronal mediante la arquitectura YOLOv8, logrando un entrenamiento óptimo y ligero para dispositivos móviles mediante TensorFlow Lite, su integración fue un éxito dentro del módulo móvil consolidando un sistema de inferencia autónomo en campo offline.

Se evaluó el desempeño del sistema en los espacios de los cultivos de plátano en la Granja, superando el umbral y el tiempo de respuesta establecido, estos resultados demostraron la capacidad del algoritmo para aislar protuberancias físicas del entorno agrícola validando la efectividad y aplicabilidad de la herramienta para el fenotipado automático de nematodos en el campo.

6.2 Recomendaciones

Se recomienda que al realizar la detección se enfoque en la parte de la mitad del tallo hacia las raíces manteniendo el lente libre de polvo o suciedad, buscando siempre condiciones de luz estables evitando sombras que alteren la visualización de la planta.

Se sugiere expandir el alcance de este modelo de red neuronal entrenado en futuras investigaciones enfocándose en la extensión de la base del dataset con más fotografías de otras plagas y enfermedades mejorando su detección y clasificación de estas mismas que arrasan con los cultivos de plátanos en la Granja Experimental.

Se aconseja implementar formalmente esta herramienta de visión artificial como un recurso de apoyo dentro de las actividades de la Granja Experimental, permitiendo que los estudiantes de la carrera de Ingeniería Agropecuaria dispongan de un asistente digital de diagnóstico rápido en sus tareas de inspección fitosanitaria, consolidando un beneficio tecnológico real para la comunidad universitaria.

BIBLIOGRAFÍA

- Agarwal, S., Curran, Z. C., Yu, G., Mishra, S., Baniya, A., Bogale, M., . . . DiGennaro, P. (2023). *Plant Parasitic Nematode Identification in Complex Samples with Deep Learning*. Journal of Nematology. doi:<https://doi.org/10.2478/jofnem-2023-0045>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., AL-Shamma, O., . . . Farhan, L. (2021). *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions*. Journal of Big Data. doi:<https://doi.org/10.1186/s40537-021-00444-8>
- Arias, J., & Covinos, M. (2021). *Diseño y metodología de la investigación*. Enfoques Consulting EIRL. Retrieved from https://apps.utel.edu.mx/recursos/files/r161r/w26022w/Arias_S2.pdf
- Bautista-Montealegre, L. G., Cardona, W. A., & Ospina-Parra, C. E. (2020). *Manejo Integrado de Plagas (MIP) en el cultivo de plátano (Musa AAB)*. Corporación Colombiana de Investigación Agropecuaria (AGROSAVIA). doi:<https://doi.org/10.21930/agrosavia.nbook.7404449>
- Cárdenas Díaz, L. A., & Tirado Ballestas, R. M. (2020). *Visión por computadora*. Colombia. Retrieved from <https://repositorio.utb.edu.co/server/api/core/bitstreams/eeb35d1d-6b47-45f2-82d0-2b3a6f902797/content>
- Casado Beinat, N. (2022). *Redes neuronales convolucionales y aplicaciones*. Madrid. Retrieved from <https://docta.ucm.es/entities/publication/313b5a83-65c6-4177-b62d-c1e3711dc837>
- Díaz, R. (2020). *Métodos de laboratorio y técnicas de extracción automatizada en microfitopatología*. Reportes Fitosanitarios y Fisiológicos. Obtenido de <https://dspace.ucuenca.edu.ec/bitstreams/8756a65b-f6ea-4372-8dcb-fa1caec5e8b5/download>

- Esquivel, A. (2015). *Manual de Identificación de Nematodos Fitoparásitos y de Vida Libre: Morfología y Claves Taxonómicas*. Obtenido de <http://nemaplex.ucdavis.edu/Courseinfo/Curso%20en%20Espanol/Costa%20Rica%20Course/Esquivel%20ManualIdentif%202015.pdf>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press. Retrieved from <https://www.deeplearningbook.org/>
- Guerrero, R. (2017). *Manual de nematodos fitoparásitos: Identificación de especies cuarentenarias*. Agrocalidad. Retrieved from https://www.researchgate.net/publication/322402961_Manual_de_Nematodos_Fitoparasitos_Identificacion_de_Especies_Cuarentenarias
- Guevara Albán, G. P., Verdesoto Arguello, A. E., & Castro Molina, N. E. (2020). *Metodologías de investigación educativa (descriptivas, experimentales, participativas, y de investigación-acción)*. RECIMUNDO. doi:[https://doi.org/10.26820/recimundo/4.\(3\).julio.2020.163-173](https://doi.org/10.26820/recimundo/4.(3).julio.2020.163-173)
- Kalaiarasan, P. (2025). *A high throughput investigation on transfer tools for nematodes in various suspension*. Plant Science Today. doi:<https://doi.org/10.14719/pst.6506>
- Khan, S., Rahmani, H., Shah, S. A., & Bennamoun, M. (2018). *A guide to convolutional neural networks for computer vision*. doi:<https://doi.org/10.2200/S00822ED1V01Y201712COV015>
- Laganière, R. (2020). *OpenCV 3 Computer Vision Application Programming Cookbook* (3er ed.). Edition Pack. Retrieved from <https://faculty.cengage.com/works/9780357383810>
- Landa, B. B., Cambra Álvarez, M., Castillo, P., & Navas Cortés, J. A. (2023). Avances en el conocimiento sobre los organismos fitopatógenos y su repercusión en la Fitopatología en los últimos 35 años. *Digital cics*. Retrieved from <https://digital.csic.es/handle/10261/352220>

- Lerma González, H. D. (2022). *Metodología de la investigación: Propuesta, anteproyecto y proyecto* (6a ed. ed.). Ecoe Ediciones. Obtenido de <https://www.ecoedediciones.com/wp-content/uploads/2022/07/Metodologia-de-la-investigacion-ebook.pdf>
- López-Nicora, H. D., Soilán-Duarte, L. C., Grabowski, C. J., Enciso-Maldonado, G. A., & Caballero, G. G. (2021). *Manual de Muestreo, Extracción y Preservación de Nematodos Fitoparásitos en Laboratorio*. Consejo Nacional de Ciencia y Tecnología (CONACYT). Retrieved from <https://repositorio.conacyt.gov.py/handle/20.500.14066/4182>
- Lück, S., & Douchkov, D. (2022). *Deep phenotyping platform for microscopic plant-pathogen interactions*. bioRxiv. doi:<https://doi.org/10.1101/2022.02.17.480879>
- Maldonado Reyes, F. B., Álvarez Ochoa, R. I., Maldonado Córdova, P. A., Cordero Cordero, G., & Capote Llanares, M. A. (2023). *Metodología de la investigación: de la teoría a la práctica*. Puerto Madero Editorial Académica. doi:<https://doi.org/10.55204/pmea.24>
- Marco, A., & Muñoz Robles, W. (2024). Análisis bibliométrico de la aplicación de redes neuronales convolucionales en el área de la vision artificial. *Revista de Investigación Científica de la Universidad Nacional Hermilio Valdizán*. doi:<https://doi.org/10.33554/riv.18.1.2105>
- Medina, M., Rojas, R., Bustamante, W., Loaiza, R., Martel, C., & Castillo, R. (2023). *Metodología de la investigación: Técnicas e instrumentos de investigación*. Instituto Universitario de Innovación, Ciencia y Tecnología Inudi Perú S.A.C. doi:<https://doi.org/10.35622/inudi.b.080>
- Meneses, J. (2021). *El cuestionario*. Ecoe. Retrieved from <https://femrecerca.cat/meneses/publication/cuestionario/cuestionario.pdf>

- Mery, D. (2021). *Visión por Computador*. Santiago de Chile. Retrieved from <https://mialdeatdo.com/wp-content/uploads/2021/01/LIBRO-MAQUETACION.pdf>
- Neupane, A., Shahi, T. B., Koech, R., Walsh, K., & Langat, P. K. (2025). *Nematode detection and classification using machine learning techniques: A review*. *Agronomy*. doi:<https://doi.org/10.3390/agronomy15112481>
- Nielsen, M. A. (2020). *Neuronal networks and deep learning*. Retrieved from <http://neuralnetworksanddeeplearning.com/>
- Palomares Rius, J. E., Cantalapiedra-Navarrete, C., Archidona-Yuste, A., & Castillo, P. (2020). *Barcoding de nematodos fitoparásitos*. Digital.CSIC. Retrieved from <https://digital.csic.es/handle/10261/164108>
- Qin, J., Wang, B., Wu, Y., Lu, Q., & Zhu, H. (2021). *Identifying Pine Wood Nematode Disease Using UAV Images and Deep Learning Algorithms*. *Teledetección*. doi:<https://doi.org/10.3390/rs13020162>
- Reddy, P. P. (2021). *Integrated Nematode Management in Horticultural Crops*. Scientific Publishers. doi:<https://doi.org/10.1007/978-981-16-3241-9>
- Rodríguez-Gomez, D., Fábregues, S., Meneses, J., & Paré, M. H. (2021). *Técnicas de investigación social y educativa*. EDITORIAL UOC. Retrieved from <https://openaccess.uoc.edu/server/api/core/bitstreams/04dfb18e-da36-4091-92e0-29b6ba77e465/content>
- Roth, L., Piepho, H. P., & Hund, A. (2021). *Phenomics data processing: A plot-level model for repeated measurements to extract the timing of key stages and quantities at defined time points*. *Plant, Cell & Environment*. doi:<https://doi.org/10.1111/pce.14051>
- Shabrina, N. H., Lika, R. A., & Indarti, S. (2023). *Deep learning models for automatic identification of plant-parasitic nematode* (Vol. 7). doi:<https://doi.org/10.1016/j.aiia.2022.12.002>

- Stevens, E., Antiga, L., & Viehmann, T. (2020). *Deep learning with Pytorch*. Manning Publications. Retrieved from <https://freecomputerbooks.com/Deep-Learning-with-PyTorch.html>
- Szeliski, R. (2022). *Computer Vision: Algorithms and Applications* (2nd ed.). Springer. Retrieved from <https://szeliski.org/Book/>
- Tarrillo Saldaña, O., Mejía Huamán, J., Dávila Mego, J. S., Pintado Castillo, C. A., Tapia Idrogo, C. E., Chilón Camacho, W. M., & Velez Escobar, S. B. (2024). *Metodología de la investigación una mirada global*. Editorial CID - Centro de Investigación y Desarrollo. doi:https://doi.org/10.37811/cli_w1078
- Teuwen, J., & Moriakov, N. (2020). Convolutional neuronal networks. In *Handbook of medical image computing and computer assisted intervention*. Retrieved from https://www2.cs.uh.edu/~ceick/ai/CNN_Reading_Material.pdf
- Torrallba, A., Isola, P., & Freeman, W. T. (2024). *Foundations of computer vision*. MIT Press. Retrieved from <https://visionbook.mit.edu/>
- Vizcaíno Zúñiga, P. I., Cedeño Cedeño, R. J., & Maldonado Palacios, I. A. (2023). *Metodología de la investigación científica: guía práctica*. doi:https://doi.org/10.37811/cl_rcm.v7i4.7658
- Zhang, A., Lipton, Z. C., Li, M., & Smola, A. J. (2021). Dive into deep learning. Retrieved from https://classic.d2l.ai/chapter_convolutional-neural-networks/index.html

ANEXOS

Anexo A: Asignación de tutor

Anexo A: Asignación de tutor

Universidad Laica Eloy Alfaro de Manabí
Periodo 2025-2 - Notificación de tutor asignado - SOFTWARE 2024 - NS - (EL CARMEN)
Estimad@ Docente y Estudiante Uleam
En cumplimiento de lo establecido en la Ley, el Reglamento de Régimen Académico y las disposiciones estatutarias de la Uleam, por medio de la presente se oficializa la dirección y tutoría en el desarrollo del Trabajo de Integración curricular / Trabajo de Titulación del siguiente estudiante: Tema: SISTEMA DE VISIÓN COMPUTACIONAL BASADO EN CNN PARA EL FENOTIPADO AUTOMÁTICO DE NEMATODOS FITOPARÁSITOS EN EL CULTIVO DE LA GRANJA EXPERIMENTAL ULEAM EL CARMEN
Estado de aprobación: Aprobado
Tipo de titulación: Trabajo de Integración Curricular
Tipo de proyecto: Trabajo de Integración Curricular / Trabajo de titulación se articula con proyectos y programas de Investigación.
Apellidos y nombres del tutor asignado: LOPEZ RODRIGUEZ CARLOS VINICIO
Apellidos y nombres del estudiante: PILATAXI PITA DIEGO RICARDO
Carrera: SOFTWARE 2024 - NS - (EL CARMEN)
Periodo de inducción: Periodo 2025-2

Anexo B: Reporte del sistema antiplagio

Anexo B: Reporte del sistema antiplagio



Anexo C: Fotografías

Anexo C: Fotografía



Fotografía realizando pruebas de funcionamiento del módulo de red neuronal para la detección de plagas

Anexo D: Evidencia de aplicación de encuestas y entrevistas

Anexo D: Evidencia de aplicación de encuestas y entrevistas



Anexo E: Estructura de la entrevista

Anexo E: Estructura de la entrevista

Entrevista

1. ¿Cuáles son los principales desafíos técnicos y de tiempo que se enfrentan actualmente en la Granja Experimental de la ULEAM al realizar el diagnóstico y fenotipado de nematodos fitoparásitos mediante los métodos tradicionales (manuales/visuales)?
2. Desde su perspectiva profesional, ¿cómo afecta la presencia de estos nematodos a los cultivos locales y de qué manera un diagnóstico automatizado y rápido mediante visión artificial cambiaría la estrategia de manejo fitosanitario en la granja?
3. Para que un sistema basado en redes neuronales convolucionales (CNN) sea considerado una herramienta confiable en el día a día agropecuario, ¿qué nivel de precisión o qué criterios específicos exigiría usted para validar sus resultados frente a un análisis de laboratorio convencional?
4. Considerando las dinámicas de trabajo en la granja y el perfil de los estudiantes de Agropecuaria, ¿qué tan preparados observa a los futuros profesionales para integrar herramientas de agricultura de precisión (como este sistema de visión artificial) en sus labores cotidianas?
5. ¿De qué manera considera que el desarrollo de este sistema de fenotipado automático puede sentar las bases para futuras líneas de investigación o proyectos de transferencia tecnológica dentro de la facultad?

Anexo F: Estructura de la encuesta

Anexo F: Estructura de la encuesta

ENCUESTA DE REALIDAD AUMENTADA PARA LA CAPACITACIÓN AGRÍCOLA DEL PLÁTANO

ENCUESTA PARA ESTUDIANTES DE SIO DE AGROPECUARIA

* Este formulario registrará su nombre, escriba su nombre.

11. ¿Qué nivel de conocimiento posee usted sobre el impacto de los nematodos en la morfología radicular del plátano?

- ☐ Conocimiento profundo
- ☐ Conocimiento moderado
- ☐ Conocimiento superficial
- ☐ Ningún conocimiento

12. ¿Cómo califica la frecuencia de observación de daños radiculares causados por nematodos en la Granja Experimental?

- ☐ Frecuencia muy alta
- ☐ Frecuencia moderada
- ☐ Escasa frecuencia
- ☐ Nunca ha observado daños

13. ¿Qué tan complejo le resulta identificar síntomas de nematodos sin recurrir a un análisis de laboratorio?

- ☐ Extremadamente complejo
- ☐ Moderadamente complejo
- ☐ Poco complejo
- ☐ Muy sencillo

14. ¿Considera necesario automatizar el registro de áreas afectadas por nematodos dentro de la granja universitaria?

- ☐ Totalmente necesario
- ☐ Muy necesario
- ☐ Poco necesario
- ☐ Innecesario

15. ¿En qué medida considera que las enfermedades fitosanitarias limitan el aprendizaje práctico en los cultivos de la granja?

- ☐ En gran medida
- ☐ De forma considerable
- ☐ De forma mínima
- ☐ No limitan el aprendizaje

GLOSARIO

Agricultura de Precisión: Enfoque de gestión agrícola que utiliza tecnologías digitales, inteligencia artificial y sensores para optimizar la toma de decisiones, la eficiencia operativa y el manejo fitosanitario en el campo.

Algoritmo: Conjunto ordenado y finito de instrucciones y operaciones computacionales diseñadas para procesar datos, resolver un problema específico o ejecutar un cálculo matemático.

Dataset: Colección estructurada y balanceada de datos (en este contexto, un banco de fotografías de muestras radiculares) empleada para el entrenamiento, validación y evaluación de modelos de inteligencia artificial.

Fenotipado Automático: Identificación y medición automatizada de las características morfológicas y síntomas visibles de un organismo vegetal mediante el uso de tecnologías de visión computacional.

Flutter: Framework de código abierto desarrollado por Google que permite construir aplicaciones multiplataforma compiladas de forma nativa a partir de una única base de código en lenguaje Dart.

Inferencia: Fase del aprendizaje automático en la que un modelo previamente entrenado procesa una entrada de datos desconocida (como un fotograma capturado por la cámara) para generar una predicción o diagnóstico en tiempo real.

Latencia: Intervalo de tiempo transcurrido desde el momento en que se captura una imagen hasta que el motor de inteligencia artificial procesa la matriz numérica y despliega el diagnóstico en pantalla.

Nematodos Fitoparásitos: Microorganismos o gusanos microscópicos que habitan en el suelo y se alimentan del tejido vegetal de las plantas, atacando principalmente el sistema radicular del plátano y reduciendo la absorción de agua y nutrientes.

Precisión: Métrica de rendimiento en aprendizaje automático que representa la proporción de detecciones verdaderamente positivas con respecto al total de predicciones realizadas por el algoritmo.

Red Neuronal Convolutiva (CNN): Arquitectura de aprendizaje profundo especializada en la extracción de patrones espaciales y características visuales dentro de imágenes digitales para tareas de clasificación y detección.

Roboflow: Plataforma orientada a la ingeniería de datos en visión artificial, utilizada para el etiquetado manual, aumentación y exportación estandarizada de datasets de imágenes.

TensorFlow Lite (TFLite): Entorno de ejecución y formato de almacenamiento ligero diseñado para desplegar modelos de redes neuronales optimizados en dispositivos móviles y sistemas embebidos.

Umbral de Confianza: Valor numérico de corte que establece el nivel de certeza mínimo requerido por el modelo para validar una detección y filtrar el ruido visual del entorno.

Visión Artificial: Disciplina de la inteligencia artificial dedicada al desarrollo de algoritmos y sistemas capaces de procesar, interpretar y comprender el contenido visual proveniente de imágenes o videos.

YOLOv8 (You Only Look Once v8): Red neuronal convolutiva de última generación diseñada para la detección y clasificación de objetos en tiempo real, destacada por su velocidad de procesamiento al evaluar la imagen en un único paso algorítmico.