



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

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

TEMA

SISTEMA MÓVIL CON TRANSFER LEARNING PARA DETECCIÓN TEMPRANA DE ARTRÓPODOS FITÓFAGOS EN CULTIVOS DE THEOBROMA CACAO EN LA GRANJA EXPERIMENTAL ULEAM EL CARMEN

**PROYECTO INTEGRADOR
MONITOREO FITOSANITARIO DIGITAL DEL CACAO**

AUTOR
ALCIVAR ZAMBRANO JENY SELENA

DOCENTE TUTOR
ING. REASCOS PINCHAO RAUL SAED, MG.

EL CARMEN, 2026



Uleam

CERTIFICACIÓN DEL DIRECTOR DEL TRABAJO DE TITULACIÓN

	NOMBRE DEL DOCUMENTO: CERTIFICADO DE TUTOR	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 de la estudiante ALCIVAR ZAMBRANO JENY SELENA, legalmente matriculada en la carrera de Ingeniería de Software, período académico 2025(2)-2026(1), cumpliendo el total de 288 horas, cuyo tema del proyecto es "SISTEMA MÓVIL CON TRANSFER LEARNING PARA DETECCIÓN TEMPRANA DE ARTRÓPODOS FITÓFAGOS EN CULTIVOS DE THEOBROMA CACAO EN 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. Saed Reascos Pinchao, Mg.
Docente Tutor
Área: Tecnologías de la Información & Software

TRIBUNAL DE SUSTENTACIÓN



Universidad Laica Eloy Alfaro de Manabí
Extensión El Carmen
Carrera de Ingeniería en Tecnologías de la Información

TRIBUNAL DE SUSTENTACIÓN

Título del Trabajo de Titulación:

Sistema móvil con Transfer Learning para la detección de Artrópodos Fitófagos en cultivos de Theobroma Cacao en la Granja Experimental Uleam El Carmen.

Modalidad:

Proyecto Integrador

Autora:

Alcivar Zambrano Jeny Selena

Tutora:

Ing. Reascos Pinchao Raúl Saed, Mg.

Tribunal de Sustentación:

Presidente: Ing. Minaya Macias Renelmo Wladimir

Miembro: Ing. Arévalo Hermida Rómulo Danilo

Miembro: Ing. Mendoza Villamar Rocio Alexandra

Fecha de Sustentación:

27 de Agosto de 2026

DECLARACIÓN EXPRESA 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 es: **SISTEMA MÓVIL CON TRANSFER LEARNING PARA DETECCIÓN TEMPRANA DE ARTRÓPODOS FITÓFAGOS EN CULTIVOS DE THEOBROMA CACAO EN LA GRANJA EXPERIMENTAL ULEAM EL CARMEN**, corresponde exclusivamente a: **ALCIVAR ZAMBRANO JENY SELENA** con C.I. 1755674932 y los derechos patrimoniales de la misma corresponden a la Universidad Laica Eloy Alfaro de Manabí.



ALCIVAR ZAMBRANO JENY SELENA

C.I. 1755674932

DEDICATORIA

Dedico este trabajo a Dios por tanto amor y permitirme culminar esta etapa.

A mi pareja, Yasmani Solis por siempre apoyarme en todo con amor.

A mi mamá Alexandra Zambrano, por su amor y su ejemplo constante que me impulsan a seguir adelante

A la memoria de mi papá, Manuel Alcivar, aunque ya no esté, le hubiera encantado verme triunfar.

A mi tutor Ing. Saed Reascos por tenerme fe y mucha paciencia.

A mis queridas, María Laaz y Guadalupe Laaz, por siempre darme consejos sabios y brindarme su apoyo en todo momento.

Jeny Alcivar

AGRADECIMIENTOS

Quiero expresar mi agradecimiento primeramente a Jehová Dios, por darme la fortaleza, la sabiduría y la perseverancia necesaria para culminar esta etapa en mi vida, incluso en los momentos de mayor exigencia.

A mi pareja, Yasmani Solis, por su paciencia, comprensión y respaldo constante a lo largo de todo este proceso y por acompañarme con palabras de aliento en cada etapa de este camino.

A mi mamá, por siempre brindarme su apoyo y amor incondicional.

A mi hermana Thalia Gonzales, por sus palabras de ánimo cada vez que sentía que no podía más.

A mi familia y a la familia de mi pareja, por su apoyo incondicional y su motivación constante, siendo siempre un pilar fundamental en cada paso de mi formación profesional.

También a mis compañeras Ana y Lilibeth, por su apoyo y ánimo constante y por hacer de esta una etapa inolvidable, las llevo siempre en mi corazón. Y por supuesto a mis compañeros Alex, Marco, Deivi, a todos mis compañeros.

A los docentes de la Uleam Ext. El Carmen, por compartir sus experiencias y enseñanzas de la mejor manera. En especial al Ing. Saed Reascos por su paciencia y dedicación en la realización de este trabajo de titulación y en todos los semestres, gracias por esas anécdotas que nos inspiran a seguir adelante.

A la Unidad Educativa Nueva Jerusalén del Recinto Simón Bolívar “La Sexta” Quinindé - Esmeraldas, y a todos sus docentes, en especial al Mgtr. José Moreira Ferrin, por su excelencia como docente y como amigo.

A todas las personas que de una u otra manera, contribuyeron con su tiempo, conocimiento o apoyo a la realización de esta investigación.

Y, por último, a mi gatito Apuky, por acompañarme fielmente en cada amanecida de este proceso.

La Autora

ÍNDICE DE CONTENIDO

PORTADA.....	I
CERTIFICACIÓN DEL DIRECTOR DEL TRABAJO DE TITULACIÓN	II
TRIBUNAL DE SUSTENTACIÓN	III
DECLARACIÓN EXPRESA DE AUTORÍA	IV
DEDICATORIA.....	V
AGRADECIMIENTOS.....	VI
ÍNDICE DE CONTENIDO	VII
ÍNDICE DE TABLAS.....	XV
ÍNDICE DE GRÁFICOS E ILUSTRACIONES	XVII
Anexos.....	XVII
RESUMEN	XIX
ABSTRACT	XX
CAPÍTULO I	1
1. INTRODUCCIÓN	1
1.1 Presentación del tema.....	1
1.2 Contextualización de la problemática	1
1.3 Planteamiento del problema	1
1.3.1 Problematización.....	2
1.3.2 Génesis del problema	2
1.3.3 Estado actual del problema.....	2

1.4 Diagrama causa-efecto	3
1.5 Objetivos	4
1.5.1 General	4
1.5.2 Específicos.....	4
1.6 Justificación.....	5
1.7 Impactos esperados	5
CAPÍTULO II.....	7
2. MARCO TEÓRICO	7
2.1 Antecedentes histórico y del estado del arte.....	7
2.2 Investigaciones relacionadas	8
2.2.1 Detección de la plaga sogata a en el cultivo de arroz mediante visión por computadora.	8
2.2.2 Sistema inteligente de reconocimiento de imágenes para apoyar el diagnóstico de plagas y enfermedades en el cultivo de arroz en el departamento de Lambayeque en el año 2019	8
2.2.3 Sistema de Detección de Plagas en la Hoja de Uva en el Departamento de La Libertad (Perú) Usando Algoritmo de Redes Neuronales Convolucionales	9
2.3 Definiciones conceptuales y categorías clave	10
2.3.1 Sistema móvil con Transfer Learning	10
2.3.1.1 Fundamentos del aprendizaje por transferencia.....	10
2.3.1.2 Arquitectura de sistemas móviles para procesamiento de inteligencia artificial.....	11

2.3.1.3 Técnicas de optimización de modelos para su ejecución en dispositivos móviles	12
2.3.1.4 Modelos preentrenados y su adaptación en entornos móviles.....	12
2.3.1.5 Implementación de Transfer Learning con TensorFlow Lite en sistemas móviles	13
2.3.1.6 Evaluación de rendimiento y precisión en sistemas móviles con Transfer Learning.....	13
2.3.1.7 Desafíos y limitaciones de la integración de Transfer Learning en dispositivos móviles	14
2.3.1.8 Aplicaciones del aprendizaje por transferencia en agricultura móvil y otras áreas.....	15
2.3.2 Detección temprana de artrópodos fitófagos en Theobroma cacao	15
2.3.2.1 Importancia de la detección temprana de artrópodos fitófagos para la agricultura.....	16
2.3.2.2 Características biológicas y comportamiento de los artrópodos fitófagos en cultivos de Theobroma Cacao.....	16
2.3.2.3 Métodos tradicionales y tecnológicos para la detección de artrópodos fitófagos en cacao.....	17
2.3.2.4 Uso de imágenes y sensores para la monitorización de cultivos.	18
2.3.2.5 Técnicas de procesamiento de imagen aplicadas a la identificación de artrópodos fitófagos.....	19
2.3.2.6 Implementación de sistemas de alerta temprana en agricultura de precisión	19

2.3.2.7 Aplicación de Inteligencia Artificial para la detección automática de plagas	20
2.3.2.8 Impacto del control temprano de fitófagos en la productividad y salud de cultivos de cacao	21
2.4 Conclusiones del marco teórico	22
CAPÍTULO III.....	24
3. MARCO INVESTIGATIVO	24
3.1 Introducción.....	24
3.2 Tipos y métodos de investigación.....	25
3.3 Fuentes de información.....	26
3.3.1 Fuentes primarias	27
3.3.2 Encuesta.....	27
3.3.3 Entrevista.....	27
3.4 Estrategia de recolección de datos	28
3.4.1 Población.....	28
3.4.2 Muestra.....	28
3.4.3 Análisis de herramientas de recolección de datos a utilizar	29
3.4.3.1 Encuesta.....	29
3.4.3.2 Entrevista	29
3.5 Análisis e interpretación de resultados.....	30
3.5.1. Tabla de la encuesta dirigida a los estudiantes de Agropecuaria de la Uleam extensión El Carmen	30

3.5.2. Tabla de la entrevista.....	34
3.5.3 Interpretación de resultados.....	38
CAPÍTULO IV	40
4. MARCO PROPOSITIVO.....	40
4.1 Introducción.....	40
4.2 Descripción de la propuesta tecnológica.....	40
4.3 Recursos requeridos	41
4.3.1 Recursos humanos.....	41
4.3.2 Recursos Tecnológicos	42
4.3.3 Recursos Económicos	43
4.4 Fases de desarrollo del software	43
4.4.1 Descripción del producto.....	43
4.4.2 Metodología de desarrollo.....	44
4.4.3 Justificación de la metodología Scrum	44
4.4.4 Roles Scrum.....	45
4.4.5 Eventos Scrum	46
4.5 Sprints de desarrollo del módulo de inteligencia artificial.....	47
4.5.1 Sprint 1: Construcción del dataset base y primer entrenamiento	47
4.5.1.1 Objetivo del sprint.....	47
4.5.1.2 Historia de usuario del Sprint 1.....	47
4.5.1.3 Sprint Backlog del Sprint 1.....	48

4.5.1.4 Sprint Review del Sprint 1	48
4.5.1.5 Sprint Retrospective del Sprint 1	48
4.5.1.6 Evidencias del Sprint 1	49
4.5.2 Sprint 2: Incorporación de clase arriera y ampliación de dataset	50
4.5.2.1 Objetivo del sprint.....	50
4.5.2.2 Historia de usuario del Sprint 2.....	50
4.5.2.4 Sprint Review del Sprint 2.....	51
4.5.2.5 Sprint Retrospective del Sprint 2	52
4.5.2.6 Evidencia del Sprint 2	52
4.5.3 Sprint 3: Incorporación de la clase “no_cacao” y configuración del umbral de confianza.....	54
4.5.3.1 Objetivo del sprint.....	54
4.5.3.2 Historia de usuario del Sprint 3.....	54
4.5.3.3 Sprint Backlog del Sprint 3.....	55
4.5.3.4 Sprint Review del Sprint 3.....	55
4.5.3.5 Sprint Retrospective del Sprint 3	55
4.5.3.6 Evidencia del Sprint 3	56
4.5.4 Sprint 4 Exportación e integración del modelo	57
4.5.4.1 Objetivo del sprint.....	57
4.5.4.2 Historia de usuario del Sprint 4.....	57
4.5.4.3 Sprint Backlog del Sprint 4.....	57
4.5.4.4 Sprint Review del Sprint 4.....	58

4.5.4.5 Sprint Retrospective del Sprint 4	58
4.5.4.6 Evidencia del Sprint 4	58
4.5.5 Sprint 5: Pruebas y validación del modelo	59
4.5.5.1 Objetivo del sprint.....	59
4.5.5.2 Historia de usuario del Sprint 5.....	59
4.5.5.3 Sprint Backlog del Sprint 5.....	60
4.5.5.4 Sprint Review del Sprint 5.....	61
4.5.5.5 Sprint Retrospective del Sprint 5	61
4.5.5.6 Evidencias del sprint 5.....	62
4.6 Validación con usuario	62
CAPÍTULO V.....	64
5. EVALUACIÓN DE RESULTADOS.....	64
5.1 Introducción.....	64
5.2 Validación técnica y funcional del producto	64
5.2.1 Validación técnica del modelo	65
5.2.2 Validación funcional.....	67
5.3 Análisis de impacto y resultados obtenidos.....	69
5.3.1 Contraste con la problemática inicial.....	69
5.3.3 Verificación de las causas del problema.....	69
Capítulo VI	71
6. Conclusiones y recomendaciones	71

6.1 Conclusiones.....	71
6.2 Recomendaciones	72
BIBLIOGRAFÍA	73
ANEXOS.....	77
GLOSARIO	83

ÍNDICE DE TABLAS

Tabla 1. Resultados de la encuesta aplicada a estudiantes.....	30
Tabla 2. Entrevista dirigida al Ing. Pedro Eduardo Nivelá Morante	34
Tabla 3. Recursos humanos.....	41
Tabla 4. Recursos tecnológicos Hardware	42
Tabla 5. Recursos tecnológicos -Software	42
Tabla 6. Recursos Económicos.....	43
Tabla 7. Roles Scrum.....	45
Tabla 8. Eventos Scrum	46
Tabla 9. HU-01 Detección de plagas mediante fotografías	47
Tabla 10. Sprint Backlog del Sprint 1.....	48
Tabla 11. Sprint Review Sprint 1	48
Tabla 12. Sprint Retrospective del Sprint 1	48
Tabla 13. HU-02 Resultado claro de clasificación	50
Tabla 14. Sprint backlog del Sprint 2	51
Tabla 15. Sprint Review del Sprint 2.....	51
Tabla 16. Sprint Retrospective del Sprint 2	52
Tabla 17, HU-03 Validación de imagen de entrada	54
Tabla 18. Sprint backlog del Sprint 3	55
Tabla 19. Sprint Review del Sprint 3.....	55
Tabla 20. Sprint Retrospective del Sprint 3	55
Tabla 21. HU-03 Funcionamiento offline.....	57
Tabla 22. Sprint backlog del Sprint 4	57
Tabla 23. Sprint Review del Sprint 4.....	58
Tabla 24. Sprint Retrospective del Sprint 4	58

Tabla 25. HU-05 Interfaz simple e intuitiva	59
Tabla 26. HU-06 Diagnóstico Rápido	60
Tabla 27. Sprint backlog del Sprint 5	60
Tabla 28. Sprint Review del Sprint 5.....	61
Tabla 29. Sprint Retrospective del Sprint 5	61
Tabla 30. Métricas de precisión exhaustiva y F1-score por clase	66
Tabla 31. Resultados de las pruebas de integración funcional del modelo en dispositivos Android.....	68

ÍNDICE DE GRÁFICOS E ILUSTRACIONES

Figura 1 Diagrama Causa- Efecto	3
Figura 2 Clases	49
Figura 3. Primer entrenamiento.....	49
Figura 4 Primer funcionamiento del modelo	50
Figura 5. Aumento de clase Arriera.....	52
Figura 6. Reentrenamiento con el dataset ampliado.....	53
Figura 7 Clase arriera implementada.....	53
Figura 8 Se añadió clase No Cacao	56
Figura 9 Clase no cacao funcionando.....	56
Figura 10 Conversión de modelo a .tflite	58
Figura 11 Modelo .tflite Entregado	59
Figura 12 Interfaz adaptada a una pantalla de móvil.....	62
Figura 13. Matriz de confusión del modelo de clasificación de artrópodos fitófagos	66

Anexos

Anexo A Asignación de docente tutor.....	77
Anexo B. Primer entrenamiento.....	78
Anexo C Etiquetado de clases.....	78
Anexo D Reentrenamiento del modelo.....	79
Anexo E Pruebas de funcionamiento.....	79
Anexo F pruebas de funcionamiento	79
Anexo G Prueba de funcionamiento en interfaz para móvil	80
Anexo H Capturando imágenes para el dataset.....	80
Anexo I Realizando entrenamiento al modelo	81

Anexo J Entrevista al Ing. Pedro Nivelá.....	81
Anexo K. Certificado de coincidencia académica.....	82

RESUMEN

La revisión visual del cultivo de *Theobroma cacao* en la Granja Experimental Uleam Extensión El Carmen presenta limitaciones que retrasan la detección de artrópodos fitófagos, favoreciendo la propagación de plagas y afectando la calidad y el rendimiento. Ante esta situación, la investigación tuvo como propósito diseñar e implementar un sistema móvil, basado en transferencia de aprendizaje, capaz de reconocer plagas en hojas de cacao en tiempo real y bajo condiciones de recursos tecnológicos limitados. El estudio se desarrolló con enfoque principalmente cuantitativo, complementado con información cualitativa obtenida mediante una encuesta aplicada a 32 estudiantes de una población de 389 estudiantes y una entrevista realizada a un ingeniero docente. En el componente técnico se utilizó la arquitectura MobileNetV2 ajustada mediante transfer learning, entrenada con 1743 imágenes procedentes de campo y de repositorios de acceso abierto, organizadas bajo la metodología Scrum en cinco Sprints. El modelo se exportó en formato TensorFlow Lite en una aplicación móvil desarrollada en Flutter, alcanzando una exactitud de 97.33% sobre un conjunto de validación depurado y permitiendo clasificar seis categorías, cuatro de plagas y dos de identificación sano y no cacao. Las pruebas en un dispositivo Android confirman su funcionamiento sin conexión a internet, ofreciendo al agricultor un diagnóstico rápido y confiable que ayuda a complementar la inspección visual tradicional.

Palabras clave: transferencia de aprendizaje, MobileNetV2, artrópodos fitófagos, aplicación móvil, cacao, monitoreo fitosanitario.

ABSTRACT

The visual inspection of *Theobroma cacao* cultivation at the Uleam Experimental Farm Extension El Carmen presents limitations that delay the detection of phytophagous arthropods, favoring the spread of pests and affecting quality and yield. Given this situation, the research aimed to design and implement a mobile system, based on transfer learning, capable of recognizing pests on cocoa leaves in real-time and under conditions of limited technological resources. The study was conducted with a primarily quantitative approach, complemented by qualitative information obtained thru a survey applied to 32 students from a population of 389 students and an interview conducted with a teaching engineer. In the technical component, the MobileNetV2 architecture was used, adjusted thru transfer learning, trained with 1,743 images from the field and open-access repositories, organized under the Scrum methodology in five Sprints. The model was exported in TensorFlow Lite format into a mobile application developed in Flutter, achieving an accuracy of 97.33% on a refined validation set and allowing the classification of six categories, four for pests and two for identifying healthy and non-cacao. Tests on an Android device confirm its functionality without an internet connection, offering the farmer a quick and reliable diagnosis that helps complement traditional visual inspection.

Keywords: transfer learning, MobileNetV2, phytophagous arthropods, mobile application, cocoa, phytosanitary monitoring.

CAPÍTULO I

1. INTRODUCCIÓN

En la actualidad la inteligencia artificial se ha vuelto una herramienta fundamental, tanto en empresas como en la vida cotidiana, en este documento se demostró que la inteligencia artificial también se puede utilizar en la agricultura. Para ello utilizó los modelos de redes neuronales (CNN) junto con los conocimientos de la agricultura.

1.1 Presentación del tema

La presente investigación se centra en el Módulo 1: Entrenamiento IA plagas, cuyo propósito es construir y validar un modelo de aprendizaje profundo que identifique artrópodos-fitófagos en tiempo real y bajo recursos limitados, con el fin de reducir el tiempo de respuesta frente a infestaciones y mejorar la toma de decisiones en campo. Por esto, es de mi agrado presentar mi tema: Sistema Móvil con Transfer Learning para detección temprana de Artrópodos Fitófagos en cultivos de Theobroma Cacao en La Granja Experimental Uleam El Carmen

1.2 Contextualización de la problemática

En la Granja experimental de la Uleam Extensión El Carmen, se ha identificado que, en los cultivos de cacao, las plagas como Mirídidos (*Distantiella theobroma*), cochinilla escamosa (*Coccus viridis*), hormiga arriera (*Atta cephalotes*) y barrenadores de frutos (*Charaxera cacaoensis*), son los principales causantes de pérdidas del cultivo, afectando a la rentabilidad del cultivo a los agricultores.

1.3 Planteamiento del problema

El problema radica en que la detección de plagas en cultivo de Theobroma cacao se realiza tarde, cuando las infestaciones ya están bastante avanzadas, esto permite que las

poblaciones de artrópodos fitófagos se desarrollen sin control y provoquen daños importantes en las plantas de cacao. Al no contar con un diagnóstico oportuno, se dificulta mucho la aplicación temprana de medidas de manejo que podrían reducir las pérdidas y hacer más eficiente el control de plagas.

1.3.1 Problematicación

¿Qué diseñar para detectar artrópodos fitófagos en cacao en condiciones reales de campo, optimizando la precisión y velocidad de inferencia sin requerir infraestructura de cómputo pesado?

1.3.2 Génesis del problema

El retraso en la detección de artrópodos fitófagos en cacao data de la crisis de 1920, cuando la moniliasis y escoba de bruja devastaron más del 70% de la producción sin métodos tempranos. Entre 1980 y 2000 se volvió a un control químico reactivo, notable a la vista. La falta de inversión en tecnologías de monitoreo, la resistencia cultural y la fragmentación institucional impidieron sistemas preventivos. Esto generó pérdidas del 30–60% de la cosecha, limitando recursos para mejorar la vigilancia y perpetuando métodos obsoletos.

1.3.3 Estado actual del problema

En el cultivo de cacao la revisión fitosanitaria de artrópodos fitófagos continúa realizándose, en la mayoría de los casos, mediante recorridos manuales cada dos a cuatro semanas. Esta frecuencia de inspección hace que muchas plagas se detecten cuando el daño ya es evidente en hojas, brotes y frutos momento en el cual ya es difícil revertir el daño.

En Ecuador se han identificado al menos 23 especies de insectos que se alimentan de tejido del cacao y que pueden alcanzar incidencias cercanas al 90% en plantaciones afectadas, con reducciones estimadas entre el 30 y 60% de la producción según distintos estudios técnicos.

Algunos productores no cuentan con formación sólida en manejo integrado de plagas y recurren principalmente a aplicación de químicos reactivos, cuando el daño ya está demasiado avanzado.

Actualmente en la Granja Experimental El Carmen, no se cuenta con un sistema de monitoreo digital accesible para la vigilancia temprana de estos artrópodos fitófagos en cacao, por lo que el control sigue dependiendo de observaciones manuales y a su vez el uso de frecuente de productos químicos. Esta situación mantiene un círculo de detección tardía, costos altos de control y riesgo constante para la sostenibilidad de las plantaciones.

1.4 Diagrama causa-efecto

Figura 1 Diagrama Causa- Efecto



1.5 Objetivos

1.5.1 General

Diseñar e implementar sistema móvil con Transfer Learning para detectar en tiempo real artrópodos fitófagos en Theobroma cacao bajo recursos limitados en la Granja Experimental de la ULEAM-El CARMEN

1.5.2 Específicos

- Analizar la investigación más reciente para demostrar con datos sólidos que CNN con Transfer Learning es ahora, la alternativa técnica más adecuada para identificar artrópodos fitófagos en cultivos de cacao.
- Documentar en las parcelas de cacao de la Granja Experimental El Carmen, durante cuatro semanas consecutivas, la presencia real y distribución espacial de artrópodos fitófagos mediante captura fotográfica y registro agronómico paralelo, a fin de alimentar y corroborar con datos primarios el desempeño del modelo CNN en condiciones reales de cultivo.
- Construir un dataset de imágenes de hojas de cacao, clasificado en categorías de plagas (ácaros, arrieras, chinches, trips), hojas sanas y elementos que no pertenezcan al cultivo, que sirva como base para el entrenamiento del modelo de inteligencia artificial.
- Desarrollar un sistema de detección temprana de artrópodos fitófagos en cultivos de Theobroma cacao que permita al agricultor capturar una sola fotografía con la cámara de su teléfono inteligente y, en menos de 10 segundos, junto con una recomendación fitosanitaria práctica.
- Evaluar el desempeño del modelo de clasificación y realizar una prueba piloto de usabilidad en campo con un usuario dedicado al cultivo de cacao, para identificar aspectos de mejora en la interacción y el flujo de la aplicación en un entorno real de producción.

1.6 Justificación

Los cultivos de cacao son vulnerables a las plagas y cuando el daño se detecta, se compromete tanto con la producción como la calidad del fruto. La revisión de las plantas suele realizarse de forma visual y con métodos tradicionales, lo que puede retrasar el diagnóstico y limitar la información disponible para decidir qué hacer en el campo. En este contexto, un sistema móvil que utiliza inteligencia artificial para reconocer plagas en hojas de cacao a partir de una fotografía se plantea como una alternativa práctica para apoyar la detección temprana directamente en la parcela.

La finalidad de implementar esta tecnología es que el agricultor cuente con un aviso claro y oportuno sobre el estado de la planta, de manera que pueda organizar mejor el manejo fitosanitario y reducir el riesgo de pérdidas por diagnósticos tardíos. Al mismo tiempo el uso de la aplicación contribuye a orientar de forma responsable del empleo del insumo, evitando aplicaciones de insecticidas que no sean necesarias. A nivel local la propuesta genera un impacto positivo en la Granja Experimental El Carmen, al ofrecer un apoyo adicional en la identificación de plagas y agilizar los procesos de revisión en las parcelas. Para la universidad el desarrollo y puesta en marcha del sistema muestra que es posible llevar herramientas digitales al ámbito agrícola y convertirlas en recursos concretos para la enseñanza, la extensión y la innovación.

1.7 Impactos esperados

Tecnológico: Al implementar un sistema con transfer learning se optimiza tiempo, ya que se reutilizan modelos pre-entrenados, permitiendo que se entrene solo las últimas capas para obtener los resultados de acuerdo a este proyecto, gracias a esto, se obtienen sistemas accesibles aun si se dispone de un hardware limitado. Se introduce un prototipo de aplicación con IA embebida, que da apertura a futuras mejoras y escalabilidad para otros cultivos.

Social: Al utilizar esta herramienta en el sector agrícola, se fomenta a utilizar este tipo de tecnologías, ya que no sería necesario tanto equipo tecnológico de costos elevados. Fomenta el uso de redes neuronales en empresas pequeñas o en sectores productivos, demostrando que la tecnología es el ahora, sin tanta necesidad de capacitación de técnicos ya que los agricultores aprenden a familiarizarse con herramientas digitales.

Ecológico : Al utilizar transfer learning se optimiza el entrenamiento desde cero, ya que se menciona que entrenar modelos de IA desde cero, consume mucha energía, entonces al utilizar transfer learning se minimiza el consumo energético. Además, como se obtendrá una detección temprana de plagas, se minimiza en gran manera el uso de grandes cantidades y tipos de pesticidas, reduciendo en aplicación de fitosanitarios químicos, obteniendo menor contaminación de suelos y agua y obteniendo conservación de la biodiversidad en la finca.

CAPÍTULO II

2. MARCO TEÓRICO

2.1 Antecedentes histórico y del estado del arte

La inteligencia Artificial ha cambiado la forma en la que interactuamos con el mundo. Creando gran impacto en muchas áreas como la salud, la economía, la comunicación, la educación y una muy importante, la agricultura debido a que esta área suministra los alimentos y exporta grandes cantidades de materia prima.

La visión por computadora es fundamental en el origen de la Inteligencia Artificial ya que esta está muy presente en el desarrollo del aprendizaje automático y la inteligencia artificial. El origen de la Inteligencia Artificial se planteó desde mediados del siglo XX, su objetivo era que las computadoras pudieran imitar el comportamiento del ser humano(Renza Torres & Ballesteros, 2023).

Por otra parte, la agricultura y la inteligencia artificial juntas son una herramienta muy buena. La agricultura por su parte es una ocupación desde tiempos ancestrales en la humanidad siendo así enseñada de generación en generación, organizando las labores del campo mediante la observación directa del clima, los ciclos del suelo y los comportamientos de los cultivos.

En la actualidad, la inteligencia artificial y la agricultura no están completamente ligadas, ya que el sector agricultor al ser muy tradicional, tiene mucha resistencia a los cambios, entonces esto frena mucho el avance de esta poderosa unión, permitiendo así la optimización de tiempo y recursos.

2.2 Investigaciones relacionadas

En los siguientes trabajos de tesis, se evidencia el uso de herramientas como la Inteligencia Artificial en el área de la agricultura.

2.2.1 Detección de la plaga sogataa en el cultivo de arroz mediante visión por computadora.

Mediante el proyecto realizado y la utilización del algoritmo de visión por computadora yolov5 se permitió detectar la plaga sogata en el cultivo de arroz, dando como resultado la identificación de la misma, mediante la comparación de imágenes precargadas y de esa manera mostrar datos que indiquen la presencia de la plaga sogata (Galan Zapata, 2021).

Esta investigación está dirigida al cultivo de arroz y a la detección de una plaga en específico la sogata que afecta a la producción de arroz, en Ecuador en la provincia del Guayas, en el cantón Daule, en la hacienda Ing. René Regato. La presente investigación de este documento pues está dirigida a los cultivos de cacao en Ecuador en la provincia de Manabí El Carmen, en la granja experimental de la Uleam, con el propósito de ayudar a los agricultores a optimizar su tiempo y evitar pérdidas en los cultivos.

2.2.2 Sistema inteligente de reconocimiento de imágenes para apoyar el diagnóstico de plagas y enfermedades en el cultivo de arroz en el departamento de Lambayeque en el año 2019

Se desarrolló un sistema inteligente implementando una aplicación móvil apoyado del modelo de reconocimiento de imágenes, esta aplicación toma imágenes de las plagas y enfermedades trayendo como respuesta los resultados del diagnóstico, es decir que enfermedad o plaga se encontró, como agregado importante la aplicación cumple con los listado de puntos en donde se tomó la imagen y una visión más clara con porcentajes de severidad, grado

respectivo, recomendaciones medicinales y costos incluidos, para llevar un diagnóstico general de su campo (Jefferson, 2021).

Esta investigación va dirigida a la detección temprana de plagas y enfermedades en el cultivo de arroz, utilizando una aplicación móvil, entrenada con un modelo de reconocimiento de imágenes en Perú, lo que la diferencia de la presente investigación de este documento es que esta está dirigida a las plantaciones de cacao en Ecuador, Manabí El Carmen, en la granja experimental de la Uleam para beneficio de los agricultores.

2.2.3 Sistema de Detección de Plagas en la Hoja de Uva en el Departamento de La Libertad (Perú) Usando Algoritmo de Redes Neuronales Convolucionales

Se utilizó el algoritmo de CNN para el desarrollo de la solución de reconocimiento de plagas en la planta de uva. Este algoritmo ha sido ser entrenado con un conjunto de datos de imágenes de uvas sanas y afectadas por plagas. Como se puede ver en la figura 137 y el algoritmo CNN fue el más adecuado por su precisión de 97.22% lo que nos permite concluir que cumple con el objetivo de seleccionar el mejor algoritmo de reconocimiento de imágenes para reconocer la plaga en la hoja de uva (Chavez Human y Del Castillo Flores, 2023).

Esta investigación está dirigida a las plantaciones de Uva en Perú, abordando la detección manual de las plagas en las plantas de uvas. Por otro lado, la presente investigación, está dirigida a plantaciones de Cacao en Ecuador, Manabí, específicamente en la Granja experimental de la Uleam, así mismo con el objetivo optimizar el tiempo y dinero a los agricultores.

Como resultado de estas investigaciones de Farfan y Guevara, Jefferson y Chavez Human y Del Castillo Flores, podemos ver que enfatizan la precisión más del 95% lo cual nos lleva a que efectivamente al utilizar herramientas como las redes neuronales sí ayudan a optimizar el tiempo y dinero, beneficiando a los agricultores.

2.3 Definiciones conceptuales y categorías clave

2.3.1 Sistema móvil con Transfer Learning

Un sistema móvil con Transfer Learning es una aplicación diseñada para ejecutarse en dispositivos móviles que incorporan modelos de inteligencia artificial previamente entrenados y adaptados a nuevas tareas. Esta técnica permite que el dispositivo realice tareas complejas de reconocimiento y clasificación sin depender de una conexión constante a internet (Mingxing y Le, 2019).

2.3.1.1 Fundamentos del aprendizaje por transferencia

El aprendizaje por transferencia es parte del conjunto de técnicas que se utilizan en el aprendizaje automático, con el cual podemos reutilizar el conocimiento para resolver tareas nuevas con la condición que sean similares a la tarea original. Permitiendo así que se economice recursos, más aún cuando no se tiene muchos datos para una nueva tarea (Bazan Yaranga et al., 2018)

Para poder utilizar el aprendizaje por transferencia se debe utilizar un modelo que ya esté pre-entrenado ya que, con el patrón ya aprendido, es menos complicado adaptar una tarea nueva a una tarea original aun si esta nueva tarea tiene mucha diferencia tanto en las características o la estadística. Es muy similar al aprendizaje de los humanos, suelen aplicar su experiencia obtenida en otros desafíos o problemas y la aplican de una manera similar, únicamente se adaptaría a la nueva situación. (Yang et al., 2020)

El aprendizaje por transferencia se utiliza de dos formas:

Uso de modelos preentrenados._ Los modelos pre-entrenado consisten en solo reemplazar las ultimas capas, manteniendo la información que ya se ha obtenido de la tarea o problema anterior. Permitiendo que se le pueda adaptar las ultimas capas a la nueva tarea o problemática.

Sintonización de la red convolucional. _ Esta trata sobre las mismas capas, solamente que se utiliza un proceso llamado backpropagation, el cual consiste en ajustar las capas más profundas con información de las últimas capas, para que este pueda tener más bases y las respuestas sean más verídicas o más confiables, en otras palabras, le hace un refinamiento.

El aprendizaje por transferencia tiene como propósito mejorar el desempeño de la función predictiva en el dominio objetivo haciendo uso del conocimiento extraído del dominio fuente. Como ya hemos mencionado la ventaja principal del aprendizaje por transferencia es que tiene una capacidad muy alta de hacerle frente a la situación de no contar con muchos datos, ya que, pues suele ser complejo recolectarlos o cuesta mucho dinero obtenerlos, aquí es donde la transferencia de aprendizaje juega su mejor papel, optimizando y permitiendo que los algoritmos sean adaptables en situaciones que están en constante cambio. (Yang et al., 2020)

2.3.1.2 Arquitectura de sistemas móviles para procesamiento de inteligencia artificial.

La arquitectura de sistemas móviles es el conjunto de técnicas, herramientas y modelos que ayudan al desarrollo de aplicaciones móviles, con el fin de que la aplicación o sistema que se va a desarrollar sea estable y se pueda modificar frente a errores, que su duración sea larga, con el fin de ir adaptando más después actualizaciones. Al aplicar las reglas y técnicas, se logra llegar a que los desarrolladores del proyecto tengan la facilidad de poder modificar ciertas partes del proyecto sin que se desconfigure o descomponga todo el proyecto.

Los sistemas móviles tienen diferentes unidades de memoria como CPU, GPU y NPU estas utilizan modelos de entre 8 bits a 4 bits, ahorrando la energía del dispositivo móvil, manteniendo un buen rendimiento sin que se pierda la precisión.

Por otra parte, los diseños en capas son beneficiosos por que permiten que los datos de la información fluyan de una manera secuencial. Primero sensores, segundo preprocesamiento, tercero inferencias y cuarto posprocesamiento. Todo el sistema debe funcionar dentro de 5W, es decir que no debe generar más de 5 vatios de calor.

2.3.1.3 Técnicas de optimización de modelos para su ejecución en dispositivos móviles

La optimización de modelos de IA para dispositivos móviles trata sobre comprimir el modelo, sin alterar su capacidad de precisión. Como bien se sabe los dispositivos móviles tienen limitaciones, una de ellas es la poca memoria, la duración de la batería e incluso sus procesadores no se comparan a la fuerza de un servidor(Peng et al., 2024)

Una de las técnicas que se usa para optimizar el modelo de IA es la cuantización, la factorización de matrices y la poda. La cuantización reduce la precisión numérica de los pesos y activaciones (32 bits a 8 bits), la factorización de matrices las capas más densas las descompone en matrices más pequeñas luego ordenar los cálculos para que sea más efectivo, la poda como su nombre lo dice, se deshace de las partes del modelo que no aportan mucho.

Gracias a estas técnicas se logra transformar en un modelo más ligero sin que baje el porcentaje de precisión en tiempo real sobre celulares, sin importar si estás online u offline(Reda et al., 2022)

2.3.1.4 Modelos preentrenados y su adaptación en entornos móviles

Los modelos preentrenados son CNN(redes neuronales) que han sido entrenadas anteriormente con un volumen significativo de información, sirven para ejecutar nuevas tareas. Las arquitecturas MobileNet y EfficientNet se recomiendan bastante debido a su nivel de precisión y eficiencia computacional, haciéndolas aptas para ser utilizadas en dispositivos móviles (Ismail et al., 2021).

MobileNet cuenta con varias versiones (MobileNetV1,V2,V3) esta arquitectura tiene como base las convoluciones depthwise, las cuales se encargan de separar la obtención espacial de rasgos, permitiendo que se reduzca grandemente la cantidad de operaciones y parámetros. Gracias a estas características MobileNet funciona de una manera muy optima y eficiente en dispositivos móviles de gama media y gama baja, permitiendo que las tareas de detección y clasificación de objetos (Mingxing y Le, 2019)

2.3.1.5 Implementación de Transfer Learning con TensorFlow Lite en sistemas móviles

Implementando el modelo transfer learning a un teléfono móvil se debe transformar una el modelo pre-entrenado a un modelo más ligero que no necesite siempre estar conectado a un servidor, por aquello es que Tensor Flow Lite es en este proyecto una herramienta clave, conteniendo API y herramientas para poder utilizar en Android sin necesidad de tanto consumo energético y con baja latencia, para convertir el modelo se utiliza una herramienta llamada: TFLiteConverter, la cual se encarga de transformar el modelo previamente guardado en un archivo .tflite que es más liviano para hardware limitado, en este caso teléfonos móviles de gama media a gama baja. (Cuevas-Tello et al., 2022)

Primero se debe seleccionar un modelo entrenado y ajustarlo a un conjunto de datos propios sobre lo que se desea entrenar, por ejemplo, clasificar imágenes de hojas de cacao con plagas y sin plagas. Una vez hecho este entrenamiento se va a convertir al formato .tflite para luego ser exportado a la aplicación móvil donde TensorFlow será el encargado de recibir los datos, en este caso se encargaría de recibir una foto hecha por la cámara y ya se encargaría de devolver una alerta, mensaje sobre la imagen. Haciendo que esto funcione de manera rápida, segura y sin conexión, como sabemos este tipo de cosas son las que necesitamos en el campo debido a que muchas veces no hay señal ni internet. (iMaster, s.f.)

2.3.1.6 Evaluación de rendimiento y precisión en sistemas móviles con Transfer Learning

Los sistemas móviles que tienen integrados modelos de Deep learning mediante Transfer learning integran métricas clásicas de precisión obteniendo indicadores del dispositivo como el consumo de energía del dispositivo móvil, el uso de su memoria, tiempo de respuesta, entre otros. Esta es una prueba que se debe realizar en un dispositivo móvil mientras se mide el tiempo que se demora en procesar una entrada. Al hacer estas verificaciones se comprueba

si el modelo está bien entrenado y si puede dar respuestas en tiempo real sin saturar el rendimiento del móvil. (Sharma, 2022)

Al utilizar modelos de transfer learning en dispositivos móviles se deben combinar la rapidez y la precisión de resultados, donde los modelos más livianos demuestran menos tiempo de espera a comparación de los modelos que contienen modelos más profundos, aunque son más precisos, consumen más recursos computacionales. Varias investigaciones mencionan que tanto la precisión y la rapidez son esenciales al momento de elegir un modelo que sea adecuado en este caso, para el sector agrícola se necesita resultados que sean confiables y rápidos para así poder tomar una decisión con fundamentos. (Alotaibi et al., 2024)

2.3.1.7 Desafíos y limitaciones de la integración de Transfer Learning en dispositivos móviles

Los modelos de Deep Learning con Transfer Learning que se integran a dispositivos móviles, encuentran siempre algunas limitaciones de hardware como por ejemplo el almacenamiento limitado, ya que al no estar conectados a un servidor en tiempo real los datos se deben almacenar en la memoria del teléfono. Por otro lado, los modelos pre-entrenados cuentan con muchos parámetros y suelen requerir operaciones intensivas, debido a esto cuando se ejecuta en un teléfono, genera lentitud al momento de cargar el programa, consume mucha batería y no suele cargar por falta de la memoria RAM. Debido a esto se ve obligado a utilizar técnicas de compresión y optimización como por ejemplo la poda de parámetros, gracias a esta técnica y otras más Transfer Learning resulta muy buena en dispositivos móviles que contiene recursos limitados. (Alireza y Rashid, 2025)

Aparte de las restricciones de hardware el transfer learning al utilizarse en dispositivos móviles tiene desafíos que se relacionan con el dominio de datos y la capacidad de este para actualizarse en el campo. Al existir diferencias de dominios tanto en el que fue entrenado el modelo base como el dominio del objetivo, baja el rendimiento por las variaciones de

distribución y a la aparición de sesgos, más que algunos dispositivos carecen de recursos para ser ajustados localmente, esto obliga a que se diseñen estrategias tanto para el proceso local como el proceso de la nube. (Yildiz et al., 2024)

2.3.1.8 Aplicaciones del aprendizaje por transferencia en agricultura móvil y otras áreas

El aprendizaje por transferencia es clave para desarrollar aplicaciones de diagnóstico como en este caso plagas. Gracias a que el modelo es pre-entrenado se reduce el volumen de datos y hace más rápido el entrenamiento, permitiendo que se den soluciones más accesibles para los agricultores con recursos limitados. Varias investigaciones demuestran que los modelos que utilizan transfer learning si alcanzan un gran porcentaje de confiabilidad para identificar insectos, el estado de la hoja y el estado del cultivo. (Kamilaris et al., 2022)

Últimamente hay muchas aplicaciones que contienen modelos de Deep learning con Transfer learning que realizan diagnósticos en tiempo real con imágenes sacadas con un teléfono, dándole a los agricultores una herramienta que permite fotografiar hojas, insectos, entre otros, permitiendo que se muestre una notificación sobre lo que contiene la planta ya sea enfermedad o plaga aun sin estar conectado a una red de internet, demostrando la eficiencia y la eficacia de ese modelo de (CNN) red neuronal. (Utomo et al., 2023)

2.3.2 Detección temprana de artrópodos fitófagos en Theobroma cacao

Detectar a tiempo los artrópodos que se alimentan del cacao es clave, se trata de identificar insectos o ácaros en las primeras etapas de la infestación, antes de que hagan daños irreversibles en hojas, brotes, mazorcas o flores. Esta practica ayuda a reducir perdidas económicas y a usar menos insecticidas, ya que permite actuar de forma localizada y en el momento justo (Afoakwa, 2016).

2.3.2.1 Importancia de la detección temprana de artrópodos fitófagos para la agricultura

Los artrópodos fitófagos en el cultivo de cacao son uno de los principales causantes de las pérdidas, el bajo rendimiento y la baja calidad del grano, siendo la detección temprana un componente indispensable en el manejo fitosanitario. Las plagas del cacao más problemáticas como los miridos, los insectos perforadores de mazorcas y los barrenadores de brotes reducen significativamente la producción cuando no son detectados a tiempo. A través del tiempo, se ha llegado a la conclusión de que al detectar a tiempo una plaga hace que se consuma menos químicos, reduciendo el impacto ambiental, lo cual ayuda a que se proteja la salud de los ecosistemas agrícolas. (Afoakwa, 2016)

Centrándonos en el cacao muchos investigadores han llegado a la conclusión de que, a la falta de monitoreo de plagas, es muy costoso el control y pone en riesgo la rentabilidad del cultivo. Existen investigaciones donde se describe que en las plantaciones que no tiene un control adecuado las plagas pueden persistir hasta varios ciclos de producción, haciendo que la planta se deteriore más rápido haciendo que la estabilidad del producto tambalee. (Research, 2017)

2.3.2.2 Características biológicas y comportamiento de los artrópodos fitófagos en cultivos de Theobroma Cacao

Los artrópodos fitófagos en el cultivo de Theobroma cacao son diversos insectos y ácaros que se alimentan de las hojas, flores, brotes, mazorcas las cuales tienen ciclos biológicos que se adaptan a las condiciones climáticas de la plantación. Algunas investigaciones técnicas describen que hay un número muy grande de especies de insectos, pero solo unas cuantas se consideran plagas económicas como los miridos, los barrenadores de brotes y troncos, las orugas defoliadoras y los perforadores de mazorca. Estos artrópodos suelen presentar fases de

desarrollo como huevos. Varios estudios ninfales, larvales u adulto los cuales se alimentan de tejidos de la planta.(Guastella et al., 2017)

El comportamiento de las plagas de cacao tiene ciertos hábitos de alimentación y de oviposición las cuales ayudan al momento de detectar las plagas en el cultivo. Como ejemplo tenemos que ciertos barrenadores de mazorca ponen sus huevecillos en frutos tiernos cuando casi no hay iluminación y las larvas completan en casi todo su ciclo de desarrollo, estando dentro del fruto siendo muy difícil de detectar cuando recién está iniciando la infestación. Los miridos también infectan de una manera muy parecida, ellos buscan las partes tiernas de la planta, donde hay sombras y al ser tan pequeños, el rastro que dejan suelen ser puntos, los cuales son un poco difícil de detectar si no se revisa minuciosamente, por lo tanto, debemos tratar de entender como es cada plaga para así poder diseñar estrategias para tener un mejor control. (Baudoin, 2005)

2.3.2.3 Métodos tradicionales y tecnológicos para la detección de artrópodos fitófagos en cacao

Como ya se sabe la agricultura viene de tiempos ancestrales por ende en el cultivo de cacao las revisiones se hacen manualmente, inspección directa, recorridos por todo el campo y muestreos periódicos que hacen los agricultores o a su vez los técnicos especializados. Unos de los métodos de inspección manual son: el conteo de insectos en la planta, también la revisión de la mazorca, viendo si tiene manchas o agujeros, también si esta deforme o si las mazorcas se caen antes de estar listas para cortar. Estos métodos casi no tienen costo y no requieren de un equipo de inspección grande, pero esto realmente depende en su mayoría de la experiencia del encargado de este trabajo y suele ser poco eficiente en cultivos grandes o en etapas tempranas, poniendo en riesgo la subestimación del problema.(Saul-Maora et al., 2017)

Actualmente nos encontramos en una era digital, donde se implementa tecnología para muchas cosas y la agricultura no es la excepción, se están empezando a implementar métodos

tecnológicos que ayuden a complementar la inspección visual, por ejemplo, el uso de “trampas” con herramientas geoespaciales que mapean la presencia de las plagas. Existen manuales técnicos para la detección de plagas que hablan sobre las trampas para estas plagas, por ejemplo, la trampa de luz, trampas con cebos para capturar a artrópodos, también existen formularios electrónicos, sistemas de posicionamiento global y plataformas que permiten almacenar y analizar información que ha sido recolectada en el campo. Aunque su implementación aún está un poco inaccesible por factores externos como el acceso a la tecnología o simplemente que los agricultores no quieren cambiar sus métodos tradicionales. (Baudoin, 2005)

2.3.2.4 Uso de imágenes y sensores para la monitorización de cultivos.

En los últimos años, muchos agricultores han hecho su seguimiento a sus cultivos a través de imágenes. En vez de solo defender de lo que se puede observar al caminar por el cultivo, con la tecnología ahora se puede utilizar imágenes tomadas de diferentes ángulos, por ejemplo, imágenes satelitales que cubren una plantación enorme, o imágenes sacadas con drones, también imágenes sacadas con cámaras que están muy cerca de la plantación, gracias a estas imágenes se pueden comparar entre sí y así poder detectar en que parte está siendo más afectado el cultivo. En cultivos como el cacao usar imágenes multiespectrales y ver la evolución temporal sirve para detectar cambios sutiles en las hojas y el vigor del cultivo. Es una forma de tener alertas tempranas por si aparecen plagas o cualquier otra cosa que nos pueda arruinar la cosecha.(Food and Agriculture Organization of the United Nations, 2017)

Aparte de las imágenes también en la agricultura se usan sensores que van instalados en la tierra directamente para poder medir ciertas cosas como la humedad del suelo, la temperatura y la luz del sol, al instalar varios por todo el cultivo, esto permite que se vean los cambios de condiciones en cada punto permitiendo que sea más comprensible como se mueven

o actúan las plagas Si se hace una correcta instalación de estos sensores se obtendría un reporte de en qué parte es más probable que aparezca una plaga en el cultivo.(Tezanos-Pinto, 2023)

2.3.2.5 Técnicas de procesamiento de imagen aplicadas a la identificación de artrópodos fitófagos

Para poder identificar artrópodos fitófagos a través de imágenes, lo primordial es hacer la segmentación de imágenes, luego debemos identificar cuáles son los atributos más relevantes de la plaga, la silueta, la tonalidad, aquellos rasgos son transformados a vectores de características que después las procesa un algoritmo encargado de clasificar para luego agregar una etiqueta específica del artrópodo fitófago. Entonces así ya se podría saber en qué parte está ubicado y que parte es la más afectada. (Deenan, 2024)

Luego de ya estar segmentada la imagen, se procede a extraer las características del artrópodo fitófago o la parte dañada mediante medidas de color, su textura y forma para que pueda detectar atropados, enfermedades y hojas sanas. Un ejemplo, se calculan histogramas de color tanto en los espacios RGB como HSV. Además, se extraen descriptores de forma a partir de los contornos, del área y de la relación ancho y alto. Para la textura se emplean técnicas como las matrices de co-ocurrencia de niveles de gris (GLCM) o filtros de Gabor, que permiten identificar los patrones finos en la superficie de la hoja o del cuerpo del insecto. Aquellas características son usadas en algoritmos que se encargan de clasificar e integran en un mismo modelo las etapas de extracción y clasificación, permitiendo identificar automáticamente la presencia y el tipo de artrópodo fitófago en las imágenes del cultivo. (Agrawal y Navneet, 2025)

2.3.2.6 Implementación de sistemas de alerta temprana en agricultura de precisión

La implementación de sistema de alerta está basada en la recopilación de información del cultivo y a su vez el ambiente de este para lograr identificar problemas antes de que sea

tarde y se den las grandes pérdidas. Un ejemplo de esto sería una estación meteorológica, se encarga de recopilar la humedad del suelo, humedad relativa ,temperatura y radiación. Estos datos se procesan mediante algoritmos, modelos de estadísticas, para así hacer una predicción del desarrollo de plagas y enfermedades. Una vez que el riesgo supera los límites establecidos por los técnicos, este sistema emite una alerta al productor, lo cual le permite poder aplicar medidas de prevención. (Alabrese, 2023)

En el monitoreo de artrópodos fitófagos, los sistemas combinan información que es extraída de trampas inteligentes, de las imágenes del cultivo y de variables climáticas que permiten la detección temprana de las plagas y a su vez predice los brotes que se pueden suscitar en el futuro. Una parte de los desarrollos recientes manejan modelos que analizan una serie de tiempo de factores como temperatura, humedad, desarrollo de cultivo y lluvia, que se asocian para generar mapas de riesgos y alertas tempranas sobre zonas que tienen alta probabilidad de brotes de plagas (Organization, 2022). Las alertas son enviadas al agricultor ya sea en una aplicación móvil o una aplicación web, facilitando la toma de decisiones y a su vez reduciendo en gran manera el uso excesivo de pesticidas.

2.3.2.7 Aplicación de Inteligencia Artificial para la detección automática de plagas

La implementación de inteligencia artificial en la Agricultura es una herramienta muy valiosa ya que se destaca por analizar grandes volúmenes de datos que son extraídos de las imágenes. Los modelos de Deep learning y aprendizaje automático se han demostrado que tienen una capacidad muy buena para reconocer patrones que son complejos en imágenes de hojas, frutos o insectos, detectando de manera rápida y automática la presencia de plagas dependiendo el color, la textura o el síntoma de la planta. Varios estudios han demostrado que la implementación de redes neuronales convolucionales y otros modelos de visión por computadora, tienen la capacidad de alcanzar niveles altos de precisión en la detección y clasificación de insectos y enfermedades en los cultivos, lo cual convierte esta herramienta en

una visión al futuro de la agricultura ya que es adecuada para desarrollar aplicaciones de monitoreo fitosanitario casi en tiempo real. (Chakrabarty et al., 2026)

La aplicación de la inteligencia artificial con la agricultura de precisión da paso a que la detección de plagas se realice a través de la captura de imágenes con un dispositivo móvil, redes de sensores, por drones, etc. La Aplicación de IA en la detección automática de plagas, tiene como base la capacidad de aprendizaje y mejorar su desempeño con el transcurso del tiempo, permitiendo así que se pueda ir adaptando distintas condiciones de iluminación, etapas de desarrollo del insecto o del daño de la planta. Al implementar esta herramienta con un dispositivo móvil se obtiene facilidad al recibir los resultados para los agricultores. (Barra, 2025)

2.3.2.8 Impacto del control temprano de fitófagos en la productividad y salud de cultivos de cacao

Tratar a tiempo las plagas es fundamental para que la producción de cacao sea buena, ya que evita daños y si ya existe el daño, evita que se extienda a más partes de la planta, como las flores, la mazorca y las partes vitales de la planta, que son esenciales para el crecimiento de la planta. Cuando los artrópodos se detectan a tiempo, se pueden aplicar soluciones específicas y que sean amigables con el medio ambiente y con la planta, permitiendo que el grano salga de buena calidad y las plantas estén libres de estrés, siendo un cultivo sano y productivo a largo plazo. (Muñoz Quijano, 2018)

Por otro lado, si la detección no se realiza a tiempo, los daños se acumulan y como resultado se obtiene consecuencias con un costo muy alto para el productor, No solo afecta al bolsillo del agricultor sino también a la plantación, ya que las plantas pueden llegar a su descenso en su totalidad. En el cultivo de cacao se hace notorio porque baja su productividad produciendo números bajos de mazorcas sanas, y el uso de pesticidas aumenta. Por aquello detectar el peligro a tiempo evita muchas consecuencias desfavorables.

2.4 Conclusiones del marco teórico

Al desarrollar el marco teórico deja en claro que juntar el aprendizaje por transferencia, la visión por computadora, las aplicaciones móviles y la Agricultura, son un equipo muy sólido para resolver problemas en el campo, en la cual se exige identificar anomalías de forma rápida y sin errores. Para este proyecto el equipo de herramientas antes mencionadas es un combo espectacular, ya que el entorno del cultivo cambia mucho, visualmente es un enredo y el agricultor necesita respuesta concretas y rápidas para no perder su cultivo. Con todas las investigaciones realizadas sale a relucir que usar modelos preentrenados es la mejor opción, ya que tendríamos una base sólida para construir el reconocimiento automático sin necesidad de entrenar un modelo desde cero, ahorrando tiempo, recursos del computador y la necesidad de conseguir miles de imágenes etiquetadas.

También llegamos a la conclusión de que no sirve de nada que el modelo sea super preciso si no va a poder funcionar en un dispositivo que tenga recursos limitados, por aquello utilizar la optimización, achicar modelos y usar arquitecturas ligeras es fundamental para que la aplicación responda de manera eficaz, sin saturar la memoria y a su vez es fácil de llevar a todos lados.

Por otro lado, analizando detenidamente el problema de los artrópodos fitófagos, comprendemos que detectar a tiempo estos insectos es vital para proteger la producción y la salud del cultivo. Si estos insectos son detectados a tiempo, se puede aplicar medidas de control suaves, evitando utilizar dosis altas de pesticidas, protegiendo flores, mazorca y ramas de la planta.

Finalmente, el marco teórico establece una base firme para justificar el desarrollo de una aplicación móvil con redes neuronales, el proyecto se sostiene firme en la fusión de la agricultura de precisión, la inteligencia artificial y la tecnología, lo que otorga pertinencia académica y aplicabilidad práctica. Así este marco teórico no solo respalda la investigación,

sino que también guía su desarrollo metodológico y técnico a una innovadora solución para el sector agrícola en especial a los agricultores dedicados a la producción del cacao.

CAPÍTULO III

3. MARCO INVESTIGATIVO

3.1 Introducción

En el presente capítulo se describe el marco investigativo y el diseño metodológico que orientan el desarrollo de la investigación sobre la detección de plagas en cultivos de cacao mediante la arquitectura MobileNetV2 y técnicas de transfer learning. Se detalla el enfoque de la investigación, el tipo de estudio, los métodos teóricos y empíricos empleados, las fuentes de información consultadas, la estrategia de recolección de datos y las técnicas utilizadas para el análisis e interpretación de los resultados. De esta manera se establece el procedimiento sistemático que permite dar respuestas al problema planteado y alcanzar los objetivos formulados en los capítulos anteriores.

La metodología propuesta combina un componente técnico, centrado en el entrenamiento y evaluación de MobileNetV2 para la clasificación de imágenes de hojas con y sin presencia de plagas, con el componente aplicado en el contexto académico, orientado a conocer la percepción de los estudiantes sobre el monitoreo fitosanitario y el uso de herramientas tecnológicas de apoyo. Para ello, se emplean instrumentos como una encuesta de diagnóstico y una entrevista semiestructurada, dirigida a estudiantes y docentes vinculados al área, con el fin de identificar sus conocimientos, experiencias y dificultades en relación con la detección de plagas y el uso de soluciones basadas en inteligencia artificial.

En este capítulo se representa, en primer lugar, el tipo y la metodología de investigación, tanto teórico como empíricos, que sustentan el estudio, destacando el enfoque cuantitativo predominante y el apoyo de técnicas cualitativas para complementar la interpretación de los resultados. A continuación, se describen las fuentes de información primarias y secundarias que sirven de base para la fundamentación científica del proyecto, incluyendo literatura

especializada en Deep learning, MobileNetV2 y aplicaciones de visión por computadora en el ámbito agrícola.

Posteriormente, se expone la estrategia de recolección de datos, donde se especifican la población y la muestra de estudiantes participantes, los instrumentos empleados los cuales son cuestionario de encuesta y guía de entrevista y el procedimiento seguido para su aplicación. Finalmente se detallan las técnicas de análisis e interpretación de los resultados, tanto para las métricas obtenidas a partir del modelo MobileNetV2 como para las respuestas de la encuesta y entrevista, lo que permite integrar la perspectiva técnica y la perspectiva académica de la evaluación de la propuesta planteada.

3.2 Tipos y métodos de investigación

La presente investigación se desarrolla bajo un enfoque cuantitativo con apoyo cualitativo, dado que el componente principal del estudio se centra en el análisis de datos numéricos obtenidos del entrenamiento y la evaluación del modelo MobileNetV2, así como en los resultados de la encuesta aplicada a los estudiantes participantes. El enfoque cualitativo se incorpora de manera complementaria mediante una entrevista realizada a un ingeniero docente, la cual permite profundizar en la interpretación de los resultados y aportar una visión experta sobre el problema de estudio.

En cuanto al tipo de investigación, el estudio de carácter aplicado, por que busca desarrollar una solución tecnológica basada en técnicas de transfer learning con MobileNetV2 para apoyar la detección de plagas en el cultivo de cacao. Igualmente, el estudio tiene un alcance descriptivo, porque se centra en mostrar cómo se comporta el modelo ante las imágenes que se presentan y también en recoger la forma en que los usuarios perciben y realizan el monitoreo fitosanitario, así como su relación con el uso de herramientas tecnológicas. El diseño de la investigación es no experimental y de corte transversal por lo que no se modifican de

manera intencional las condiciones del entorno, sino que se observa la situación en un momento específico y se analizan los datos recogidos en ese periodo.

Para la fundamentación conceptual y la construcción del marco teórico se emplean diversos métodos teóricos. Entre ellos, el método análisis síntesis, que permite descomponer el problema en sus elementos esenciales, tipos de plagas, características visuales de las hojas, estructura de MobileNetV2, en dispositivos móviles. Finalmente, los métodos deductivos e inductivo facilitan, por un lado, la aplicación de principios generales del aprendizaje profundo al caso específico del cacao y, por otra parte, la formulación de conclusiones a partir de los resultados obtenidos en los experimentos y en los instrumentos aplicados.

En la fase práctica del estudio se recurre a diversos métodos empíricos, los cuales permiten obtener información directa del contexto investigado. Entre ellos se encuentran la observación, utilizada para identificar y registrar las características visuales de las hojas de cacao que presentan o no la presencia de plagas, la experimentación, que se materializa en el entrenamiento, validación y prueba del modelo MobileNetV2 con el conjunto de imágenes recolectadas, la encuesta, aplicada a 32 estudiantes para recabar datos cuantitativos sobre sus conocimientos y percepciones en relación con el monitoreo fitosanitario. Finalmente, la entrevista a un ingeniero docente complementa estos resultados al aportar una visión experta que contribuye a contextualizar los hallazgos y a fortalecer la interpretación de la información obtenida.

3.3 Fuentes de información

Para el desarrollo de la presente investigación se utilizaron fuentes de información primarias y secundarias, con el propósito de sustentar teóricamente el estudio y obtener datos directos que permitan analizar el problema planteado desde una perspectiva técnica y contextual. La combinación de ambas fuentes proporciona una base sólida para el diseño,

implementación y evaluación de la propuesta de detección de plagas en cacao mediante MobileNetV2.

3.3.1 Fuentes primarias

Las fuentes primarias están constituidas por los datos recolectados de manera directa en el contexto de la investigación. En este estudio, dicha fuente proviene de la aplicación de una encuesta a estudiantes y una entrevista realizadas para el entrenamiento y validación del modelo MobileNetV2, junto con los resultados obtenidos en el proceso experimental.

3.3.2 Encuesta

La encuesta es una técnica de recolección de datos que consiste en aplicar un cuestionario estructurado a un grupo de personas con el fin de obtener información estandarizada sobre sus opiniones, características o comportamientos. Se apoya en preguntas previamente diseñadas y en un procedimiento uniforme de aplicación, lo que permite cuantificar las respuestas y analizarlas estadísticamente a partir de una muestra representativa de la población (SGA UNEMI, s. f.).

La encuesta aplicada a 32 estudiantes permitió recopilar información sobre sus conocimientos, percepciones y experiencias relacionadas con el monitoreo fitosanitario del cacao y el uso de herramientas tecnológicas para la detección de plagas. Este instrumento facilitó la obtención de datos cuantitativos que posteriormente fueron analizados mediante frecuencias y porcentajes.

3.3.3 Entrevista

La entrevista es una técnica de recolección de datos cualitativos en la que el investigador utiliza una guía de preguntas previamente elaborada, pero con flexibilidad para formular preguntas adicionales o modificar el orden de las mismas, con el propósito de profundizar en las respuestas del entrevistado. Este tipo de entrevista permite explorar en

detalles experiencias, percepciones y significados, manteniendo al mismo tiempo un marco temático común entre los distintos participantes (Gutiérrez, 2024).

La entrevista realizada al ingeniero docente aportó una visión técnica y especializada sobre la problemática investigada. A través de este instrumento se obtuvo información cualitativa complementaria, orientada a profundidad en la interpretación del problema en la viabilidad de una solución basada en inteligencia artificial.

3.4 Estrategia de recolección de datos

Para llevar a cabo la investigación fue necesario diseñar un procedimiento que permitiera reunir información adecuada en cuanto a calidad, cantidad y relevancia. Con este propósito se determinaron los criterios para definir la población, la muestra y las herramientas que se emplearon para recolectar los datos, manteniendo siempre una relación lógica entre lo que se busca resolver y la información que se necesita. Gracias a esto se llevo a cabo un trabajo de forma organizada, permitiendo obtener datos organizados.

3.4.1 Población

La población de estudio estuvo conformada por 389 estudiantes de la granja experimental vinculados al contexto académico en el que se desarrolló la investigación, quienes participaron como informantes en el levantamiento de datos mediante encuesta. Además, se consideró como parte de la investigación a un ingeniero docente quien fue entrevistado ya que su experiencia técnica permitió complementar la información obtenida.

3.4.2 Muestra

La muestra estuvo conformada por 32 estudiantes seleccionados para la aplicación de la encuesta mediante Google Forms y por un ingeniero docente entrevistado de manera presencial. La técnica de muestreo que se aplicó fue de no probabilística por conveniencia ya que los participantes no se eligieron al azar, sino según su disponibilidad en el momento de

aplicar los instrumentos. Se invito a responder la encuesta a los estudiantes que manifestaron interés ya que estos estudiantes han tenido contacto directo con la Granja de la Uleam El Carmen con actividades relacionadas con el cultivo de cacao, por lo que representan adecuadamente el perfil de futuros profesionales que podrían utilizar o promover soluciones tecnológicas de monitoreo fitosanitario. Este tipo de muestreo se considera adecuado para estudios de carácter exploratorio como el presente, porque permite obtener información de forma práctica y rápida sin necesidad de un listado completo de toda la población.

3.4.3 Análisis de herramientas de recolección de datos a utilizar

Para el desarrollo de la investigación se utilizaron dos herramientas principales de recolección de datos: la encuesta y la entrevista. Ambas permitieron obtener información complementaria, una desde una perspectiva cuantitativa y otra desde una perspectiva cualitativa, enriqueciendo así el análisis global del problema investigado.

3.4.3.1 Encuesta

La encuesta fue aplicada a través de Google Forms a 32 estudiantes de diferentes semestres. Esta herramienta se diseñó con preguntas cerradas dirigidas a los estudiantes con el objetivo de conocer que tanto saben sobre el monitoreo fitosanitario en cacao y como perciben el uso de herramientas tecnológicas para detectar plagas. A su vez también esta encuesta permitió ver de manera clara los patrones más repetidos y las tendencias generales presentes en la muestra.

3.4.3.2 Entrevista

La entrevista realizada de manera presencial al ingeniero docente Pedro Eduardo Nivelá Morante, con conocimientos en el área de estudio. La guía de entrevista estuvo estructurada en tres módulos los cuales son: identificación de plagas y síntomas de daños, factores de entorno que favorecen a las plagas y limitaciones del monitoreo tradicional junto


con oportunidades digitales. Este instrumento permitió obtener información más profunda y especializada sobre la problemática investigada, así como criterios técnicos relacionados con la pertinencia de desarrollar soluciones basadas en inteligencia artificial para el monitoreo de plagas en cacao. Las respuestas obtenidas sirvieron como complemento a la información recabada mediante la encuesta y aportaron una visión experta para la interpretación de los resultados.



3.5 Análisis e interpretación de resultados



3.5.1. Tabla de la encuesta dirigida a los estudiantes de Agropecuaria de la Uleam extensión El Carmen

En la Tabla 1 se muestran los resultados obtenidos en la encuesta realizada a los estudiantes de la granja experimental Uleam El Carmen.


Tabla 1. Resultados de la encuesta aplicada a estudiantes.

Preguntas	Respuestas	Interpretación
01. ¿Al revisar su cultivo de cacao usa solo la vista para revisar las plantas?	 ● Si 19 ● No 13 41% 59%	La mayoría de encuestados afirma depender exclusivamente de la inspección visual para evaluar el estado de sus plantas. Esto evidencia una falta de herramientas tecnológicas o métodos técnicos complementarios para el monitoreo del cultivo, limitando la detección temprana de plagas.

Preguntas	Respuestas	Interpretación
02. ¿Fumiga, aunque no vea bichos solo por prevenir?	 ● Si 17 ● No 6 ● Aceves 9	Los resultados muestran que, en muchos casos, se tiende a fumigar de manera preventiva, incluso cuando no ha confirmado la presencia de plagas. Sin embargo, también hay participantes que indicaron que solo aplican fumigación en ciertos momentos o cuando consideran que realmente es necesario.
03. ¿Le ha pasado que dos personas ven la misma planta, pero ambos notan cosas diferentes?	 ● Si 30 ● No 2	La mayoría indica que existe discrepancia en las observaciones visuales de una misma planta. Este resultado resalta la alta subjetividad del diagnóstico netamente visual, lo que puede inducir a errores o diagnósticos inconsistentes sobre el estado fitosanitario.
04. ¿En la granja hay pocas personas para revisar las plantas?	 ● Si 16 ● No 16	Se observa una división equitativa respecto a la disponibilidad de personal. Esto significa que, mientras la mitad de los productores cuenta con mano de obra suficiente, la otra mitad no cuenta con personal para esta importante actividad.

Preguntas	Respuestas	Interpretación									
05. ¿Ha visto que el personal que revisa las plantas no tiene entrenamiento para reconocer plagas?	● Si 26 ● No 6  <table border="1"> <thead> <tr> <th>Respuesta</th> <th>Cantidad</th> <th>Porcentaje</th> </tr> </thead> <tbody> <tr> <td>Si</td> <td>26</td> <td>81%</td> </tr> <tr> <td>No</td> <td>6</td> <td>19%</td> </tr> </tbody> </table>	Respuesta	Cantidad	Porcentaje	Si	26	81%	No	6	19%	La mayoría de los estudiantes han visto que el personal que revisa las plantas en la Granja Experimental no cuenta con una capacitación formal en identificación de plagas. Esto significa que las infestaciones suelen detectarse cuando ya han avanzado y causado daños a gran escala.
Respuesta	Cantidad	Porcentaje									
Si	26	81%									
No	6	19%									
06. ¿Ha visto que sea difícil encontrar personal capacitado para identificar plagas en el cacao?	● Si 19 ● No 13  <table border="1"> <thead> <tr> <th>Respuesta</th> <th>Cantidad</th> <th>Porcentaje</th> </tr> </thead> <tbody> <tr> <td>Si</td> <td>19</td> <td>59%</td> </tr> <tr> <td>No</td> <td>13</td> <td>41%</td> </tr> </tbody> </table>	Respuesta	Cantidad	Porcentaje	Si	19	59%	No	13	41%	Los estudiantes han visto que es difícil encontrar personal totalmente capacitado para identificar rápidamente las plagas en la granja, lo que confirma la escasez de mano de obra cualificada en el sector, retrasando las acciones de control.
Respuesta	Cantidad	Porcentaje									
Si	19	59%									
No	13	41%									
07. ¿Ha visto trabajadores que solo revisen plagas en la Granja Experimental?	● Si 6 ● No 26  <table border="1"> <thead> <tr> <th>Respuesta</th> <th>Cantidad</th> <th>Porcentaje</th> </tr> </thead> <tbody> <tr> <td>Si</td> <td>6</td> <td>19%</td> </tr> <tr> <td>No</td> <td>26</td> <td>81%</td> </tr> </tbody> </table>	Respuesta	Cantidad	Porcentaje	Si	6	19%	No	26	81%	La mayoría de los estudiantes no ha visto trabajadores dedicados exclusivamente al control de plagas en la Granja experimental. Esto indica que el monitoreo fitosanitario es una tarea secundaria, compartida con otras labores agrícolas, lo que le resta eficiencia a la supervisión.
Respuesta	Cantidad	Porcentaje									
Si	6	19%									
No	26	81%									

Preguntas	Respuestas	Interpretación									
08. ¿Ha notado que falta personal para revisar plagas por falta de dinero?	● Si 19 ● No 13  <table border="1"> <thead> <tr> <th>Respuesta</th> <th>Cantidad</th> <th>Porcentaje</th> </tr> </thead> <tbody> <tr> <td>Si</td> <td>19</td> <td>59%</td> </tr> <tr> <td>No</td> <td>13</td> <td>41%</td> </tr> </tbody> </table>	Respuesta	Cantidad	Porcentaje	Si	19	59%	No	13	41%	En su mayoría los estudiantes han notado que la ausencia de personal especializado para el monitoreo no se debe a desinterés, sino a la limitaciones de presupuesto. Existe una necesidad latente de mejora la supervisión técnica, pero se ve frenada por la falta de recursos económicos en la Granja experimental.
Respuesta	Cantidad	Porcentaje									
Si	19	59%									
No	13	41%									
09. ¿Ha visto que se gasta más en pesticidas que en contratar personal para revisar plagas a tiempo?	● Si 18 ● No 14  <table border="1"> <thead> <tr> <th>Respuesta</th> <th>Cantidad</th> <th>Porcentaje</th> </tr> </thead> <tbody> <tr> <td>Si</td> <td>18</td> <td>56%</td> </tr> <tr> <td>No</td> <td>14</td> <td>44%</td> </tr> </tbody> </table>	Respuesta	Cantidad	Porcentaje	Si	18	56%	No	14	44%	Los estudiantes han observado una tendencia mayoritaria a priorizar el gasto en insumos químicos antes que en la contratación de personal para inspección. Esto refleja una cultura de manejo agrícola reactiva, donde se prefiere invertir directamente en pesticidas en lugar de prevenir mediante monitoreo
Respuesta	Cantidad	Porcentaje									
Si	18	56%									
No	14	44%									

Preguntas	Respuestas	Interpretación
10. ¿Se ha dado cuenta que fumigar sin necesidad enferma las plantas?	 ● Si 23 ● No 9 72% 28%	La mayoría de los productores es totalmente consciente de los efectos negativos y del daño fitosanitario que causa el uso indiscriminado o injustificado de agroquímicos. Este reconocimiento justifica la urgencia de adoptar herramientas de diagnóstico más precisa que ayuden a evitar aplicaciones innecesarias que perjudiquen la salud del cultivo.

3.5.2. Tabla de la entrevista

En la Tabla 2 se detallan las respuestas obtenidas en la entrevista realizada al Ing. Pedro Nivelá, docente en la granja experimental.

Tabla 2. Entrevista dirigida al Ing. Pedro Eduardo Nivelá Morante

Pregunta	Respuesta	Interpretación
01. En su experiencia con el cultivo de cacao en El Carmen, ¿cuáles son los insectos, ácaros o larvas que más daño están causando actualmente	En el cacao hay diversas plagas importantes, entre ellas hormigas arrieras, pulgones y también se han detectado langostas, y señaló que es necesario identificar correctamente el agente causal antes de aplicar un programa de control.	La respuesta evidencia que el cultivo presenta varias plagas de impacto económico y que su identificación temprana es fundamental para un manejo adecuado. Lo que respalda el uso de una herramienta basada en visión artificial para apoyar la identificación automática de plagas.

Pregunta	Respuesta	Interpretación
02. ¿Cómo se ven las hojas o los frutos en los primeros días de ataque de esas plagas?	En los primeros días de ataque, los síntomas más frecuentes son daños producidos por insectos masticadores, minadores, trazadores, los cuales dejan galerías, cortan las plántulas o generan afectaciones visibles en hojas y frutos. Señaló que, con base en esos signos, es posible determinar el agente causal.	La respuesta demuestra que las plagas generan síntomas tempranos visibles, aunque no siempre fáciles de identificar a simple vista, como galerías, cortes o daños por masticación. Esto confirma que el monitoreo visual requiere experiencia para reconocer el tipo de plaga, por lo que una herramienta de apoyo basada en visión artificial puede ayudar a detectar esos signos de manera más rápida y precisa.
03. ¿Cuánto tiempo tarda una plaga en multiplicarse lo suficiente como para empezar a causar pérdidas económicas?	La multiplicación de las plagas depende de su estado evolutivo y que los mayores brotes suelen presentarse en las transiciones de estación, especialmente cuando termina el verano y comienza el invierno. El ingeniero indico que en el lapso de un mes los huevecillos eclosionan por lo tanto ese el tiempo estimado para producir brotes importantes de insectos.	La respuesta del ingeniero muestra que el aumento de las plagas va de la mano con los cambios de clima, lo cual pone en alerta a los agricultores creando la necesidad de vigilar el cultivo de manera frecuente, ya que en un mes que no lo revise este ya estaría infestado y empezaría a causar pérdidas económicas desde ya.
04. ¿Podría decirse que los niveles de humedad, temperatura o altitud hacen que estas plagas se reproduzcan más rápido o se dispersen con facilidad?	Claro, sí, porque la humedad, la temperatura, la altitud, incluso las fases lunares y el estado evolutivo de la planta son indicadores que favorecen o limitan el desarrollo de plagas y enfermedades, especialmente de insectos.	La respuesta confirma que las plagas no se reproducen de manera aislada, sino en función de las condiciones ambientales y del estado de la planta. Esto respalda la necesidad de considerar variables como clima, latitud y fenología del cultivo en el monitoreo, y justifica el uso de herramientas tecnológicas para anticipar momentos de mayor riesgo de aparición y multiplicación de insectos plaga.

Pregunta	Respuesta	Interpretación
05. Dado que en El Carmen llueve mucho y hace calor casi todo el año, ¿eso hace que las plantas sean más vulnerables a las plagas? ¿Por qué?	Si, debido a la alta humedad y el calor constante en el Carmen, las plantas se vuelven más vulnerables a las plagas, ya que al aumentar la población de cacao también aparecen más individuos susceptibles a las enfermedades y ataques.	Esto significa que las condiciones climáticas de la zona favorecen la presencia de plagas, pero también que el aumento de la plantación hace más evidente la aparición de plantas débiles o susceptibles. En otras palabras, mientras más crece la población del cultivo, mayor es la probabilidad de que se presenten problemas fitosanitarios, porque eso se vuelve necesario un control más constante.
06. ¿Un cacao con mucho follaje o sin podas adecuadas crea condiciones que ayudan a que las plagas se escondan o se reproduzcan más?	Claro si, por que un cacao con mucho follaje o sin poda adecuada genera más humedad y un microclima favorable para que las plagas y enfermedades se desarrollen.	Esto significa que la falta de poda y el exceso de follaje crean condiciones propicias para que las plagas se escondan y se reproduzcan con mayor facilidad. Por eso, el manejo del cultivo es importante para reducir la humedad interna y evitar un ambiente favorable para su aparición.
07. Cuando se inspecciona una plantación grande a simple vista, ¿qué es lo más difícil de detectar?	El problema más fuerte son las arrieras y pulgones, para evitar aquello se trabaja con un manejo integrado del cultivo para evitar brotes de plagas y enfermedades, iniciando los protocolos antes de la llegada de las lluvias.	Esto demuestra que la prevención es una parte fundamental del manejo del cultivo, porque al anticiparse A las lluvias se reducen las condiciones que favorecen la aparición de plagas y enfermedades. También se deja ver que las podas y el control fitosanitario no se hacen de forma improvisada, Sino como parte de una planificación para disminuir los brotes, Especialmente frente a los problemas más frecuentes como los pulgones y las hormigas arrieras.

Pregunta	Respuesta	Interpretación
08. ¿Cómo afectan la experiencia del observador, el tamaño de la parcela y la rapidez con que se mueven las plagas a la precisión del monitoreo tradicional?	El tamaño de la parcela y la rapidez con la que se mueven las plagas si afecta la precisión de la detección, porque muchas veces los insectos trabajan más en la noche y eso dificulta encontrar la plaga a tiempo. También no todos los insectos son dañinos ya que algunos como ciertas mosquitas cumplen la función de polinizar el cacao. Por eso aplicar insecticidas sin cuidado puede eliminar tanto como polinizadores. Lo que obliga a definir mejor el momento ideal del control y trabajar con un programa de manejo fitosanitario.	Esto muestra que la detección de plagas no depende sólo de observar el cultivo sino también de conocer el comportamiento de los insectos y las condiciones del momento. La respuesta del ingeniero deja ver que existe un equilibrio delicado entre controlar insectos perjudiciales y proteger a los polinizadores, por lo que es necesario un manejo más técnico y planificado para evitar errores que afecten la producción del cacao.
09. ¿Qué ventajas concretas podría tener un sistema que use inteligencia artificial para identificar plagas y distinguir entre insectos dañinos y benéficos, comparado con la revisión visual actual?	Un sistema con inteligencia artificial sería útil porque ayudaría a preservar los polinizadores y distinguir entre insectos buenos y malos, algo que muchas veces nos identifica bien por desconocimiento o por malas prácticas. Además, le permitiría determinar la población de cada tipo de insecto y aplicar control sólo cuando la plaga llegue a un porcentaje significativo es decir cuando realmente se justifique hacerlo.	Esto demuestra que una herramienta basada en inteligencia artificial podría hacer más precisa la detección de plagas y evitar controles innecesarios que afecten a los insectos beneficiosos. En este sentido, el sistema no sólo mejoraría el manejo fitosanitario, sino que también ayudaría a tomar decisiones más técnicas, oportunas y sostenibles en el cultivo de cacao.

Pregunta	Respuesta	Interpretación
10. ¿Qué prácticas de Manejo Integrado de Plagas (MIP) recomendaría automatizar o priorizar en un sistema digital para interrumpir el ciclo de vida de la plaga antes de que crezca?	Lo más práctico para evitar brotes es priorizar el manejo de las podas, porque en con ellas se pueden cortar los ciclos evolutivos de plagas y enfermedades. Señaló que la poda no se hace por estética sino para bajar la humedad relativa y la humedad interna del cultivo, eliminar posibles brotes de insectos y evitar que con las lluvias eclosionen y causen problemas. También las tecnologías deben ir dirigidas a apoyar este manejo integral del cultivo y el programa Fitosanitario.	Esto significa que, para interrumpir el ciclo de vida de las plagas antes que se desarrollen, una plataforma digital debería dar prioridad al monitoreo y programación de podas como medidas preventivas. La idea es que la tecnología no sólo sirva para detectar plagas sino también para ayudar a reducir las condiciones que favorecen su aparición especialmente la humedad y los brotes provocados por las lluvias.

3.5.3 Interpretación de resultados

Según la pregunta 01 de la encuesta, los estudiantes indicaron que en la granja experimental para revisar el cultivo de cacao se usa solo la vista para observar la planta. La pregunta 03 muestra discrepancia en las revisiones visuales de la misma planta, lo que evidencia que el diagnostico visual es subjetivo, y la pregunta 01 de la entrevista en el cual el Ing. Pedro Nivelá menciona que la detección de plaga puede complicarse porque muchas veces no se identifican a tiempo y que incluso algunas observaciones deben hacerse en la noche se demuestra que la causa del problema 1 que señala que el monitoreo se realiza mediante la vista sin su parte digital es verdadera, indica que la inspección visual sola no es suficiente para una detección temprana efectiva.

Según la pregunta 05 de la encuesta, los estudiantes han visto que el personal que revisa las plantas en la granja experimental no ha recibido una capacitación formal para reconocer plagas dañinas. La pregunta 06 indica que cuesta encontrar personal capacitado para identificar plagas. La pregunta 07 indicó que los estudiantes no han visto trabajadores que se dediquen solo a revisar plagas en la granja, y en la pregunta 02 de la entrevista, en la cual el Ing. Pedro

Nivela menciona que no todos los insectos son malignos y que algunos cumplen funciones como la polinización, demuestra que la causa del problema 2, que señala la falta de personal técnico capacitado en la identificación rápida de artrópodos en campo, es verdadera, debido a que la ausencia de capacitación y de personal especializado dificulta el reconocimiento correcto de plagas y enfermedades.

Según la pregunta 08 de la encuesta, los estudiantes han notado que la falta de personal para revisar brotes de plagas se debe a limitaciones de presupuesto, y la pregunta 09 indica que han visto en la granja experimental se prioriza el gasto en pesticidas antes que en contratar personal capacitado para el monitoreo, y en la pregunta 03 de la entrevista, en la cual el Ing. Pedro Nivela menciona que es necesario aplicar controles solo cuando exista un porcentaje significativo de plaga, se demuestra que la causa del problema 03, que señala los limitados recursos económicos para contratar personal dedicado exclusivamente al monitoreo, es verdadera, ya que las limitaciones económicas afectan la vigilancia del cultivo y favorecen decisiones de manejo poco eficientes.

CAPÍTULO IV

4. MARCO PROPOSITIVO

4.1 Introducción

En este capítulo se presenta el marco propositivo y el desarrollo de la solución tecnológica planteada el cual es un sistema móvil basado en transfer learning con el modelo MobileNetV2 para la detección temprana de artrópodos fitófagos en cultivos de cacao en la granja experimental de la Uleam en El Carmen. La propuesta nace como solución al retraso en la identificación fitosanitaria, la dependencia del monitoreo visual y la escasez de personal especializado para esta tarea tan importante.

Este capítulo muestra el proceso que se llevó a cabo, la metodología, los recursos que se utilizaron para poder realizar este proyecto integrador. También muestra a raíz de las necesidades de los agricultores como podemos implementar este sistema y poco a poco irlo adaptando más.

4.2 Descripción de la propuesta tecnológica

La propuesta tecnológica consiste en un módulo de clasificación de imágenes basado en transfer learning, construido sobre la arquitectura MobileNetV2, seleccionada por su bajo costo computacional y la idoneidad para ejecutar en dispositivos móviles con recursos limitados, condición indispensable dado que el sistema de funcional sin conexión a internet en el campo.

El modelo fue desarrollado utilizando TensorFlow/Keras y posteriormente exportando a formato .tflite (TensorFlow Lite), optimizado para su integración en la aplicación móvil, la cual fue desarrollada en Flutter por otro integrante de este proyecto. El módulo clasifica imágenes de hojas de cacao en seis categorías: ácaros, arrieras, chinches, trips, sano y no cacao.

Para evitar clasificaciones erróneas cuando el usuario fotografía objetos ajenos al cultivo, se implementó un umbral de confianza mínima del 50%. Las predicciones por debajo de este valor son descartada o marcada como concluyente, priorizando la confiabilidad un diagnóstico entregado al agricultor.

El flujo general de la propuesta comprende: la captura de la imagen desde el dispositivo móvil, el procesamiento de la misma la inferencia mediante el modelo .tflite embebido y la aplicación y la presentación del resultado junto con una recomendación práctica dirigida a la agricultura redactada en lenguaje sencillo y no técnico.

El dataset utilizado para el entrenamiento se conformó principalmente a partir de fuentes públicas especializadas (Roboflow Universe, Kaggle, entre otros.), complementado con un conjunto reducido de imágenes propias capturadas en la granja experimental Uleam El Carmen, con el fin de ajustar el modelo a las condiciones reales del cultivo local.

4.3 Recursos requeridos

En la Tabla 3 se detallaron los recursos humanos involucrados en el desarrollo del módulo de inteligencia artificial.

4.3.1 Recursos humanos

Tabla 3. Recursos humanos

Rol	Función en el módulo de IA
Desarrollador(a) / autor(a) del modulo	Diseño, entrenamiento, validación y documentación del modelo de clasificación.
Tutor de tesis	Guía metodológica y revisión de técnicas del avance.
Equipo de desarrollo	Integración del modelo con la interfaz móvil y los demás módulos del sistema

4.3.2 Recursos Tecnológicos

Tabla 4. Recursos tecnológicos Hardware

Recurso	Descripción/ Uso
Computadora portátil (Windows)	Entrenamiento y desarrollo del modelo de IA
Dispositivo móvil con cámara	Pruebas de campo de la aplicación
Smartphone	Captura de imágenes para el dataset

Tabla 5. Recursos tecnológicos -Software

Recurso	Descripción/ Uso
Python3	Es el lenguaje de programación principal en este proyecto, en un entorno virtual (.venv)
TensorFlow / Keras	Framework de entrenamiento, de la arquitectura MobileNetV2 usada en este proyecto.
TensorFlow Lite	Conversión y despliegue del modelo en formato .tflite
Visual Studio Code	Entorno de desarrollo (IDE). Herramienta usada para realizar el proyecto.
Roboflow	Usado para la gestión, etiquetado y aumento de datos del dataset
Tkinter	Interfaz gráfica para realizar pruebas de escritorio antes de ser convertido a .tflite

4.3.3 Recursos Económicos

Tabla 6. Recursos Económicos.

Recurso	Costo estimado	Observación
Software (Python, TensorFlow, VS Code)	\$0.00	Herramientas de código abierto, sin costo de licencia.
Roboflow	\$0.00	Plan gratuito utilizado para gestión y aumento
Computadora portátil	\$650.00	Laptop Dell inspiron 15 i5
Dispositivo móvil	\$200.00	Equipo Redmi note 11 pro
Internet / conectividad	\$28.00 * 4 mese =\$112.00	Uso puntual para descargas y gestión de dataset
Tiempo	386 horas * \$10.00 = \$3686	386 horas de desarrollo, entrenamiento del modelo y pruebas, a \$10.00 cada hora
Total, estimado:	\$ 4.648,00	

4.4 Fases de desarrollo del software

El desarrollo del módulo de inteligencia artificial se llevó a cabo bajo el marco de trabajo Ágil es Scrum, Elegido por su capacidad de adaptarse a proyectos iterativos como el entrenamiento de modelos de aprendizaje automático, Donde los resultados de cada ciclo (precisión, errores de clasificación) Determinan los ajustes del siguiente. A continuación, se describe el producto, las historias de usuario que conforman el Product Backlog, y los Sprints ejecutados durante el desarrollo.

4.4.1 Descripción del producto

El producto corresponde al módulo de inteligencia artificial para la detección temprana de artrópodos fitófagos en cultivos de cacao, componente del sistema móvil desarrollado para la granja experimental Uleam El Carmen. A partir de una fotografía de una hoja de cacao,

tomada desde un dispositivo móvil, el sistema identifica automáticamente si la planta presenta signos de afectación por ácaro, arriera, chinche o Trips o si se encuentra sana entregando al agricultor una recomendación práctica y comprensible sobre la acción a seguir.

El producto está diseñado para operar sin conexión a internet, ya que el modelo de clasificación entrenado mediante transfer learning sobre la arquitectura MobileNetV2 se exporto el formato .tflite para ejecutarse localmente dentro de la aplicación móvil. Además, incorpora un umbral de confianza mínima que evita entregar diagnósticos poco confiables, rechazando imágenes de baja calidad o que no corresponden a hojas de cacao.

4.4.2 Metodología de desarrollo

Para el desarrollo del sistema móvil de detección de artrópodos fitófagos se utilizó la metodología Scrum como marco de trabajo, con el fin de organizar el proceso en etapas cortas y controladas. En vez de construir el sistema completo de una sola vez, se planificaron varios Sprints, cada uno con un objetivo específico relacionado con la mejora de modelo de clasificación de imagen y su preparación para su uso en el campo.

En cada sprint se definió las historias de usuario que reflejan las necesidades del agricultor, como, por ejemplo, poder tomar una fotografía y que esta le dé un diagnóstico claro, utilizar la aplicación sin conexión a internet. A raíz de estas historias de usuario se elaboró un conjunto de tareas técnicas, que incluía la recolección y organización de fotografías, el entrenamiento y ajuste del modelo, la incorporación de nuevas clases, la conversión del modelo a formato móvil y la realización de pruebas de validación.

4.4.3 Justificación de la metodología Scrum

Se eligió la metodología Scrum como marco de trabajo porque esta permite dividir el desarrollo del sistema en ciclos breves, llamados Sprints, cada uno con objetivos claros y resultados concretos. En este proyecto era necesario ir ajustando el comportamiento del modelo

de clasificación de imágenes a medida que se incorporaban nuevas plagas, se ampliaba el conjunto de imágenes y se realizaban pruebas, la metodología Scrum facilitó organizar estos ajustes de forma ordenada.

Con esta metodología el objetivo general del sistema se transformó en pequeñas metas realizables, primero se trabajó con clases básicas de plagas, luego se fueron añadidas otras clases, se añadió una clase para rechazar imágenes que no tengan que ver con cacao, se preparó el modelo para que funcione en dispositivos móviles y su funcionamiento sin acceso a internet, junto con pruebas de validación. Cada una de las metas se trató en Sprints específicos, lo que permitió detectar errores y corregirlos sin detener el proyecto completamente.

4.4.4 Roles Scrum

En el desarrollo del modelo de inteligencia artificial se adaptaron los roles propuestos por Scrum al contexto académico del proyecto, asignando claramente las responsabilidades de cada participante.

Tabla 7. Roles Scrum

Rol Scrum	Responsable	Funciones desarrolladas
Product Owner	Ing., Saed Reascos	Orientar los requerimientos del módulo, revisar la utilidad de la propuesta y validar que el sistema respondiera al contexto agrícola.

Rol Scrum	Responsable	Funciones desarrolladas
Scrum Master	Jeny Alcivar	Organiza los Sprints, controlar el avance, identificar objetos y asegurar el cumplimiento de las actividades planificadas
Desarrollador	Jeny Alcivar	Recolección y organización del dataset, entrenamiento y ajuste del modelo MobileNetV2, realización de pruebas de validación y exportación del modelo a formato móvil.

4.4.5 Eventos Scrum

Los eventos de Scrum se aplicaron de forma adaptada al contexto del proyecto, manteniendo su propósito principal, pero ajustando su ejecución del trabajo individual.

Tabla 8. Eventos Scrum

Evento Scrum	Aplicación en el proyecto
Sprint Planning	Definición del objetivo de cada sprint, historias de usuario y tareas técnicas del Sprint Backlog asociadas al modelo de IA.
Daily Scrum	Seguimiento personal de las actividades terminadas, pendientes y dificultades encontradas durante el entrenamiento del modelo y las pruebas.
Sprint Review	Comprobación del funcionamiento del incremento desarrollado en cada sprint
Sprint Retrospective	Análisis de los errores encontrados y las mejoras aplicadas para el siguiente sprint.

Estos eventos permitieron mantener una visión clara del avance del módulo de IA, asegurando que cada incremento aportara valor al objetivo final del sistema móvil y que los hallazgos técnicos se transformaran en mejoras concretas.

4.5 Sprints de desarrollo del módulo de inteligencia artificial

4.5.1 Sprint 1: Construcción del dataset base y primer entrenamiento

4.5.1.1 Objetivo del sprint

Construir el conjunto de datos inicial con las clases fundamentales de plagas del cacao, combinando fuentes públicas con imágenes propias, y obtener un primer modelo funcional basado en transfer learning con MobileNetV2 capaz de clasificar y recomendar acciones básicas al agricultor.

4.5.1.2 Historia de usuario del Sprint 1

Tabla 9. HU-01 Detección de plagas mediante fotografías

HISTORIA DE USUARIO			
Id de historia:	HU-01	Título:	Detección de plagas mediante fotografías
Prioridad:	Alta	Usuario:	Usuario de la aplicación
Como:	Usuario del sistema		
Quiero:	Tomar una foto de una hoja de cacao con mi celular		
Para:	Saber si tiene alguna plaga sin necesidad de un especialista		
Criterios de aceptación:	Permitir captura desde cámara o galería del dispositivo, procesar la imagen localmente sin conexión a internet y mostrar el resultado en menos de 10 segundos.		

4.5.1.3 Sprint Backlog del Sprint 1

Tabla 10. Sprint Backlog del Sprint 1

ID	Tarea	Estado
SB-01	Localizar y descargar conjuntos de datos públicos de las clases base de plagas desde Roboflow Universe y repositorios similares	Completado
SB-02	Capturar fotografías propias del cultivo de Cacao en la Granja Experimental de la Uleam El Carmen para complementar el dataset	Completado
SB-03	Organizar el conjunto de imágenes combinado en carpetas separadas por clase para facilitar su manejo.	Completado
SB-04	Etiquetar las imágenes del dataset utilizando la plataforma de Roboflow.	Completado
SB-05	Aplicar técnicas de aumento de datos sobre las cuatro clases base definidas.	Completado
SB-06	Implementar el script entrenamiento.py con detección automática de clases a partir de las carpetas del dataset.	Completado
SB-07	Ejecutar el primer entrenamiento del modelo empleando Transfer Learning MobileNetV2.	Completado

4.5.1.4 Sprint Review del Sprint 1

Tabla 11. Sprint Review Sprint 1

Funcionalidad evaluada	Resultado	Estado
Carga y organización del dataset	Las imágenes se almacenaron y clasificaron correctamente en carpetas por clase, conforme al diseño del proyecto	Aprobado
Entrenamiento del modelo	El modelo generó predicciones sobre las cuatro clases base sin presentar errores de ejecución durante las pruebas iniciales.	Aprobado
Generación de archivos del modelo	Se generaron sin inconvenientes los archivos cacao_multi_model.h5 y clases.txt, necesarios para el uso posterior del modelo	Aprobado

4.5.1.5 Sprint Retrospective del Sprint 1

Tabla 12. Sprint Retrospective del Sprint 1

Aspecto evaluado	Resultado
¿Qué funcionó bien?	La combinación de fuentes públicas y fotografías propias permitió conformar rápidamente un dataset inicial útil para entrenar el modelo.

Aspecto evaluado	Resultado
¿Qué dificultades se presentaron?	Se contó con pocas imágenes capturadas directamente en campo, lo que obligó a depender en gran medida los recursos externos.
¿Cómo se solucionaron?	Se complementó el conjunto de datos con imágenes seleccionadas de Roboflow Universe y Kaggle, revisando manualmente su pertenencia para el cultivo de cacao
¿Qué se mejorará en el siguiente sprint?	Ampliar el dataset incorporando nuevas clases consideradas prioritarias en campo, como la hormiga arriera

4.5.1.6 Evidencias del Sprint 1

Figura 2 Clases




Figura 3. Primer entrenamiento





Figura 4 Primer funcionamiento del modelo



4.5.2 Sprint 2: Incorporación de clase arriera y ampliación de dataset

4.5.2.1 Objetivo del sprint

Ampliar el modelo para reconocer daño causado por hormigas arrieras, identificadas como una de las principales plagas en la Extensión El Carmen, integrando un conjunto de datos externos filtrado automáticamente.

4.5.2.2 Historia de usuario del Sprint 2

Tabla 13. HU-02 Resultado claro de clasificación

HISTORIA DE USUARIO			
Id de historia:	HU-02	Título:	Resultado claro de clasificación
Prioridad:	Alta	Usuario:	Usuario de la aplicación
Como:	Usuario del sistema		
Quiero:	Recibir un resultado que indique la manera explícita si la planta tiene plagas o está libre de ellas		

Para:	Tomar decisiones rápidas sobre el tratamiento del cultivo de cacao
Criterios de aceptación:	El sistema muestra el nombre de la clase detectada, presenta el porcentaje de confianza del modelo y diferencia visualmente el estado “plaga detectada” de “libre de plagas” mediante colores o iconos.

4.5.2.3 Sprint Backlog del Sprint 2

Tabla 14. Sprint backlog del Sprint 2

ID	Tarea	Estado
SB-08	Descargar un conjunto de datos externo de hormigas arrieras desde Roboflow Universe, iNaturalist	Completado
SB-09	Desarrollar el script “filtrar_arrieras.py” para eliminar automáticamente imágenes con fondos de laboratorio blanco.	Completado
SB-10	Ejecutar el filtrado y añadir las imágenes válidas a la carpeta dataset/train/arriera.	Completado
SB-11	Recolectar nuevas imágenes para las clases existentes: ácaros, chinches y sano	Completado
SB-12	Aplicar aumento de datos a todas las clases del dataset ampliado.	Completado
SB-13	Reentrenar el modelo incluyendo la nueva clase arriera	Completado
SB-14	Analizar las métricas de precisión del modelo después de la ampliación del dataset	Completado

4.5.2.4 Sprint Review del Sprint 2

Tabla 15. Sprint Review del Sprint 2

Funcionalidad evaluada	Resultado	Estado
Filtrado automático de imágenes	El script descarto adecuadamente las imágenes con fondo blanco o de laboratorio, conservando solo con contexto de campo	Aprobado
Detección de la clase arriera	En pruebas manuales, el modelo identifico la forma correcta la clase arriera en las imágenes de test.	Aprobado
Métricas de precisión	Tras incorporar la quinta clase, el modelo mantuvo un rendimiento satisfactorio de precisión global	Aprobado

4.5.2.5 Sprint Retrospective del Sprint 2

Tabla 16. Sprint Retrospective del Sprint 2

Aspecto evaluado	Resultado
¿Qué funcionó bien?	El filtrado automático basado en el color de fondo permitió depurar el dataset externo sin necesidad de revisar cada imagen manualmente.
¿Qué dificultades se presentaron?	EL conjunto de datos de arriera incluía numerosas imágenes de laboratorio poco representativas del entorno real de la plantación
¿Cómo se solucionaron?	Se implementó un script de filtrado automático que analiza el color de fondo y elimina las imágenes no adecuadas.
¿Qué se mejorará en el siguiente sprint?	Incorporar un mecanismo de rechazo para fotografías que no pertenezcan al cultivo de cacao.

4.5.2.6 Evidencia del Sprint 2

Figura 5. Aumento de clase Arriera

```

1 import os
2 import tensorflow as tf
3 from tensorflow.keras.preprocessing.image import ImageDataGenerator
4 from tensorflow.keras.applications import MobileNetV2
5 from tensorflow.keras import layers, models
6
7 TRAIN_DIR = 'dataset/train'
8 VALID_DIR = 'dataset/valid'

```

PROBLEMS OUTPUT DEBUG CONSOLE TERMINAL PORTS

(.venv) PS C:\Users\Usuario\Desktop\prototipo_plagas> python entrenamiento.py
Found 62 images belonging to 5 classes.

Clases detectadas: ['acaro', 'arriera', 'chinche', 'sano', 'trips']
Total train: 321 imágenes
Total valid: 62 imágenes

I0000 00:00:1781699641.832004 8820 cpu_feature_guard.cc:227] This TensorFlow binary is optimized for the following instructions: SSE3 SSE4.1 SSE4.2 AVX AVX2 AVX_VNNI FMA, in other operations you may experience less performance.
WARNING:tensorflow:TensorFlow GPU support is not available on native Windows for TensorFlow >= 2.0.0. If you have the TensorFlow-DirectML plugin, it may be able to use the GPU.
Model: "sequential"

Layer (type)	Output Shape	Param #
mobilenetv2_1.00_224 (Functional)	(None, 7, 7, 1280)	2,257,984
global average pooling2d (GlobalAveragePooling2D)	(None, 1280)	0
dense (Dense)	(None, 128)	163,968
dropout (Dropout)	(None, 128)	0
dense_1 (Dense)	(None, 5)	645

Total params: 2,422,597 (9.24 MB)
Trainable params: 164,613 (643.02 KB)
Non-trainable params: 2,257,984 (8.61 MB)

Figura 6. Reentrenamiento con el dataset ampliado

```

218 # FOOTER
219 footer = tk.Frame(root, bg=BG2, padx=25, pady=8)
220 footer.pack(fill="x", side="bottom")
221 tk.Frame(footer, bg=BORDER, height=1).pack(fill="x", pady=(0,6))
222 tk.Label(footer, text="Transfer Learning · MobileNetV2 · TensorFlow 2.x",
223         font=("Courier New",8), bg=BG2, fg=TEXT2).pack(side="left")
224 tk.Label(footer, text="Ingeniería en Software – ULEAM El Carmen",
225         font=("Courier New",8), bg=BG2, fg=TEXT2).pack(side="right")
226
227 root.mainloop()

```

PROBLEMS OUTPUT DEBUG CONSOLE TERMINAL PORTS


```

(.venv) PS C:\Users\Usuario\Desktop\prototipo_plagas> python entrenamiento.py
59/59 24s 410ms/step - accuracy: 0.9807 - loss: 0.0656 - val_accuracy: 0.9912 - val_loss: 0.0355
Epoch 12/25
59/59 29s 482ms/step - accuracy: 0.9722 - loss: 0.0795 - val_accuracy: 0.9912 - val_loss: 0.0334
Epoch 18/25
59/59 25s 414ms/step - accuracy: 0.9850 - loss: 0.0426 - val_accuracy: 0.9912 - val_loss: 0.0340
Epoch 19/25
59/59 22s 378ms/step - accuracy: 0.9786 - loss: 0.0596 - val_accuracy: 0.9823 - val_loss: 0.0384
59/59 24s 399ms/step - accuracy: 0.9679 - loss: 0.0832 - val_accuracy: 0.9823 - val_loss: 0.0397
Epoch 21/25
59/59 29s 490ms/step - accuracy: 0.9882 - loss: 0.0450 - val_accuracy: 0.9823 - val_loss: 0.0421
Epoch 22/25
59/59 25s 420ms/step - accuracy: 0.9840 - loss: 0.0570 - val_accuracy: 0.9823 - val_loss: 0.0434
Epoch 23/25
59/59 23s 381ms/step - accuracy: 0.9840 - loss: 0.0473 - val_accuracy: 0.9823 - val_loss: 0.0377
Epoch 24/25
59/59 24s 399ms/step - accuracy: 0.9775 - loss: 0.0644 - val_accuracy: 0.9823 - val_loss: 0.0375
Epoch 25/25
59/59 27s 456ms/step - accuracy: 0.9872 - loss: 0.0392 - val_accuracy: 0.9912 - val_loss: 0.0384
WARNING:absl:You are saving your model as an HDF5 file via 'model.save()' or 'keras.save_model(model)'. This file format is considered legacy. We recommend using instead the native Keras format, e.g. 'model.save('my_model.keras')' or 'keras.save_model(model, 'my_model.keras')'.

```

Modelo guardado en: modelo/cacao_multi_model.h5
 Clases guardadas en: modelo/clases.txt

Figura 7 Clase arriera implementada



4.5.3 Sprint 3: Incorporación de la clase “no_cacao” y configuración del umbral de confianza

4.5.3.1 Objetivo del sprint

Dotar al modelo de la capacidad de rechazar imágenes que no correspondan a hojas de cacao, evitando diagnósticos erróneos ante fotos fuera de dominio mediante una nueva clase y un umbral de confianza mínimo.

4.5.3.2 Historia de usuario del Sprint 3

Tabla 17, HU-03 Validación de imagen de entrada

HISTORIA DE USUARIO			
Id	de	HU-04	Título: Validación de imagen de entrada
historia:			
Prioridad:		Media	Usuario: Usuario de la aplicación
Como:	Usuario del sistema		
Quiero:	Que el sistema me avise cuando la imagen no corresponde a una hoja de cacao		
Para:	Evitar diagnósticos incorrectos a partir de fotografías fuera del dominio del modelo		
Criterios de aceptación:	Las predicciones con nivel de confianza inferior al 50% se rechazan y se muestra un mensaje claro indicando que la imagen no pertenece al cultivo de cacao o no es válida para el análisis.		

4.5.3.3 Sprint Backlog del Sprint 3

Tabla 18. Sprint backlog del Sprint 3

ID	Tarea	Estado
SB-15	Recolectar imágenes que no corresponden al cultivo de cacao para conformar la clase no_cacao.	Completado
SB-16	Integrar la carpeta no_cacao al dataset general de entrenamiento	Completado
SB-17	Reentrenar el modelo incluyendo las seis clases finales.	Completado
SB-18	Definir y configurar el umbral mínimo de confianza para aceptar una predicción	Completado
SB-19	Ejecutar el reentrenamiento definitivo del modelo con las seis clases y el umbral configurando.	Completado

4.5.3.4 Sprint Review del Sprint 3

Tabla 19. Sprint Review del Sprint 3

Funcionalidad evaluada	Resultado	Estado
Clase no_cacao	En las pruebas, el modelo rechazo de forma correcta imágenes que no correspondían al cultivo de cacao.	Aprobado
Umbral de confianza	Las predicciones son un nivel de confianza inferior a 50% se marcaron como “no reconocidas” según lo establecido.	Aprobado

4.5.3.5 Sprint Retrospective del Sprint 3

Tabla 20. Sprint Retrospective del Sprint 3

Aspecto evaluado	Resultado
¿Qué funcionó bien?	La incorporación de la clase no_cacao disminuyó considerablemente los diagnósticos forzados sobre imágenes irrelevantes.
¿Qué dificultades se presentaron?	Resultó complejo seleccionar un umbral de confianza que no descartara predicciones correctas de baja certeza.
¿Cómo se solucionaron?	Se realizó pruebas comparativas con distintos valores y se fijó el umbral en 0,50 por ofrecer mejor equilibrio entre aciertos y rechazos
¿Qué se mejorará en el siguiente sprint?	Preparar el modelo para su exportación e integración con la aplicación móvil.

4.5.3.6 Evidencia del Sprint 3

Figura 8 Se añadió clase No Cacao





Figura 9 Clase no cacao funcionando



4.5.4 Sprint 4 Exportación e integración del modelo

4.5.4.1 Objetivo del sprint

Exportar el modelo entrenado en formato compatible con dispositivos móviles y garantizar su funcionamiento sin conexión a internet, integrándolo con la aplicación desarrollada en Flutter.

4.5.4.2 Historia de usuario del Sprint 4

Tabla 21. HU-03 Funcionamiento offline

HISTORIA DE USUARIO			
Id de historia:	HU-03	Título:	Funcionamiento offline
Prioridad:	Alta	Usuario:	Usuario de la aplicación
Como:	Usuario del sistema		
Quiero:	Utilizar la aplicación, aunque no tenga acceso a internet		
Para:	Poder realizar diagnostico directamente en el cultivo de cacao		
Criterios de aceptación:	El modelo en formato .tflite se ejecuta de manera local en el dispositivo, no realiza llamadas a servicios externos para clasificar y la aplicación funciona correctamente incluso en modo avión.		

4.5.4.3 Sprint Backlog del Sprint 4

Tabla 22. Sprint backlog del Sprint 4

ID	Tarea	Estado
SB-20	Convertir el modelo entrenado al formato TensorFlow Lite (.tflite)	Completado
SB-21	Verificar el tamaño del archivo y su funcionamiento básico en pruebas locales	Completado
SB-22	Entregar el archivo .tflite y la lista de clases al compañero responsable de la interfaz desarrollada en Flutter	Completado

4.5.4.4 Sprint Review del Sprint 4

Tabla 23. Sprint Review del Sprint 4

Funcionalidad evaluada	Resultado	Estado
Conversión a TFLite	El modelo se exportó correctamente al formato TFLite con un tamaño aproximado de 2,57 MB	Aprobado
Entrega al equipo	El archivo convertido fue recibido e integrado sin problemas por el compañero encargado del desarrollo en Flutter.	Aprobado

4.5.4.5 Sprint Retrospective del Sprint 4

Tabla 24. Sprint Retrospective del Sprint 4

Aspecto evaluado	Resultado
¿Qué funcionó bien?	La conversión a TFLite redujo la forma notable el tamaño del modelo, facilitando su uso en dispositivos móviles.
¿Qué dificultades se presentaron?	Fue necesario comprobar que el modelo convertido mantuviera un comportamiento similar en precisión respecto a la versión original en .h5.
¿Cómo se solucionaron?	Se realizaron pruebas comparativas entre ambas versiones antes de proceder a la entrega oficial.
¿Qué se mejorará en el siguiente sprint?	Validar el modelo de mantener de manera independiente en un dispositivo Android real.


4.5.4.6 Evidencia del Sprint 4

Figura 10 Conversión de modelo a .tflite



```
PS C:\Users\Usuario\Desktop\prototipo_plagas> python
... f.write(tflite_model)
File "<stdin>", line 2
    f.write(tflite_model)
    ^
IndentationError: expected an indented block after 'with' statement on line 1
>>> with open('modelo/cacao_multi_model.tflite', 'wb') as f:
...     f.write(tflite_model)
...
9542576
>>>
```

Figura 11 Modelo .tflite Entregado



4.5.5 Sprint 5: Pruebas y validación del modelo

4.5.5.1 Objetivo del sprint

Verificar el funcionamiento correcto y la velocidad del modelo de clasificación de forma independiente, mediante interfaz de prueba, documentar los hallazgos encontrados en las pruebas de caja negra.

4.5.5.2 Historia de usuario del Sprint 5

Tabla 25. HU-05 Interfaz simple e intuitiva

HISTORIA DE USUARIO				
Id historia:	de	HU-05	Título:	Interfaz simple e intuitiva
Prioridad:		Media	Usuario:	Usuario de la aplicación

Como:	Usuario del sistema
Quiero:	Que la interfaz sea clara y fácil de entender desde el primer uso
Para:	Manejar la aplicación sin necesidad de capacitaciones previas
Criterios de aceptación:	La pantalla presenta iconos e indicadores visuales comprensibles, botones de tamaño adecuado para uso en campo y textos en español sencillos, evitando términos técnicos complejos.

Tabla 26. HU-06 Diagnóstico Rápido

HISTORIA DE USUARIO			
Id de historia:	HU-06	Título:	Diagnóstico rápido
Prioridad:	Alta	Usuario:	Usuario de la aplicación
Como:	Usuario del sistema		
Quiero:	Obtener el resultado de la clasificación en poco tiempo		
Para:	No interrumpir mis labores mientras espero el diagnostico		
Criterios de aceptación:	El tiempo de inferencia por imagen es inferior a 10 segundos y el modelo esta optimizado en tamaño para garantizar una carga ágil en el dispositivo móvil.		

4.5.5.3 Sprint Backlog del Sprint 5

Tabla 27. Sprint backlog del Sprint 5

ID	Tarea	Estado
SB-23	Desarrollar una interfaz gráfica de escritorio con Tkinter para ejecutar pruebas locales del modelo durante la fase de entrenamiento.	Completado

ID	Tarea	Estado
SB-24	Realizar pruebas de caja negra sobre salida del modelo, primero en entorno de escritorio y posteriormente en la aplicación móvil integrada.	Completado
SB-25	Documentar de forma detallada los resultados obtenidos en las pruebas	Completado
SB-26	Preparar y efectuar la presentación oral individual de los hallazgos de las pruebas con el equipo.	Completado
SB-27	Identificar y registrar el hallazgo relacionado con imágenes borrosas que presentan confianza injustificadamente alta	Completado

4.5.5.4 Sprint Review del Sprint 5

Tabla 28. Sprint Review del Sprint 5

Funcionalidad evaluada	Resultado	Estado
Interfaz de pruebas con Tkinter	La interfaz permitió clasificar imágenes de forma aislada durante el desarrollo, facilitando la depuración del modelo previo a su integración en la aplicación móvil.	Aprobado
Pruebas de caja negra	Se registraron aciertos y errores de clasificación sobre casos reales, generando evidencias del desempeño del modelo.	Aprobado
Detección de anomalías	Se identificó el problema de predicciones con alta confianza en imágenes borrosas y se documentó como hallazgo relevante.	Aprobado


4.5.5.5 Sprint Retrospective del Sprint 5

Tabla 29. Sprint Retrospective del Sprint 5

Aspecto evaluado	Resultado
¿Qué funcionó bien?	Las pruebas de caja negra permitieron descubrir errores que no se apreciaban durante el proceso de entrenamiento.
¿Qué dificultades se presentaron?	Se detectó una fuga de datos entre los conjuntos de entrenamiento y validación, además de las imágenes borrosas con confianza elevada.
¿Cómo se solucionaron?	Se depuró el conjunto de validación eliminando duplicados exactos y se incorporó un filtro de nitidez basado en la varianza del filtro Laplaciano.
¿Qué se mejorará en el siguiente sprint?	Mejorar, falencias de alguna clase que este presentando errores.

4.5.5.6 Evidencias del sprint 5

Figura 12 Interfaz adaptada a una pantalla de móvil



4.6 Validación con usuario

La validación con usuarios se realizó sobre la aplicación móvil ya integrada con el modelo de clasificación, mediante una prueba de uso con una agricultora dedicada al cultivo de cacao en la zona rural de El Carmen. Esta validación, de carácter exploratorio y concebida como una prueba piloto, tuvo como objetivo principal comprobar cómo una usuaria real interactuaba con la aplicación en su entorno y al mismo tiempo observar el comportamiento del sistema de detección de plagas en situaciones cercanas al uso cotidiano en el campo.

Para la sesión se dispuso de un dispositivo Android con la aplicación final instalada, incluyendo el modelo TensorFlow embebido. La agricultora realizó tareas representativas de su trabajo diario, capturar fotografías de hojas de cacao con presencia de daño, tomar imágenes de plantas aparentemente sanas y probar que ocurría al fotografiar elementos ajenos al cultivo. Durante la interacción se registraron tanto aspectos de usabilidad como comprensión de

botones y mensajes, facilidad para completar las acciones, como la respuesta del modelo de detección ante cada imagen, poniendo el énfasis en el desempeño del sistema de clasificación.

Al finalizar la prueba se discutieron con la usuaria sus impresiones sobre la aplicación como herramienta de apoyo, mientras se analizó en detalle los resultados de las predicciones generadas por el modelo. Se documentó casos en los que el sistema identificó correctamente plagas y plantas sanas, así como situaciones límite en las que la confianza del modelo disminuía o la imagen era rechazada por no corresponder al cultivo de cacao. Esta información se utilizó para validar el funcionamiento del módulo de detección desarrollado en este documento.

Si bien esta evaluación se realizó con una sola agricultora, los hallazgos obtenidos ofrecen una primera evidencia de que el modelo puede operar de forma coherente integrado en la aplicación móvil. Esta prueba piloto sirve como base para futuras validaciones con una muestra más amplia de usuarios, lo cual se plantea como una línea de trabajo futuro.

CAPÍTULO V

5. EVALUACIÓN DE RESULTADOS

5.1 Introducción

En el presente capítulo se expone el proceso de evaluación de resultados obtenidos tras el desarrollo del sistema móvil con transfer learning para la detección temprana de artrópodos fitófagos en cultivos de *Theobroma cacao*. Esta evaluación se estructura en dos ejes principales: la validación técnica y funcional del producto desarrollado, y el análisis del impacto que la solución representa frente a la problemática identificada en el diagnóstico inicial del proyecto.

Con la validación técnica se confirma que el modelo de clasificación de imágenes realizado en este proyecto con MobileNetV2 con Transfer Learning, alcanza los niveles de precisión y confiabilidad necesaria para ser puesto en marcha en el campo. También la validación funcional verifica que el modelo entrenado funcione sin problemas al integrarse con los demás módulos del proyecto integrador, sin necesitar conexión a internet.

Posteriormente, el análisis de impacto contrasta los resultados alcanzados con los objetivos planteados en capítulos anteriores, evidenciando los beneficios que el sistema aporta a la Granja experimental Uleam El Carmen y de manera general, a los productores de cacao de la zona.

5.2 Validación técnica y funcional del producto

La validación del módulo de inteligencia artificial se realizó en dos etapas complementarias: una validación técnica, centrada en el desempeño del modelo de clasificación durante su entrenamiento y una validación funcional orientada a comprobar su correcto funcionamiento al ser integrado en un entorno móvil real.

Es importante mencionar que, en relación con el objetivo de documentar la presencia de artrópodos fitófagos durante cuatro semanas consecutivas en la granja experimental, no fue posible completar este seguimiento en su totalidad debido a que el alcance del proyecto y los tiempos establecidos para el desarrollo del trabajo de titulación priorizaron las fases de entrenamiento, validación e integración del modelo, lo que redujo el periodo disponible para el trabajo de campo. Por esta razón, el dataset se complementó con imágenes de repositorios públicos, alcanzando un total de 1,743 imágenes que permitieron entrenar y validar el modelo con un 97.33% de exactitud. La validación técnica y funcional presentada a continuación demuestra que esta estrategia de complementación fue efectiva para cumplir con el propósito del proyecto.


5.2.1 Validación técnica del modelo

El modelo de clasificación basado en la arquitectura MobileNetV2 mediante transfer learning, fue entrenado para reconocer seis categorías las cuales son: ácaro, arriera, chinche, Trips, cacao sano y no sano. Tras el proceso de reentrenamiento que consistió el aumento de datos de la clase arriera para corregir un desbalance inicial en el conjunto de datos, se procedió a evaluar el desempeño del modelo sobre un conjunto de validaciones independientes.

Durante la depuración del conjunto de validaciones, se identificó mediante comparaciones de contenido exacto, que un número considerable de imágenes se encontraban duplicadas entre los subconjuntos de entrenamiento y validación, como consecuencia de una separación manual del dataset. Con el fin de garantizar una evaluación objetiva del modelo, es decir medir su desempeño únicamente sobre imágenes que no fueran utilizadas durante el entrenamiento. Se depuró el conjunto de validaciones eliminando dichas coincidencias, y se complementó con fotografías adicionales para la clase no_cacao, obteniendo un conjunto final de 75 fotos de validaciones genuinamente independientes del conjunto de entrenamiento.

Sobre este conjunto depurado, el modelo alcanzó una exactitud(accuracy) de 97.33% resultado que considera representativo del desempeño real del modelo ante imágenes nunca antes vistas.

Figura 13. Matriz de confusión del modelo de clasificación de artrópodos fitófagos



Nota. Elaboración propia

Como se observa en la Figura13, el modelo clasificó correctamente 73 de las 75 imágenes de validación, con errores concentrados en dos casos puntuales: una imagen de trip clasificada como chinche. La clase arriera presentó un error de confusión con no_cacao. Las clases no_cacao y sano no presentan ningún error de clasificación

Tabla 30. Métricas de precisión exhaustiva y F1-score por clase

Clase	Precisión	Exhaustividad (Recall)	F1-score	Nº imágenes
Ácaro	1.0000	1.0000	1.0000	6
Arriera	1.0000	0.9000	0.9474	10
Chinche	0.8889	1.0000	0.9412	8

No cacao	1.0000	1.0000	0.9767	21
Sano	1.0000	1.0000	1.000	20
Trips	1.0000	0.9000	0.9474	10
Exactitud global			0.9733	75

Nota. Elaboración propia

Los resultados evidencian un desempeño consistente alto en todas las clases, con valores de F1-score superiores a 0.94 en la totalidad de las categorías y valores perfectos (1.0000) en acaro y sano. La ligera reducción en Recall de las clases arriera y trips (0.9000) corresponde a un único error de clasificar en cada caso, resultado esperable dado el tamaño reducido de las muestras de validación en un proyecto de alcance académico.

A su vez, se implementó un mecanismo de control de calidad de imagen mediante la varianza del filtro Laplaciano, con un umbral de mínimo de nitidez de 94.0 calibrado sobre el conjunto real de 1743 imágenes del dataset, con la finalidad de descartar automáticamente fotografías borrosas que pudieran inducir diagnósticos poco confiables.

También se estableció un umbral mínimo de confianza de 0.50, de manera que toda predicción por debajo de este valor sea reportada como “no reconocida” en lugar de forzar una clasificación incierta.

5.2.2 Validación funcional

Una vez exportado el modelo al formato TensorFlow Lite (.tflite, con 2.57 MB) se realizaron pruebas funcionales con el objetivo de verificar que el modelo entrenado opera correctamente al ser integrado en un entorno móvil real, sin conexión a internet. Para esto, las pruebas se realizaron directamente sobre la aplicación móvil final ya integrada por el equipo de trabajo, centrando la validación específicamente en el módulo de detección de plagas correspondiente a este componente de inteligencia artificial.

Se seleccionó una muestra de 15 imágenes correspondientes a las distintas clases del sistema, procesadas directamente desde dicha aplicación de prueba instalada en un dispositivo Android (modelo 2201116TG, Android 13).

Tabla 31. Resultados de las pruebas de integración funcional del modelo en dispositivos Android.

N°	Clase real	Clase predicha	Confianza	Resultado
1	Arriera	Arriera	99.99%	Correcto
2	Arriera	Arriera	98.32%	Correcto
3	Trips	Trips	99.97%	Correcto
4	Trips	Ácaros	60.95%	Incorrecto
5	Ácaro	Ácaro	99.74%	Correcto
6	Ácaro	Ácaro	79.57%	Correcto
7	Chinche	Chinche	99.99%	Correcto
8	Chinche	Chinche	94.61%	Correcto
9	Sano	Sano	99.95%	Correcto
10	Sano	Sano	99.99%	Correcto
11	No cacao	No cacao	100.00%	Correcto
12	No cacao	No cacao	100.00%	Correcto
13	Trips	Trips	99.93%	Correcto
14	Acaro	Trips	94.42%	Correcto
15	Arriera	Arriera	99.53%	Correcto

Como se observa en la Tabla 31, de las 15 pruebas, 13 dieron un resultado correcto, lo que representa una precisión funcional del 86.7% en una muestra. Los dos errores registrados correspondieron a una confusión entre las clases trips y ácaro, lo cual es explicable por la similitud visual que pueden presentar ambas plagas en etapas iniciales de daño sobre las hojas, representando una limitación esperable del modelo ante casos de alta semejanza visual entre clases.

5.3 Análisis de impacto y resultados obtenidos

5.3.1 Contraste con la problemática inicial

Antes del desarrollo el presente sistema la detección de artrópodos fitófagos en cultivo de cacao dependía principalmente de la observación visual directa por parte del agricultor sin apoyo de herramientas técnicas ni conocimientos especializados en entomología. Esta forma de inspección resulta susceptible al error humano ya que requiere que el agricultor identifique correctamente el tipo de plagas basándose únicamente en su experiencia empírica, lo cual puede derivar en diagnósticos imprecisos o un reconocimiento tardío del problema, incrementando el riesgo de propagación dentro del cultivo.

Frente a esta problemática el modelo de inteligencia artificial desarrollado permite que el agricultor obtenga un diagnóstico automatizado a partir de una simple fotografía, sin disponibilidad de un especialista. En la Tabla 30 (Métricas de precisión exhaustiva y F1-score por clase), se puede visualizar que el modelo alcanzó una exactitud de 97.3% sobre el conjunto de validación depurado, el sistema ofrece un apoyo objetivo y accesible que reduce la dependencia del criterio empírico individual, contribuyendo a una identificación más consistente y oportuna de las principales plagas que afectan al cultivo de Theobroma Cacao en la Granja Experimental de la Uleam El Carmen.

5.3.3 Verificación de las causas del problema

A continuación, se contrastan las principales causas identificadas en el diagrama causa-efecto del Capítulo I de este documento, con la forma en la que el sistema desarrollado aporta su mitigación.

En primer lugar, el monitoreo del cultivo se realiza principalmente mediante observación visual, sin apoyo de herramientas digitales, esto hace que la información obtenida dependa mucho de la experiencias de cada persona y pueda variar entre un observador y otro.

Frente a esta situación, el sistema propuesto ayuda a realizar una clasificación automática a partir de una imagen, permitiendo obtener resultados más consistentes y sin necesidad de un profesional.

Por otro lado, la falta de personal técnico capacitado para identificar con rapidez los artrópodos fitófagos en campo también presentan una dificultad muy importante. En este sentido la herramienta desarrollada puede servir como apoyo para el agricultor o usuario obtenga una orientación inicial sin necesidad de tener conocimientos especializados en entomología.

Así mismo, las limitaciones económicas para contratar personal dedicado exclusivamente al monitoreo hacen que esta tarea no siempre pueda realizarse con frecuencia necesaria. Debido a que el sistema funciona en un dispositivo móvil y no requiere conexión a internet sin equipos adicionales, se presenta como una alternativa totalmente accesible para los agricultores.

Finalmente. Estos elementos muestran que la propuesta responde a las causas principales del problema identificado y puede contribuir a mejorar el monitoreo fitosanitario del cacao.

Capítulo VI

6. Conclusiones y recomendaciones

6.1 Conclusiones

Después de revisar varios trabajos e investigaciones, se pudo comprobar que usar redes neuronales con Transfer Learning, en especial MobileNetV2, es una muy buena opción para identificar plagas en cacao. Esto se debe a que no se necesita entrenar el modelo desde cero, lo que ahorra tiempo y recursos, además se obtienen resultados con alta precisión, como el 97.33% que se alcanzó en este proyecto.

Durante las visitas a la Granja Experimental Uleam El Carmen se logró tomar fotografías a ciertas plagas que afectan al cacao, principalmente la arriera, también ácaros, chinches y trips. Si bien el tiempo disponible para el trabajo de campo fue limitado y no se consiguieron tantas imágenes propias como se hubiera deseado, combinarlas con fotos de repositorios públicos permitió tener un buen conjunto de datos para entrenar el modelo. Esto deja claro que, para futuros trabajos, es importante seguir tomando fotos en el campo para que el modelo se adapte mejor a la realidad de la zona.

Se logro armar un dataset con 1743 imágenes organizadas en seis categorías: ácaros, arriera, chinche, trips, cacao sano y no cacao. Para esto usaron imágenes de plataformas como Roboflow Universe, Kaggle e iNaturalist, y también algunas fotos propias tomadas en la granja. Este dataset fue la base para que el modelo aprenda a reconocer cada tipo de plaga, y demuestra que con recursos limitados también se puede construir material de calidad para entrenar inteligencia artificial.

Se logro desarrollar un sistema que funciona en el teléfono y que le permita al agricultor toma una foto de una hoja de cacao y recibir un diagnóstico en menos de 10 segundos, todo sin necesidad de internet. La aplicación, hecha en Flutter con el modelo MobileNetV2 convertido a TensorFlow Lite, clasifica la imagen y muestra si la planta tiene algún plaga o esta sana, junto

con una recomendación práctica. Esto demuestra que sí es posible llevar tecnología al campo de una manera sencilla y útil.

Las pruebas realizadas al modelo mostraron que funciona bien, con un 97.33% de exactitud y valores de F1-score por encima de 0.94 en todas las categorías. También se probó la aplicación con una agricultora de la zona rural de El Carmen, lo que permitió ver que el sistema sí funciona en el campo y que la interfaz es entendible. Queda claro que hace falta probarlo con más agricultores para seguir mejorando, pero este primer acercamiento ya deja ver que la herramienta tiene futuro.

6.2 Recomendaciones

Se recomienda que las instituciones y organizaciones relacionadas con el cultivo impulsen a hacer campañas de tomar fotos en el campo y así armar un repositorio propio y poder entrenar más modelos. Contar con más datos permitirá ajustar mejor la herramienta a las condiciones reales de la zona y mejorar su desempeño.

Para trabajos futuros, conviene ampliar el modelo incorporando nuevas clases de plagas como pulgón, cochinilla y otras que sean relevantes en la región, apoyándose en dataset específicos y en registros fotográficos adicionales. De igual manera se recomienda seguir aumentando y depurando el conjunto de datos, con el fin de elevar el porcentaje de confianza de las predicciones y reducir los casos en los que el sistema duda o rechaza imágenes validas

Respecto a los usuarios, se sugiere utilizar la aplicación como apoyo a las observaciones en campo y no como única fuente de decisión, procurando siempre tomar fotografías nítidas y centradas en la hoja para favorecer un diagnóstico más preciso.

BIBLIOGRAFÍA

- Afoakwa, E. O. (2016). Cocoa diChocolate science and technology. *Wiley-Blackwell*, 73-98.
<https://doi.org/https://doi.org/10.1002/9781118913758.ch4>
- Agrawal, K., y Navneet, K. (2025). Inteligencia artificial y aprendizaje automático en la agricultura: técnicas novedosas, estrategias de implementación y aplicaciones. En J. K. Pandey, M. Rai, y T. Sarkar, *Inteligencia computacional y procesamiento de imágenes en la agricultura: aplicaciones e innovaciones*. Wiley.
<https://doi.org/10.1002/9781394320905.ch04>
- Alabrese, M. (2023). El alcance regulatorio de la teledetección en la agricultura dentro del contexto de la Unión Europea: Regulaciones de la Política Agrícola Común en la intersección con la disciplina Copernicus. En *Derecho de la UE sobre agricultura sostenible y resiliente al clima después del Pacto Verde Europeo* (págs. 90-106). RURINNOVA–Editoriale Tecnico Scientifica.
- Alireza, S. F., y Rashid, R. (2025). Efficient deep learning for edge devices: Challenges and optimization techniques. *International Journal of Future Multidisciplinary Research*, 7(4), 1-15. <https://www.ijfmr.com/papers/2025/4/53530.pdf>
- Alotaibi, A., Abdullah , A., Bandar , A., y Faisal , A. K. (2024). Optimizing agricultural data security: Harnessing IoT and AI with Latency Aware Accuracy Index (LAAI). *PeerJ Computer Science*, 10. <https://doi.org/https://doi.org/10.7717/peerj-cs.2271>
- Barra, M. Á. (2025). Aplicación de inteligencia artificial en la detección temprana de plagas. *INGENIO*, 8(1), 24-34.
- Bazan Yaranga, C., Sanchez, Z., y Rodriguez, R. (2018). Transferencia de aprendizaje mediante redes neuronales convolucionales para el reconocimiento de conductores distraídos. *TECNIA*, 28(2). <https://doi.org/10.21754/tecnia.v28i2.549>

- Chakrabarty, S., Chandan , K. D., Sudeep , M., Haque, M., Deebea , K., Raju , B., y Pathour Rajendra Shashank, R. S. (2026). Application of artificial intelligence in insect pest identification: A review. *Artificial Intelligence in Agriculture*, 16(1), 44-61.
- Chavez Human, J., y Del Castillo Flores, J. (2023). Sistema de Deteccion de Plagas en la Hoja de Uva en el Departamento de la Libertad (Perú) Usando Algoritmo de Redes Neuronales Convolucionales Profundas. 288.
file:///C:/Users/Usuario/Downloads/Ch%C3%A1vez_HJ%20(1).pdf
- Cuevas-Tello, C., De la Rosa-Escalante, M. Á., y De la Cruz-Canul, J. (2022). Introducción al Deep Learning con TensorFlow y PyTorch. *Conferencia Latinoamericana de Informática (CLEI)*. <https://clei.org/site/wp-content/uploads/2022/12/Introducido-al-Deep-Learning-con-TensorFlow-y-PyTorch.pdf>
- Deenan, S. J. (2024). *Principles of Digital Image Processing for Agricultural Applications*. Nova Science Publishers. <https://doi.org/10.52305/LZGO5867>
- Galan Zapata, J. L. (2021). *Sistema inteligente de reconocimiento de imágenes para apoyar el diagnóstico de plagas y enfermedades en el cultivo de arroz en el departamento de Lambayeque en el año 2019*. Chiclayo, Perú: Universidad Católica Santo Toribio de Mogrovejo. <https://hdl.handle.net/20.500.12423/3216>
- Gutiérrez, J. (2024). La entrevista semiestructurada: una herramienta pertinente en la investigación cualitativa. *Revista de Ciencias Sociales*, 20(1), 88-105.
- iMaster, A. (s.f.). Introducción e instalación de TensorFlow. *TalentoTech (Módulo 2, Unidad 3)*. <https://imaster.academy/contenidos-tematicos/talentotech/TalentoTech/M2unidad3/Unidad3/Inteligencia%20artificial/Explorador/assets/files/4.-IntroduccioneininstalaciondeTensorFlow.pdf>

- Ismail, H. M., Awrangjeb, M., Pan, S., y Al Mamun, A. (2021). Transfer learning in agriculture: a review. *Artificial Intelligence Review*, 58(4).
<https://doi.org/10.1007/s10462-024-11081-x>
- Jefferson, G. (2021). Sistema inteligente de reconocimiento de imagenes para apoyar el diagnostico de plagas y enfermedades en el cultivo de arroz en el departamento de Lambayaque en el año 2019. *Universidad Catolica Santo Toribio de Mogrovejo*, 22.
<https://repositorio.usat.edu.pe/server/api/core/bitstreams/a08a6f46-d708-4be4-af61-8dbf34a230cd/content>
- Kamilaris, A., Liakos, K. G., y Prenafeta-Boldú, F. X. (2022). The power of transfer learning in agricultural applications: AgriNet. *Frontiers in Plant Science*, 13.
<https://doi.org/https://doi.org/10.3389/fpls.2022.992700>
- Mingxing, T., y Le, Q. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *Proceedings of the 36th International Conference on Machine Learning*. PMLR. <https://proceedings.mlr.press/v97/tan19a.html>
- Muñoz Quijano, F. J. (2018). *Evaluación de las mejoras tras la implementación de la norma de Buenas Prácticas Agrícolas reglamentada por el Instituto Colombiano Agropecuario en la producción de cacao (Theobroma cacao) y pimienta (Piper nigrum) en el Valle del Guamuez*. Universidad de Manizales.
<https://ridum.umanizales.edu.co/server/api/core/bitstreams/2b672585-e80d-4545-ab28-b9844410e86e/content>
- Organization, W. I. (2022). *Early warning systems, modelling and monitoring (Green Technology Book: Agriculture and forestry section)*. WIPO.
- Organization, W. I. (2022). *Early warning systems, modelling and monitoring (Green Technology Book: Agriculture and forestry section)*. WIPO.

- Research, A. C. (2017). *Papua New Guinea cocoa farmer's handbook* (4. ed.). Australian Centre for International Agricultural Research. <https://research.aciar.gov.au/tadep/wp-content/uploads/2021/02/PNG-Cocoa-Farmers-Handbook-4-Sept-2017.pdf>
- SGA UNEMI. (s. f.). *Técnicas e instrumentos de investigación*. SGA UNEMI: <https://sga.unemi.edu.ec>
- Sharma, P. (2022). Application of TensorFlow Lite on embedded devices. *University of Gävle*. <http://www.diva-portal.org/smash/record.jsf?pid=diva2:1698946>
- Torres, D. R., y Ballesteros, D. M. (2023). *Fundamentos de visión por computador utilizando aprendizaje profundo*. Editorial REDIPE.
- Utomo, B. S., Ariyanto, A., y Sari, R. F. (2023). Development of a mobile application for plant disease detection using convolutional neural networks. *EMITTER International Journal of Engineering Technology*, 11(2). <https://emitter.pens.ac.id/index.php/emitter/article/view/808>
- Yang, Q., Yu, Z., Dai, W., y Pan, S. J. (2020). *Transfer Learning*. Prensa de la Universidad de Cambridge. <https://www.cambridge.org/core/books/transfer-learning/>
- Yildiz, F., Chellappa, R., y Wu, Y. (2024). MicroTL: Transfer learning on low-power IoT devices. *IEEE Internet of Things Journal*, 11(3), 2157-2173. https://research.chalmers.se/publication/533597/file/533597_Fulltext.pdf

ANEXOS

Anexo A Asignación de docente 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 MÓVIL CON TRANSFER LEARNING PARA DETECCIÓN TEMPRANA DE ARTRÓPODOS FITÓFAGOS EN CULTIVOS DE THEOBROMA CACAO EN 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: REASCOS PINCHAO RAUL SAED

Apellidos y nombres del estudiante: ALCIVAR ZAMBRANO JENY SELENA


Carrera: SOFTWARE 2024 - NS - (EL CARMEN)

Periodo de Inducción: Periodo 2025-2

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

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

Anexo B. Primer entrenamiento



```

73 print("\n Fase 1: Entrenando cabeza del modelo...")
74 model.fit(train_gen, validation_data=valid_gen, epochs=15)
75
76 print("\n Fase 2: Fine-tuning...")
77 base_model.trainable = True
78 for layer in base_model.layers[-10]:
79     layer.trainable = False
80
81 model.compile(
82     optimizer=tf.keras.optimizers.Adam(1e-5),
83     loss='categorical_crossentropy',
84     metrics=['accuracy'])
85
86 model.fit(train_gen, validation_data=valid_gen, epochs=25)
87
88 model.save("modelo/cacao_multi_model.h5")
89 print("\n Modelo guardado en: modelo/cacao_multi_model.h5")
90 print("\n Clases guardadas en: modelo/clases.txt")


```

PROBLEMAS OUTPUT DEBUG CONSOLE TERMINAL PORTS

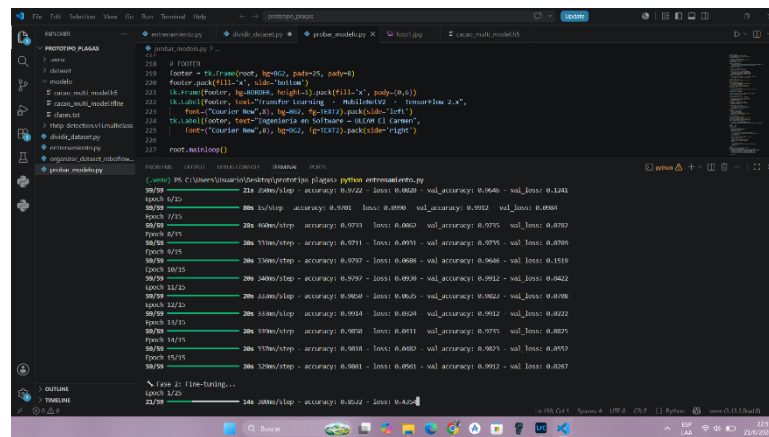
(venv) PS C:\Users\Usuario\Desktop\prototipo_plagas> python entrenamiento.py

Epoch	1/15	2/15	3/15	4/15	5/15
100%	923ms/step	106 517ms/step	86 463ms/step	75 489ms/step	46 558ms/step
accuracy	0.7393	0.9071	0.9536	0.9821	0.9638
loss	0.7078	0.2284	0.1681	0.0653	0.0906
val_accuracy	0.9444	0.9815	0.9815	0.9815	0.9815
val_loss	0.1339	0.0750	0.0548	0.0689	


Anexo C Etiquetado de clases




Anexo D Reentrenamiento del modelo




Anexo E Pruebas de funcionamiento



Anexo F pruebas de funcionamiento



Anexo G Prueba de funcionamiento en interfaz para móvil.



Anexo H Capturando imágenes para el dataset.



Anexo I Realizando entrenamiento al modelo



Anexo J Entrevista al Ing. Pedro Nivelá



Anexo K. Certificado de coincidencia académica



GLOSARIO

accuracy (Exactitud): Métrica que indica el porcentaje total de predicciones correctas realizadas por un modelo de clasificación, calculada sobre el total de casos evaluados.

¡Error! No se encuentra el origen de la referencia.: Sistema operativo móvil desarrollado por Google, utilizando como plataforma el despliegue de la aplicación en dispositivos inteligentes.

API (Applicacion Programming Interface): Conjunto de reglas y protocolos que permite la comunicación entre distintos componentes de software.

artrópodo fitófago: Organismo invertebrado del filo Arthropoda que se alimenta de tejido vegetal, causando daños directos a los cultivos.

aprendizaje automático: Rama de la inteligencia artificial que permite a los sistemas aprender patrones a partir de datos sin ser programados explícitamente para cada tarea.

Backlog (Product Backlog): Lista priorizada de todas las funcionalidades y requerimientos pendientes de un proyecto, gestionado bajo la metodología Scrum.

CNN (Red Neuronal Convolutacional): Arquitectura de red neuronal profunda especializada en el procesamiento de imágenes capaz de extraer patrones visuales como bordes, texturas y formas.

¡Error! No se encuentra el origen de la referencia.: Valor numérico, expresado en porcentaje que indica qué tan segura está una red neuronal de que su predicción es correcta.

convolutacional: Adjetivo que describe operaciones matemáticas basadas en filtros que recorren una imagen para detectar patrones visuales, propias de las redes neuronales convolucionales.

dataset: Conjunto estructurado de datos como imágenes utilizado para entrenar y evaluar un modelo de inteligencia artificial.

depuración: Proceso de revisión en limpieza de un conjunto de datos con el fin de eliminar duplicados o inconsistencias que puedan afectar la evaluación de un modelo.

Recall: Métrica que indica la proporción de casos positivos reales que un modelo logró identificar correctamente.

F1-score: Métrica que combina precisión y exhaustividad en un solo valor, útil para evaluar el desempeño de un modelo.

fitosanitario: Relativo a la protección de las plantas frente a plagas y enfermedades.

¡Error! No se encuentra el origen de la referencia.: Framework de desarrollo de software de código abierto, creado por Google, utilizado para construir aplicaciones móviles multiplataforma.

fuga de datos (Data leakage): Problema que ocurre cuando información del conjunto de validación se filtra al conjunto de entrenamiento generando métricas de desempeño infladas y poco confiable.

Historia de usuario (User Story): Descripción breve de una funcionalidad desde la perspectiva del usuario final utilizada en metodologías ágiles para definir requerimientos.

inferencia: Proceso mediante el cual un modelo entrenado genera una predicción a partir de una nueva entrada de datos.

iNaturalist: Plataforma colaborativa en línea que aloja registros fotográficos de flora y fauna utilizada como fuente de imagen para el dataset.

Kaggle: Plataforma en línea que aloja conjunto de datos públicos y competencias de Ciencias de datos utilizada como fuente de imagen para el entrenamiento del modelo.

Laplaciano (Filtro Laplaciano): Operador matemático utilizado en procesamiento de imágenes para detectar bordes aplicado en este proyecto para calcular la nitidez de una fotografía.

Python: Lenguaje de programación utilizado para el desarrollo del entrenamiento y procesamiento del modelo de inteligencia artificial.

reentrenamiento: Proceso mediante el cual un modelo previamente entrenado es ajustado nuevamente con datos adicionales con el fin de mejorar o corregir su desempeño.

Scrum: Marco de trabajo ágil para la gestión y desarrollo de proyectos de software, organizado en ciclos cortos denominado Sprints.

Sprints: Ciclo de trabajo de duración fija, propio de la metodología Scrum, al final del cual se debe obtener un incremento funcional del producto.

Sprint Retrospective: Análisis realizado al finalizar un sprint, orientado a identificar a ciertas dificultades y oportunidades de mejora.

Sprint Review: Instancia de revisión al finalizar un sprint, donde se evalúa el funcionamiento del incremento desarrollado.

TensorFlow: Biblioteca de Código abierto desarrollada por Google utilizada para la construcción y entrenamiento de modelos de aprendizaje automático.

TensorFlowLite: Versión optimizada de Tensor Flow diseñada para ejecutar modelos de inteligencia artificial en dispositivos móviles sin necesidad de conexión a Internet.

Theobroma Cacao: Nombre científico del árbol de cacao cultivo del cual se extrae la materia prima para la elaboración de chocolate.

Transfer Learning : Técnica de aprendizaje automático que reutiliza el conocimiento de un modelo previamente entrenado en una tarea para resolver una tarea distinta pero relacionada.

umbral de confianza: Valor mínimo de certeza que debe alcanzar una predicción para ser aceptada como válida por el sistema, las predicciones por debajo de este valor son rechazadas.