



Plataforma web y móvil para la planificación de cosecha de cacao basada en visión artificial y arquitectura serverless

Moreira Zambrano, Melany Rosmery y Chevez Bazan, Karlos Gregory

Departamento de Ciencias de la Computación
Carrera en Tecnologías de la Información

Trabajo de integración curricular, previo a la obtención del título de ingeniero en
Tecnologías de la Información y Comunicación

Mgtr. Cruz Garzón, John Javier

31 de Julio de 2026

Certificado de análisis

Compilatio Magister+ | ESPE-ECU

Plataforma web y móvil para la planificación de cosecha de cacao basada en visión artificial y arquitectura serverless

ID : 416229af8575c6f46c68e6e885c6781a7c81c05f

8%

Textos sospechosos

Nombre del fichero : Plataforma web y móvil para la planificación de cosecha de cacao basada en visión artificial y arquitectura serverless.bit

Tamaño del archivo original : 709,35 kB

Número de palabras : 19.410

Depositante : John Javier Cruz Garzón

Fecha de depósito : 28 de agosto de 2026

Tipo de carga : Interface

fecha de fin de análisis : 28 de agosto de 2026

Resumen

(sección 1/2)

Localización de los textos sospechosos en el documento :

Incluido en el porcentaje de textos sospechosos :

Similitudes

<1%

Pasajes con similitudes a fuentes encontradas en diferentes colecciones.

Detección de IA

5%

Textos estilísticamente próximos a un texto generado por una IA.

Este índice es un indicador y no una prueba. Comprueba con el autor si domina los conocimientos mencionados en el documento.

Idiomas no reconocidos

3%

Pasajes en los que parte del vocabulario utilizado no forma parte del diccionario de la lengua.

Puede tratarse de un intento del autor de modificar el texto para evitar ser detectado.

Similitudes

<1%

Pasajes con similitudes a fuentes encontradas en diferentes colecciones.

Fuente con similitudes fortuitas

Nº	Descripciones	Similitudes	Ubicaciones
1	repositorio.usc.edu.co repositorio.usc.edu.co/bitstreams/ddb12ba2-5430-4b77-b2de-a2bd5aad6d...	<1%	
2	Visión computacional y aprendizaje profundo para el fenotipado d... repositorio.puce.edu.ec/handle/123456789/46275	<1%	
3	Documento de otro usuario #868be0 Viene de de otro grupo	<1%	
4	burjcdigital.urjc.es burjcdigital.urjc.es/bitstreams/174400c3-3518-4bc7-9189-d242de545041/d...	<1%	

Fuente mencionada (sin similitudes detectadas)

Nº	Descripciones
1	https://github.com/MelanyMoreiraZambrano/tesis-cacao
2	https://github.com/gregoryNa9/Tesis_Plataforma_Cacao

Mgtr. Cruz Garzón, John Javier
Director



Departamento de Ciencias de la Computación

Carrera de Ingeniería en Tecnologías de la Información

Certificación

Certifico que el trabajo de integración curricular: **“Plataforma web y móvil para la planificación de cosecha de cacao basada en visión artificial y arquitectura serverless”** fue realizado por los señores **Moreira Zambrano, Melany Rosmery y Chevez Bazan, Karlos Gregory**, el mismo que cumple con los requisitos legales, teóricos, científicos, técnicos y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE; habiéndose efectuado una revisión integral de forma y de fondo conforme a los lineamientos y formatos institucionales vigentes. Además, fue revisado y analizada en su totalidad por la herramienta de prevención y/o verificación de similitud de contenidos; razón por la cual me permito acreditar y autorizar para que se lo sustente públicamente.

Santo Domingo de los Tsáchilas, 31/07/2026

Mgtr. Cruz Garzón, John Javier

Director

C.C.: 1205926148



ESPE

UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

Departamento de Ciencias de la Computación

Carrera de Ingeniería en Tecnologías de la información

Responsabilidad de Autoría

Nosotros, **Chevez Bazán, Karlos Gregory y Moreira Zambrano, Melany Rosmery**, con cédulas de ciudadanía n.º 0952799708 y n.º 2300710866, declaro/declaramos que el contenido, ideas y criterios del trabajo de integración curricular: **Plataforma web y móvil para la planificación de cosecha de cacao basada en visión artificial y arquitectura serverless** es de mi/nuestra autoría y responsabilidad, cumpliendo con los requisitos legales, teóricos, científicos, técnicos, y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

Santo Domingo de los Tsáchilas, 31/07/2026

Chevez Bazán, Karlos Gregory

C.C.: 0952799708

Moreira Zambrano, Melany Rosmery

C.C.: 2300710866



ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

Departamento de Ciencias de la Computación

Carrera de Ingeniería en Tecnologías de la información

Autorización de Publicación

Nosotros, **Chevez Bazán, Karlos Gregory y Moreira Zambrano, Melany Rosmery**, con cédulas de ciudadanía n.º 0952799708 y n.º 2300710866, autorizamos a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de integración curricular: **Plataforma web y móvil para la planificación de cosecha de cacao basada en visión artificial y arquitectura serverless en el Repositorio Institucional**, cuyo contenido, ideas y criterios son de mí/nuestra responsabilidad.

Santo Domingo de los Tsáchilas, 31/07/2026

Chevez Bazán, Karlos Gregory

C.C.: 0952799708

Moreira Zambrano, Melany Rosmery

C.C.: 2300710866

Dedicatoria

Hoy concluye una etapa que comenzó hace varios años con un sueño y la ilusión de convertirme en profesional. Al mirar hacia atrás, comprendo que cada esfuerzo, cada sacrificio y cada desafío fueron parte del camino que me condujo hasta este momento. Me dedico este logro a mí misma, por la disciplina, el esfuerzo y la perseverancia que tuve durante todos estos años. Por no rendirme cuando las dificultades parecían superar mis fuerzas y por confiar en que cada sacrificio realizado tendría su recompensa.

A mi papá, porque este título lleva impreso el esfuerzo de tus manos y el sacrificio de toda una vida. Gracias por recorrer las carreteras durante días, por las noches sin dormir, por las largas jornadas al volante de un tráiler y por cada sacrificio que hiciste para que yo tuviera las oportunidades que tú soñabas para mí. Sé que muchas veces soportaste el cansancio, la distancia e incluso dejaste de lado tus propias necesidades con tal de brindarme una educación y una vida mejor. Hoy puedo decir con orgullo que este logro también te pertenece, porque el mayor anhelo de tu corazón siempre fue verme convertirme en profesional, y gracias a tu esfuerzo ese sueño hoy se hace realidad.

A mi mamá, por acompañarme incondicionalmente en cada etapa de este camino. Gracias por tus palabras de aliento en los momentos de mayor dificultad, por escucharme cuando más lo necesitaba y por recordarme siempre que los sueños se alcanzan con esfuerzo y perseverancia. Tu amor, paciencia y confianza fueron la fuerza que muchas veces necesité para continuar.

A mis hermanos, Johan y Meili, por formar parte de mi vida y por compartir conmigo cada etapa de este camino. Gracias por su cariño, por las alegrías compartidas y por motivarme de una u otra manera, a ser mejor persona. Deseo que este logro les recuerde que no existen metas imposibles cuando se trabaja con dedicación, constancia, fé y sobretodo de la mano de Dios.

Melany Rosmery Moreira Zambrano

Dedicatoria

Dedico este proyecto de titulación, en primer lugar, a mis padres, Carlos Chevez y Helen Bazán, quienes con su amor, esfuerzo, confianza y apoyo incondicional han sido un pilar fundamental durante toda mi formación académica. Este logro también les pertenece, pues su motivación y respaldo me dieron fuerzas para continuar en aquellos momentos en los que pensé en rendirme. Gracias por creer siempre en mí y por enseñarme que, con perseverancia y dedicación, es posible alcanzar cada meta.

A mis hermanos, Khris, Yarik, Yirak y Melissa, por formar parte de mi vida y acompañarme a lo largo de este camino. Gracias por su apoyo, compañía y por estar presentes tanto en los buenos momentos como en aquellos más difíciles. Este logro también lleva una parte de ustedes.

A mis abuelitas, Mariana Moreira y Mercedes Arana, y a mis abuelos, Manuel Chevez y Bolívar Bazán, por su cariño, consejos y enseñanzas. Gracias por transmitirme valores que han contribuido a formar la persona que soy y por ser ejemplo de esfuerzo, fortaleza y perseverancia.

De manera especial, dedico este logro a quien hoy me cuida desde el cielo, cuya presencia permanece viva en mi corazón y cuyo recuerdo me acompañó durante todo este camino. A mis tías, Grace Tandazo y Johana Bazán, por su cariño, apoyo y por estar presentes en diferentes etapas de mi vida, brindándome sus palabras, consejos y respaldo durante este proceso.

Finalmente, dedico este proyecto a mi familia y a todas las personas que creyeron en mí y contribuyeron, de una u otra manera, a alcanzar esta meta. Este logro representa años de esfuerzo, sacrificio, aprendizaje y crecimiento, por lo que no lo considero únicamente mío, sino también de quienes caminaron a mi lado y me impulsaron a seguir adelante.

Chevez Bazan, Karlos Gregory

Agradecimiento

Al culminar esta etapa de mi vida, deseo expresar mi gratitud a Dios, por acompañarme en cada paso del camino, darme la fortaleza en los momentos de dificultad y permitirme alcanzar una meta que representa el esfuerzo de muchos años de estudio y dedicación.

Mi sincero agradecimiento a nuestro tutor de tesis, Ing. Jhon Cruz por compartir sus conocimientos, orientar este trabajo con profesionalismo y brindar el tiempo necesario para mejorar cada etapa de este proyecto.

De manera especial, agradezco al Ing. Patricio Vaca por su disposición y colaboración durante el desarrollo de este proyecto. Gracias por compartir sus conocimientos sobre el cultivo de cacao y por facilitar el acceso a su lote de producción, donde fue posible realizar la validación de la plataforma y obtener información de gran valor para este proyecto.

Agradezco también al Ing. Paulo Galarza, quien desde los inicios de este proyecto brindó su apoyo, orientación y valiosos aportes, contribuyendo a la definición y desarrollo del proyecto. A los docentes de la Carrera de Ingeniería en Tecnologías de la Información de la Universidad de las Fuerzas Armadas - ESPE Sede Santo Domingo, mi gratitud por compartir sus conocimientos, experiencias y enseñanzas durante mi formación académica. Cada aprendizaje recibido ha contribuido a mi crecimiento profesional y personal.

A mi compañero de tesis, Gregory Chevez, con quien tuve la oportunidad de compartir varios años de formación académica. Gracias por el compromiso, la dedicación y el trabajo en equipo demostrados durante este proceso.

Finalmente, a mi familia, por ser el motor que me impulsó a seguir adelante en cada etapa de este camino. Gracias por su amor, comprensión, paciencia y apoyo incondicional, por creer en mi y por acompañarme en los momentos de mayor esfuerzo. Este logro también les pertenece, porque sin su confianza y respaldo habría sido mucho mas difícil alcanzar esta meta.

Melany Rosmery Moreira Zambrano

Agradecimiento

Expreso mi más sincero agradecimiento a la Universidad de las Fuerzas Armadas ESPE, por haberme brindado la oportunidad de formarme académica y profesionalmente, así como por los conocimientos, experiencias y valores adquiridos a lo largo de esta etapa. A cada docente que formó parte de mi formación, gracias por compartir sus conocimientos y contribuir al desarrollo de las capacidades que hoy me permiten culminar esta carrera.

De manera especial, agradezco a Jhon Cruz tutor de tesis por su orientación, paciencia, tiempo y conocimientos durante el desarrollo de este proyecto de titulación. Sus observaciones, recomendaciones y acompañamiento fueron fundamentales para superar cada dificultad y culminar satisfactoriamente este trabajo.

A mi compañera de tesis, Melany Moreira, gracias por el compromiso, esfuerzo, responsabilidad y dedicación compartidos durante todo este proceso. El trabajo en equipo, las ideas, los desafíos superados y las largas jornadas hicieron posible alcanzar juntos esta meta.

A mis padres, por su amor, sacrificio, confianza y apoyo incondicional durante toda mi formación académica. Gracias por motivarme a continuar incluso en los momentos más difíciles y por ser una fuente constante de fortaleza para alcanzar mis objetivos.

A mis hermanos, abuelos, abuelitas, tíos y tías, por su cariño, consejos, palabras de ánimo y por estar presentes a lo largo de este camino. Cada uno, de distintas maneras, ha contribuido a mi crecimiento personal y ha sido parte importante de este logro.

Finalmente, agradezco a todas aquellas personas que me acompañaron durante esta etapa y que, con una palabra, un consejo o un gesto de apoyo, contribuyeron a que pudiera llegar hasta este momento. A todos ustedes, mi más profunda gratitud.

Chevez Bazan, Karlos Gregory

ÍNDICE

Dedicatoria	6
Dedicatoria	7
Agradecimiento	8
Agradecimiento	9
Resumen	14
Abstract	15
1 Introducción	16
1.1 Planteamiento del problema	18
1.1.1 Contexto general	18
1.1.2 Situación actual	18
1.1.3 Brecha o problema específico	19
1.2 Formulación del problema	20
1.3 Objetivos	20
1.3.1 Objetivo general	20
1.3.2 Objetivos específicos	20
1.4 Justificación	20
2 Marco Teórico	22
2.1 El cultivo del cacao	23
2.1.1 El clon CCN-51	23
2.1.2 Enfermedades del cacao	24
2.2 Agricultura de precisión y planificación de la cosecha	26
2.2.1 Planificación de la cosecha	27
2.2.2 Grados Día de Desarrollo (Growing Degree Days)	28
2.2.3 Aplicación de los GDD en la planificación de la cosecha del cacao	29
2.3 Inteligencia artificial aplicada a la agricultura	29
2.3.1 Aprendizaje profundo (Deep Learning)	30
2.3.2 Visión por computador	31
2.3.3 Redes neuronales convolucionales	31
2.3.4 Modelo YOLO	32
2.4 Métricas utilizadas para evaluar los modelos de inteligencia artificial.	32
2.5 Métricas de evaluación de modelos de detección	33
2.5.1 Precisión (Precision)	33
2.5.2 Exhaustividad (Recall)	34
2.5.3 Medida F1	34
2.5.4 Intersección sobre Unión (IoU)	35
2.5.5 Precisión Media Promedio (mAP)	35
2.6 Estimación de la severidad de la enfermedad	36
2.7 Sistemas de información para el monitoreo agrícola	36
2.7.1 Aplicaciones web	37
2.7.2 Aplicaciones móviles	37
2.7.3 Arquitectura cliente-servidor	38
2.7.4 API REST	38
2.8 Estado del Arte	39
2.8.1 Aplicaciones de YOLO en el cultivo de cacao	39

2.9	Síntesis del estado del arte	41
3	Metodología	43
3.1	Metodología de desarrollo de la investigación.	43
3.2	Metodología de desarrollo	44
3.2.1	Fase 1. Levantamiento de requerimientos	45
3.2.2	Fase 2. Diseño del sistema	48
3.2.3	Fase 3. Implementación	51
3.2.4	Preparación del conjunto de datos	55
3.2.5	Fase 4. Pruebas	58
3.2.6	Fase 5. Validación	59
3.3	Disponibilidad del código fuente	59
4	Análisis y discusión de los resultados	61
4.1	Resultados funcionales	61
4.1.1	Validación de las funcionalidades del administrador	61
4.1.2	Validación de las funcionalidades del técnico	65
4.1.3	Validación de las funcionalidades del agricultor	70
4.2	Resultados no funcionales	72
4.2.1	Integración entre los componentes	72
4.2.2	Control de acceso	73
4.2.3	Compatibilidad entre las aplicaciones	73
4.2.4	Persistencia de la información	74
4.3	Evaluación de los modelos de visión artificial	74
4.3.1	Evaluación del modelo de madurez	74
4.3.2	Evaluación del modelo de enfermedades	80
4.4	Discusión de resultados	86
5	Conclusiones y recomendaciones	88
5.1	Conclusiones	88
5.2	Recomendaciones	89
5.3	Trabajos futuros	89
	Referencias Bibliográficas	90

ÍNDICE DE FIGURAS

Figura 1. Metodología de desarrollo de la investigación	44
Figura 2. Etapas del modelo de desarrollo en cascada empleadas durante la implementación del sistema.	45
Figura 3. Diagrama general de casos de uso del sistema.	46
Figura 4. Arquitectura de plataforma web y móviil para planificación de cosecha de cacao basada en visión artificial.	49
Figura 5. Modelo entidad-relación de la base de datos.	50
Figura 6. Estructura del Backend.	52
Figura 7. Implementación física de la base de datos en PostgreSQL (Supabase).	55
Figura 8. Servicio de IA implementado utilizando FastAPI.	56
Figura 9. Flujo de procesamiento de una captura y entrega de resultados.	57
Figura 10. Prueba de funcionamiento de un endpoint de la API REST implementada para la consulta de lotes mediante autenticación JWT.	58
Figura 11. Procesamiento de grabación de imágenes de mazorcas de cacao durante la validación funcional de la plataforma en el lote Valle Hermoso.	59
Figura 12. Gestión de usuarios disponible para el rol administrador en las aplicaciones web y móvil.	62
Figura 13. Gestión de lotes disponible para el rol administrador en las aplicaciones web y móvil.	63
Figura 14. Consulta de la planificación de cosecha desde las aplicaciones web y móvil.	64
Figura 15. Módulo de reportes disponible para el rol administrador en las aplicaciones web y móvil.	64
Figura 16. Consulta de lotes desde las aplicaciones web y móvil para el rol técnico.	65
Figura 17. Registro de capturas para el análisis del cultivo desde la aplicación móvil.	66
Figura 18. Resultado del análisis obtenido para una captura del lote Valle Hermoso.	67
Figura 19. Historial de capturas ingresadas.	68
Figura 20. Planificación de la cosecha desde el rol de técnico.	69
Figura 21. Reporte técnico de planificación de cosecha.	69
Figura 22. Vista de lotes asignados por agricultor.	70
Figura 23. Diagnósticos desde el rol de agricultor.	71
Figura 24. Planificación de cosecha de lotes asignados al agricultor.	72
Figura 25. Curva F1-score confianza del modelo de madurez basado en YOLOv8.	75
Figura 26. Curva precisión–confianza del modelo de madurez basado en YOLOv8.	76
Figura 27. Curva sensibilidad–confianza del modelo de madurez basado en YOLOv8.	77
Figura 28. Curva Precisión–Sensibilidad del modelo de madurez basado en YOLOv8.	78
Figura 29. Matriz de confusión del modelo de madurez basado en YOLOv8.	80
Figura 30. Curva F1-modelo de confianza en enfermedades fundamentado en YOLOv8.	81
Figura 31. Curva precisión–confianza del modelo de enfermedades basado en YOLOv8.	82
Figura 32. Curva de sensibilidad–nivel de confianza del modelo de enfermedades fundamentado en YOLOv8.	83
Figura 33. Curva Precisión–Sensibilidad del modelo de enfermedades basado en YOLOv8.	84
Figura 34. Matriz de confusión normalizada del modelo de enfermedades basado en YOLOv8.	85

ÍNDICE DE TABLAS

Tabla 1.	Comparación de trabajos relacionados con la presente investigación	41
Tabla 2.	Aplicación del modelo en cascada durante el desarrollo del proyecto	45
Tabla 3.	Requerimientos funcionales del sistema	47
Tabla 4.	Requerimientos no funcionales del sistema	48
Tabla 5.	Resultados de precisión promedio por clase del modelo de madurez.	79
Tabla 6.	Resultados de precisión promedio por clase del modelo de enfermedades. . . .	84

Resumen

Gestión de la cosecha de cacao para una mejor producción. La gestión de la cosecha de cacao necesita disponer de información sobre el estado de salud de las vainas y la madurez para que la toma de decisiones sea eficaz en la producción. Basta con que muchas fincas cacaoteras aún tengan que depender de inspecciones visuales para tal información. Para ayudar a planear la cosecha, este estudio propone un sistema web y móvil que permite automatizar el proceso empleando la tecnología de visión artificial. El sistema se diseñó basado en el modelo de cascada. La plataforma introduce funcionalidades para usuarios, grupos de usuarios, capturas, diagnósticos, planificación de cosechas e informes, lo que proporciona mayor coherencia para administradores, técnicos y agricultores a la hora de mantener la información estructurada y accesible. Validación de la funcionalidad: en el campo (Valle Hermoso, surco entre Perú y Bolivia, a 3639 m), los módulos base estaban en funcionamiento y los diversos elementos del sistema interactuaban entre sí. En lo que respecta a los modelos de visión artificial, un mAP@0.5 de 0.710 y 0.750 para la clasificación de madurez y detección de enfermedades, respectivamente, indicando buen desempeño en apoyo al monitoreo de cultivos y la planificación de cosechas.

Palabras clave: cacao CCN-51, visión artificial, YOLOv8n, planificación de cosecha, diagnóstico fitosanitario.

Abstract

For the cocoa harvest planning process to work accurately, reliable information about the ripening and health status of cocoa pods is necessary. Many plantations still depend on visual inspections and the use of manual records to gather this data from trees, which makes it difficult to conduct timely crop analysis. To tackle these problems, this project developed a web and mobile application utilizing computer vision methods to support cocoa harvest planning for the cocoa type CCN-51. The application is designed in accordance with the Waterfall model and consists of a web application designed with React and TypeScript, a mobile application developed with React Native and Expo technologies, a RESTful API made with Node.js, Express and TypeScript, a PostgreSQL database, and artificial intelligence microservices designed with FastAPI technology. To address the image processing task, two computer vision models were created: the first determines whether a cocoa pod is ripening, while the second identifies diseases. Functional tests were performed in Valle Hermoso, where the functionality of all key modules of the system and the ability of the platform components to interact were tested. The use of computer vision achieved mAP@0.5 of 0.710 for ripeness-stage classification and 0.750 for disease detection, which supports the applicability of the framework for crop monitoring and management.

Keywords: CCN-51 cocoa, computer vision, YOLOv8n, harvest planning, plant disease detection.

Capítulo 1

Introducción

El cacao es uno de los principales productos agrícolas del Ecuador y representa una fuente de ingresos para miles de productores ubicados en diferentes provincias del país [1]. Entre las variedades que se cultivan, el clon CCN-51 se destaca por su elevada producción, por su adaptabilidad a diferentes condiciones ambientales y por la contribución que realiza a la producción nacional [2]. Por lo tanto, el cultivo de esta planta y la planificación de la cosecha se ven afectados por estos factores, lo que se traduce en el producto y en los ingresos que obtiene el agricultor en cada periodo de producción. Con el fin de conocer el estado de los frutos y la posible afectación en la producción de los mismos, se recomiendan inspecciones periódicas durante el desarrollo del cultivo [2].

La información recabada en estas visitas se utiliza para apoyar la planificación de la cosecha y la definición de la estrategia relacionada con el manejo fito-sanitario del cultivo [3]. No obstante, su utilidad estriba en que los registros sean sencillos de organizar y consultar. En varias fincas la información recabada durante las inspecciones no ha cambiado de ser anotada manualmente en papel, archivada como fotografías, o documentación con archivos separados [3]. Esto complica un poco la tarea de revisar el historial de un lote para luego comparar los resultados obtenidos en diferentes fechas y para hacer un seguimiento continuo del cultivo [3]. Por lo tanto, la información con que se realiza la planificación para la cosecha se encuentra generalmente dispersa y desorganizada.

Las enfermedades del cacao siguen siendo una de las mayores fuentes de pérdida de producción cuando no se detectan a tiempo [4]. Entre las más representativas se cuentan la moniliasis y la fitóftora, por los efectos que causan sobre el rendimiento y la calidad de los frutos [5]. Para ello, contar con herramientas que faciliten el seguimiento sanitario del cultivo puede permitir la detección de estos problemas con mayor anticipación. Los desarrollos en agricultura de precisión (AP) han posibilitado la integración de tecnologías digitales para asistir en diversas tareas asociadas al manejo de los cultivos [3].

Entre ellas, la visión por computador ha mostrado buenos resultados en aplicaciones como la

madurez del fruto de forma automática y la detección de enfermedades por medio del análisis de imágenes [3]. Sin embargo, gran parte de estas investigaciones se centran en el rendimiento de los modelos de inteligencia artificial y poco atienden al manejo de la información generada en las inspecciones.

Se desarrolló en este trabajo una plataforma web y móvil para la planificación de la cosecha de cacao CCN-51 utilizando técnicas de visión artificial. La plataforma cubre desde la administración de usuarios, lotes, capturas de imágenes y diagnósticos fito-sanitarios hasta la planificación de la cosecha y reportes en un único sistema. De esta manera la información generada en las inspecciones siempre está ordenada y es consultable para hacer seguimiento de los cultivos.

La plataforma fue construida con una arquitectura cliente-servidor. Consiste en una aplicación web creada con React y TypeScript, una aplicación móvil desarrollada con React Native y Expo, una API REST hecha con Node.js y Express, una base de datos PostgreSQL gestionada por Supabase y un microservicio que procesa imágenes en FastAPI. También, se aprovechó Cloudflare R2 para guardarlas imágenes y autenticación basada en JSON Web Tokens (JWT) para gestión de acceso de usuarios. Esto hace más fácil que cada módulo sea mantenido y la separación de la gestión de la plataforma de la computación realizada por los modelos de visión artificial.

Se entrenaron dos modelos basados en la variante YOLOv8n para el procesamiento de imágenes. Uno se usó para distinguir el nivel de madurez de las mazorcas y el otro para identificar enfermedades en los frutos. Los dos modelos se implementaron en la plataforma de forma que los resultados obtenidos quedaban almacenados en el historial de cada lote y podían ser consultados según el rol de usuario.

Este documento está dividido en cinco capítulos. El Capítulo 1 incluye el planteamiento, los objetivos y la justificación de la investigación. Antecedentes técnicos relacionados con el cultivo del cacao, la visión por computador y las tecnologías utilizadas son discutidos en el Capítulo 2. Metodología y desarrollo de la plataforma se describen en el Capítulo 3. Capítulo 4 presenta los resultados de la validación funcional y la evaluación en los modelos de visión artificial. Finalmente, en el capítulo 5 se presentan las conclusiones, recomendaciones y trabajos futuros derivados de la investigación.

1.1 Planteamiento del problema

1.1.1 Contexto general

El cacao constituye uno de los principales productos agrícolas del Ecuador y representa una fuente importante de ingresos para miles de pequeños y medianos productores del país [1]. Además de su importancia económica, este cultivo forma parte de las actividades que aportan al sector agroexportador nacional y requiere un manejo adecuado para mantener su productividad y calidad [6], [7]. En este contexto, el seguimiento permanente del cultivo resulta fundamental para apoyar las actividades de producción.

El manejo de una plantación de cacao requiere realizar inspecciones periódicas para evaluar el estado fitosanitario, el desarrollo de las mazorcas y las condiciones presentes en cada lote [2]. Estas actividades proporcionan información que sirve de apoyo para planificar la cosecha y definir las labores agronómicas que deben ejecutarse durante el ciclo del cultivo [1]. Sin embargo, la utilidad de esta información depende de que pueda registrarse y consultarse de manera organizada.

La agricultura de precisión ha incorporado tecnologías digitales que permiten mejorar el monitoreo de los cultivos y apoyar la toma de decisiones mediante el uso de información obtenida en campo [8]. Del mismo modo, el análisis de datos agrícolas y el empleo de herramientas tecnológicas han contribuido a optimizar la gestión de los procesos productivos en diferentes sistemas agrícolas [9]. A pesar de estos avances, su incorporación en el manejo cotidiano de plantaciones de cacao todavía es limitada.

1.1.2 Situación actual

En las plantaciones de cacao de Santo Domingo de los Tsáchilas, las labores de producción se desarrollan en fincas con diferentes características de manejo y niveles tecnológicos, donde el seguimiento del cultivo forma parte de las actividades habituales realizadas por los productores [10]. Durante las inspecciones de campo se evalúa el estado de las mazorcas y se identifican posibles síntomas de enfermedades para apoyar las decisiones relacionadas con el manejo del cultivo [2]. Como resultado, gran parte de las decisiones dependen de la información obtenida durante cada recorrido realizado en el lote.

Los registros generados durante estas actividades generalmente se conservan mediante anotaciones manuales, fotografías o archivos almacenados de forma independiente [9]. Esta forma de trabajo dificulta consultar inspecciones anteriores, comparar resultados entre diferentes fechas y mantener un historial organizado de cada lote [11]. En consecuencia, el seguimiento del cultivo demanda más tiempo y limita la disponibilidad de información para apoyar la toma de decisiones.

Las enfermedades del cacao representan una de las principales causas de pérdidas durante la producción cuando no son identificadas oportunamente [12]. Entre las más importantes se encuentran la moniliasis y la fitóftora, debido al impacto que generan sobre el rendimiento y la calidad de los frutos [13], [14]. Esta situación hace necesario realizar un monitoreo continuo que permita detectar estos problemas antes de que afecten una mayor cantidad de plantas.

1.1.3 Brecha o problema específico

Las técnicas de visión por computador y aprendizaje profundo han demostrado resultados favorables en tareas relacionadas con la detección y clasificación automática de objetos mediante imágenes digitales [15], [16]. Asimismo, diferentes investigaciones han aplicado estas tecnologías para identificar enfermedades y estados de madurez en cultivos de cacao con resultados prometedores [17], [18]. La mayoría de estos trabajos se concentra en el desarrollo de los modelos y no en la integración de una plataforma que facilite la gestión de la información obtenida durante las inspecciones.

Los sistemas de información permiten organizar registros históricos y facilitar la consulta de datos generados durante un proceso determinado [9]. Por otra parte, la agricultura de precisión promueve el uso de herramientas digitales para apoyar el seguimiento de los cultivos y mejorar la toma de decisiones basada en información objetiva [8], [11]. En este contexto, surge la necesidad de desarrollar una plataforma que integre la información generada durante las inspecciones del cultivo y facilite su gestión en un único sistema permitiendo mantener organizados los registros de usuarios, lotes, capturas, diagnósticos fitosanitarios y planificación de cosecha para apoyar el seguimiento del cultivo y la toma de decisiones.

1.2 Formulación del problema

¿De qué manera una plataforma web y móvil, integrada con técnicas de visión artificial, puede apoyar la planificación de la cosecha de cacao CCN-51 mediante la identificación del estado sanitario y del nivel de madurez de las mazorcas, así como el registro, almacenamiento y consulta de la información generada durante las inspecciones de campo?

1.3 Objetivos

1.3.1 Objetivo general

Desarrollar una plataforma web y móvil basada en visión artificial que apoye el diagnóstico del estado sanitario, la identificación del nivel de madurez y la planificación de la cosecha en cultivos de cacao CCN-51 de la zona de Santo Domingo de los Tsáchilas.

1.3.2 Objetivos específicos

1. Preparar el conjunto de datos de imágenes de mazorcas de cacao destinado al entrenamiento y evaluación de modelos de visión artificial.
2. Desarrollar e integrar la arquitectura de la plataforma para la gestión de usuarios, lotes, capturas, diagnósticos y planificación de cosecha.
3. Desarrollar aplicaciones web y móvil que permitan la interacción con la plataforma y la consulta de la información agrícola.
4. Validar funcionalmente la plataforma y evaluar el desempeño de los modelos de visión artificial en un entorno real.

1.4 Justificación

La planificación de la cosecha permite organizar las actividades relacionadas con la recolección del cacao a partir del seguimiento del desarrollo de las mazorcas y del estado general del cultivo [1], [2]. El uso de herramientas digitales en la agricultura facilita el registro de información, la consulta de datos históricos y el apoyo a la toma de decisiones durante las labores de producción [9], [11]. En este contexto, la plataforma propuesta busca centralizar la información obtenida durante las inspecciones y facilitar su gestión dentro de un único sistema.

La condición sanitaria y el nivel de madurez de las mazorcas constituyen criterios importantes para planificar la cosecha y reducir pérdidas durante la producción [12], [19]. Enfermedades como la moniliasis y la fitóftora pueden afectar significativamente el rendimiento del cultivo cuando no son detectadas de manera oportuna [13], [14]. Por esta razón, incorporar herramientas que apoyen la identificación de estas condiciones puede contribuir al seguimiento del cultivo.

Los avances en visión por computador y aprendizaje profundo han permitido desarrollar modelos capaces de detectar y clasificar objetos mediante imágenes con resultados favorables en aplicaciones agrícolas [15], [20]. De tal manera, diversos estudios han aplicado estas técnicas para identificar enfermedades y estados de madurez en mazorcas mediante dispositivos móviles y modelos de aprendizaje profundo [17], [18]. La integración de estas tecnologías en una plataforma web y móvil permite complementar las actividades realizadas durante las inspecciones de campo.

Los grados-día de desarrollo constituyen un indicador ampliamente utilizado para estimar el crecimiento de diferentes cultivos a partir de la acumulación térmica [21], [22]. Sin embargo, este indicador debe complementarse con observaciones de campo relacionadas con la madurez de los frutos y el estado sanitario del cultivo para apoyar la planificación de las labores agrícolas [22]. La plataforma integra esta información con los resultados obtenidos mediante visión artificial para proporcionar un mayor contexto durante la planificación de la cosecha, asimismo, esta investigación integra conocimientos relacionados con desarrollo de software, bases de datos, inteligencia artificial y agricultura de precisión aplicados al cultivo de cacao.

Capítulo 2

Marco Teórico

El proceso de desarrollo de una plataforma de monitoreo para la agricultura necesita que se integren conocimientos relacionados con el cultivo del cacao, las enfermedades fitosanitarias, la agricultura de precisión, la visión por computador o invención y la utilización de sistemas de información [9], [20]. Estos temas proporcionan las bases para el aprendizaje de las tecnologías que se emplean en el desarrollo de la plataforma y la relación que mantienen las que se requieren[15], [23].

En este capítulo se introducen los conceptos fundamentales en los que se basa el trabajo. Se describen en primer lugar aspectos relativos al cultivo del cacao y a las enfermedades de mayor impacto. A continuación se presentan los principios básicos de la inteligencia artificial, visión computacional y los sistemas de información empleados para la implementación de la plataforma. Finalmente, se hace una revisión de trabajos recientes que permiten detectar la situación actual del problema de investigación y la carencia de soluciones que integren, en una única herramienta, estas tecnologías.

El cultivo del cacao presenta características agronómicas específicas en cuanto al desarrollo de la vaina, la incidencia de enfermedades y el manejo de la cosecha [1], [19]. Asimismo, los avances en inteligencia artificial (IA) y aprendizaje profundo han propiciado el desarrollo de herramientas capaces de procesar imágenes agrícolas y facilitar diversas tareas de monitoreo [16], [20]. Esta combinación de conocimientos constituye la base sobre la que se fundamenta la propuesta presentada en este trabajo.

Finalmente, se revisan investigaciones relacionadas con la aplicación de visión por computador en cultivos de cacao, identificando sus principales aportes y limitaciones [17], [24]. Este análisis permite establecer el contexto tecnológico actual y reconocer la necesidad de integrar modelos de inteligencia artificial con sistemas de información orientados al seguimiento del cultivo [18], [25]. A partir de esta revisión se fundamenta la propuesta desarrollada en la presente investigación.

2.1 El cultivo del cacao

El cacao (*Theobroma cacao* L.) es un cultivo tropical de gran importancia económica porque constituye la materia prima para la elaboración de chocolate y otros productos derivados, además de generar ingresos para millones de productores en diferentes regiones del mundo [7], [26]. En el Ecuador ocupa un lugar importante dentro de las exportaciones agrícolas y representa una actividad relevante para numerosas familias dedicadas a su producción [1], [6]. Debido a estas características, el uso de herramientas tecnológicas orientadas al manejo del cultivo ha despertado un creciente interés.

El manejo de una plantación de cacao comprende actividades relacionadas con el monitoreo del desarrollo de las mazorcas, la identificación de enfermedades, el control fitosanitario y la planificación de la cosecha [1]. La información obtenida durante estas labores sirve de apoyo para definir intervenciones oportunas y evaluar el comportamiento del cultivo a lo largo de su ciclo productivo [6], [26]. Por esta razón, mantener registros organizados de las inspecciones facilita el seguimiento del cultivo y respalda la toma de decisiones durante la producción.

2.1.1 El clon CCN-51

El clon CCN-51 (Colección Castro Naranjal 51) es una de las variedades de cacao más cultivadas en el Ecuador debido a su productividad, capacidad de adaptación y estabilidad en el rendimiento bajo diferentes condiciones de manejo [1]. Estas características han favorecido su expansión en varias zonas productoras del país y lo convierten en una alternativa ampliamente utilizada para la producción comercial [1], [6]. Por este motivo, fue seleccionado como objeto de estudio en la presente investigación.

Durante el proceso de desarrollo, las mazorcas del clon CCN-51 experimentan cambios progresivos en su coloración, textura y apariencia superficial que reflejan su estado de madurez [1]. Asimismo, factores como la iluminación, la humedad, la edad fisiológica del fruto y las condiciones ambientales pueden modificar su apariencia visual, generando diferencias entre frutos que pertenecen al mismo estado de desarrollo [24]. Esta variabilidad constituye uno de los principales desafíos para los sistemas de visión por computador encargados de analizar imágenes capturadas en condiciones reales de campo.

Desde la perspectiva de la inteligencia artificial, estas variaciones hacen necesario utilizar

conjuntos de datos que representen adecuadamente las diferentes condiciones presentes durante la captura de imágenes [20]. La calidad y diversidad de las imágenes empleadas durante el entrenamiento influyen directamente en la capacidad de los modelos para reconocer patrones y generalizar correctamente frente a nuevos escenarios [23], [27]. En consecuencia, la selección del conjunto de datos constituye un aspecto fundamental para obtener resultados confiables durante la identificación del estado de madurez y de las enfermedades del cacao.

2.1.2 Enfermedades del cacao

Las enfermedades fitopatológicas constituyen uno de los principales factores que limitan la productividad del cultivo de cacao, debido a que afectan el desarrollo de las mazorcas y reducen tanto la cantidad como la calidad de la producción obtenida [12], [19]. Entre las enfermedades de mayor impacto se encuentran la moniliasis y la fitóftora, las cuales ocasionan pérdidas económicas significativas en las principales regiones productoras de cacao cuando no son detectadas y controladas oportunamente [13], [14]. Su identificación temprana representa una actividad fundamental dentro del manejo fitosanitario del cultivo.

El monitoreo de estas enfermedades se realiza habitualmente mediante inspecciones visuales efectuadas por agricultores o técnicos durante los recorridos de campo [1]. Este procedimiento permite identificar síntomas visibles en las mazorcas; sin embargo, depende de la experiencia del evaluador y generalmente requiere recorrer grandes extensiones de cultivo para obtener una valoración completa [12], [19]. Estas limitaciones han impulsado el desarrollo de herramientas basadas en visión por computador que apoyen el diagnóstico fitosanitario durante las inspecciones.

Las manifestaciones visuales de las enfermedades pueden variar según el estado de desarrollo del fruto, el avance de la infección y las condiciones ambientales presentes durante la captura de las imágenes [24]. Además, algunas lesiones presentan características similares a daños mecánicos o cambios naturales asociados con la maduración del fruto, lo que incrementa la complejidad del proceso de identificación [20]. Por esta razón, es necesario comprender las características de las principales enfermedades antes de abordar los modelos de inteligencia artificial empleados para su detección.

■ Moniliasis:

La moniliasis es una enfermedad causada por hongos *Moniliophthora roreri*, una de las principales enfermedades que afectan la producción de cacao en Latinoamérica [13]. La enfermedad infecta las vainas, provocando deformaciones y necrosis, y grandes pérdidas de rendimiento si no se toman medidas oportunas para controlarla [12], [19]. Debido a su importancia, la moniliasis reviste gran interés en lo que respecta a los aspectos fitosanitarios relacionados con este cultivo.

En la fase inicial de la infección, no se observan síntomas, ya que los cambios en las capas visibles de la piel se producen gradualmente durante el desarrollo del hongo [13].

Posteriormente, pueden observarse manchas, deformaciones y una esporulación blanquecina típica, lo que permite su identificación en etapas avanzadas de la enfermedad [12]. La diversidad de estos síntomas supone un reto para el reconocimiento automático basado en imágenes.

Desde la perspectiva de la visión por computador, la moniliasis presenta cambios de color, textura y forma que dependen del grado de avance de la infección y de las condiciones bajo las cuales se capturan las imágenes [24]. Estas variaciones incrementan la complejidad del entrenamiento de los modelos de inteligencia artificial, ya que es necesario aprender patrones representativos de diferentes escenarios [20]. En consecuencia, disponer de imágenes variadas resulta fundamental para mejorar la capacidad de generalización del modelo.

■ **Fitóftora:**

La fitóftora, conocida también como mazorca negra, es una enfermedad causada principalmente por especies del género *Phytophthora*, siendo *Phytophthora palmivora* una de las más frecuentes en los cultivos de cacao [14]. Su desarrollo se favorece en ambientes con alta humedad y precipitaciones frecuentes, condiciones que facilitan la propagación del patógeno y aumentan el riesgo de infección en las plantaciones [12], [19]. Debido a su rápida dispersión, esta enfermedad representa una de las principales causas de pérdidas durante la producción de cacao.

Los primeros síntomas suelen manifestarse mediante pequeñas manchas oscuras sobre la superficie de la mazorca, las cuales aumentan progresivamente hasta cubrir gran parte del

fruto y provocar necrosis de los tejidos afectados [14]. Cuando la enfermedad no es controlada oportunamente, el deterioro de las mazorcas reduce significativamente la calidad y el rendimiento de la cosecha [12]. Estas características hacen necesario realizar inspecciones periódicas para identificar los frutos afectados antes de que la infección continúe propagándose.

Desde la perspectiva de la visión por computador, la fitóftora presenta desafíos relacionados con la similitud existente entre algunos síntomas de la enfermedad, las sombras producidas por el follaje y los cambios naturales de coloración durante la maduración del fruto [20]. Por ello, los modelos de inteligencia artificial deben aprender patrones asociados con la textura, la distribución de las lesiones y otras características visuales que permitan diferenciar esta enfermedad de otras condiciones presentes en el cultivo [24]. Esta diferenciación resulta fundamental para mejorar la confiabilidad de las predicciones realizadas por el sistema.

2.2 Agricultura de precisión y planificación de la cosecha

La agricultura de precisión reúne un conjunto de tecnologías que permiten recopilar, procesar y analizar información del cultivo para apoyar la toma de decisiones durante la producción [8], [11]. Su aplicación considera que las condiciones dentro de una plantación no son uniformes, por lo que las labores agrícolas pueden adaptarse a las necesidades de cada área [9], [11]. Gracias a ello, las decisiones dejan de basarse únicamente en la experiencia del agricultor y pasan a complementarse con información obtenida directamente en campo.

El desarrollo de sensores, dispositivos móviles, sistemas de posicionamiento global, imágenes aéreas e inteligencia artificial ha impulsado la evolución de la agricultura de precisión durante las últimas décadas [9]. Estas tecnologías permiten registrar información relacionada con el estado del cultivo, analizar grandes volúmenes de datos y generar herramientas que facilitan el monitoreo, el control fitosanitario y la planificación de las actividades agrícolas [9], [20]. Como resultado, los productores disponen de información más organizada para evaluar el comportamiento de sus cultivos a lo largo del tiempo.

En cultivos perennes como el cacao, la agricultura de precisión favorece el seguimiento continuo del desarrollo de las plantas mediante registros históricos asociados a cada lote de producción

[1]. La disponibilidad de esta información facilita la identificación de tendencias relacionadas con la aparición de enfermedades, la evolución del estado de madurez y el comportamiento productivo del cultivo [9], [11]. Estas características proporcionan una base adecuada para incorporar herramientas que apoyen la planificación de la cosecha.

2.2.1 Planificación de la cosecha

La planificación de la cosecha comprende el conjunto de actividades orientadas a determinar el momento adecuado para realizar la recolección de los frutos, considerando su estado de desarrollo, las condiciones del cultivo y la disponibilidad de recursos para ejecutar esta labor [1], [7]. Una planificación adecuada contribuye a mejorar la calidad del producto obtenido, optimizar el uso de mano de obra y reducir pérdidas ocasionadas por frutos sobremaduros o afectados por enfermedades [6], [26]. Por ello, constituye una de las etapas más importantes dentro del manejo del cultivo.

Tradicionalmente, esta planificación se realiza mediante inspecciones periódicas efectuadas por agricultores o técnicos, quienes evalúan visualmente el estado de las mazorcas y programan las actividades de cosecha de acuerdo con su experiencia [1]. Aunque este procedimiento continúa siendo ampliamente utilizado, puede verse afectado por la subjetividad de las observaciones, la dificultad para conservar registros históricos y el tiempo requerido para recorrer grandes extensiones de cultivo [9], [11]. Estas limitaciones han motivado la incorporación de herramientas digitales que complementen las actividades desarrolladas en campo.

Las plataformas de información agrícola permiten registrar inspecciones, almacenar imágenes, consultar el historial de cada lote e integrar los resultados obtenidos mediante modelos de inteligencia artificial [9]. La combinación de estas funcionalidades proporciona información organizada que facilita el seguimiento del cultivo y contribuye a respaldar las decisiones relacionadas con la planificación de la cosecha [11], [20]. En este contexto, la planificación deja de depender únicamente de la experiencia del agricultor y puede complementarse con información registrada durante todo el ciclo productivo.

2.2.2 Grados Día de Desarrollo (*Growing Degree Days*)

Los Grados Día de Desarrollo (*Growing Degree Days*, GDD) constituyen un indicador utilizado para estimar el desarrollo fenológico de los cultivos a partir de la acumulación de calor disponible durante su ciclo de crecimiento [21]. Este método parte del principio de que el crecimiento de las plantas depende de la temperatura y considera únicamente la energía térmica acumulada por encima de una temperatura base específica para cada especie [22]. Por esta razón, los GDD son ampliamente empleados como una herramienta de apoyo para la planificación de actividades agrícolas.

El cálculo de los GDD se realiza utilizando la temperatura máxima y mínima registradas durante el día, junto con la temperatura base del cultivo, obteniendo una estimación de la acumulación térmica diaria [21]. La suma de estos valores a lo largo del tiempo permite aproximar el progreso del desarrollo fisiológico de la planta y establecer referencias para diferentes etapas del cultivo [22]. La expresión utilizada para calcular los Grados Día de Desarrollo se presenta en la Ecuación 2.1.

$$GDD_{\text{diario}} = \max \left(\frac{T_{\max} + T_{\min}}{2} - T_{\text{base}}, 0 \right) \quad (2.1)$$

donde:

- $T_{\max}$ corresponde a la temperatura máxima registrada durante el día.
- $T_{\min}$ representa la temperatura mínima registrada durante el día.
- T_{base} corresponde a la temperatura base del cultivo.

Cuando el resultado de la diferencia térmica es inferior a cero, el valor del GDD diario se establece en cero, debido a que las temperaturas inferiores a la temperatura base no contribuyen a la acumulación térmica considerada para el desarrollo del cultivo. Los valores obtenidos diariamente se suman durante el periodo de seguimiento para determinar los GDD acumulados. En el caso del cacao, la temperatura base utilizada para el cálculo depende del proceso fisiológico analizado. Para el crecimiento vegetativo se han reportado temperaturas base superiores a las utilizadas para el desarrollo del fruto. En particular, Romero Vergel et al. [28]

señalan que la temperatura base para el crecimiento de las mazorcas se encuentra entre 9 y 12.9 °C y emplean un valor de 10 °C para calcular el tiempo térmico requerido durante su desarrollo. A partir de este antecedente, en la presente investigación se adoptó una temperatura base de 10 °C como referencia para el módulo de planificación de la cosecha.

2.2.3 Aplicación de los GDD en la planificación de la cosecha del cacao

La acumulación de Grados Día de Desarrollo ha sido utilizada en diferentes cultivos como una herramienta para estimar el avance del desarrollo fenológico y apoyar la programación de actividades agrícolas [21], [22]. En muchos cultivos, la suma de los grados día de crecimiento (GDD) se ha utilizado para determinar las etapas fenológicas y planificar los tratamientos [22]. Si bien la actividad fisiológica del cacao depende de diversos factores ambientales, los datos térmicos pueden servir como criterio útil para evaluar la duración de algunas etapas de crecimiento.

Los grados día de crecimiento (GDD), combinados con registros históricos, observaciones de campo e información sobre la etapa de madurez de las mazorcas, pueden dar como resultado predicciones más fiables de las posibles fechas de cosecha. [21]. Esta integración contribuye a reducir la dependencia de evaluaciones completamente subjetivas y facilita la planificación de recorridos técnicos para verificar las condiciones reales del cultivo [22]. De esta manera, la información disponible ofrece un mayor respaldo para la toma de decisiones durante la cosecha. En la presente investigación, los GDD constituyen el fundamento teórico del módulo de planificación implementado en la plataforma. Para este propósito se adoptó una temperatura base de 10 °C, considerando los valores reportados para el crecimiento de las mazorcas de cacao [28]. La acumulación térmica se utiliza como un indicador del avance del desarrollo del fruto y como una referencia para estimar el periodo probable de cosecha. No obstante, la estimación generada por el sistema se considera una herramienta de apoyo y no sustituye las inspecciones de campo ni el criterio técnico del agricultor o del especialista.

2.3 Inteligencia artificial aplicada a la agricultura

La inteligencia artificial agrupa técnicas que permiten desarrollar sistemas capaces de aprender a partir de datos, reconocer patrones y apoyar la toma de decisiones [16], [23]. En los últimos

años su uso se ha extendido a diferentes áreas debido al crecimiento de la capacidad de procesamiento y a la disponibilidad de grandes volúmenes de información [20]. En el sector agrícola, estas herramientas se han convertido en un apoyo para automatizar tareas de monitoreo y análisis del cultivo.

En el ámbito agrícola, la inteligencia artificial se utiliza para apoyar tareas como el monitoreo de cultivos, la detección de enfermedades, la estimación del rendimiento, el reconocimiento de malezas y la automatización de procesos de inspección [20], [25]. La mayoría de estas aplicaciones emplean información obtenida mediante imágenes, sensores o registros históricos para generar modelos capaces de identificar patrones relevantes para el manejo del cultivo [9], [20]. Como consecuencia, la IA se ha transformado en un recurso de ayuda para aumentar la eficacia de las labores agrícolas. En este estudio, se utiliza la inteligencia artificial para examinar imágenes de mazorcas de cacao para determinar su nivel de madurez y reconocer enfermedades presentes en las revisiones de campo. Para entender cómo opera este tipo de aplicaciones, es fundamental examinar los principios del aprendizaje profundo y de la visión por computadora.

2.3.1 Aprendizaje profundo (Deep Learning)

El aprendizaje profundo, es una rama del aprendizaje automático basada en redes neuronales artificiales con múltiples capas, diseñadas para aprender representaciones complejas directamente a partir de grandes volúmenes de datos [23]. A diferencia de los métodos tradicionales, extraen automáticamente las características más relevantes durante el proceso de entrenamiento, reduciendo la necesidad de definir manualmente los atributos de entrada [16]. Esta capacidad ha permitido mejorar el desempeño de numerosos sistemas de reconocimiento automático.

Los modelos de aprendizaje profundo han demostrado resultados destacados en tareas relacionadas con clasificación de imágenes, detección de objetos, reconocimiento facial, procesamiento del lenguaje natural y análisis de señales [23]. En agricultura, estas técnicas han sido utilizadas para identificar enfermedades, estimar el estado de desarrollo de los cultivos y apoyar procesos de monitoreo mediante imágenes obtenidas en condiciones reales de campo [20], [25]. Su habilidad para adquirir conocimiento patrones complejos es especialmente

beneficioso cuando hay una gran variabilidad visual entre los análisis de muestras. El desempeño de un modelo de aprendizaje profundo se basa en elementos como la calidad del conjunto de datos, la estructura empleada y el procedimiento de entrenamiento realizado. Estos elementos afectan de manera directa la habilidad del modelo para generalizar adecuadamente ante a imágenes que no formaron parte del entrenamiento.

2.3.2 Visión por computador

La visión por computador es una disciplina de la inteligencia artificial que estudia métodos para extraer información útil a partir de imágenes y videos mediante técnicas de procesamiento digital y aprendizaje automático [15]. Su objetivo consiste en permitir que un sistema interprete el contenido visual de manera automática para reconocer objetos, analizar escenas o identificar patrones de interés [15], [23]. Gracias a estos avances, la visión por computador ha adquirido un papel relevante en múltiples aplicaciones industriales y científicas.

En el sector agrícola, la visión por computador se emplea para inspeccionar cultivos, detectar enfermedades, identificar frutos, estimar el grado de madurez y automatizar procesos que tradicionalmente requieren observación humana [20], [25]. La información obtenida mediante cámaras convencionales o dispositivos móviles puede procesarse utilizando modelos de aprendizaje profundo capaces de reconocer características visuales presentes en las imágenes [24]. Estas aplicaciones permiten apoyar las inspecciones de campo mediante resultados consistentes y reproducibles.

En el desarrollo de esta investigación, la visión por computador constituye la base para analizar las imágenes capturadas desde la aplicación móvil e identificar automáticamente el estado sanitario y el nivel de madurez de las mazorcas de cacao.

2.3.3 Redes neuronales convolucionales

Las redes neuronales convolucionales (*Convolutional Neural Networks*, CNN) constituyen una arquitectura de aprendizaje profundo diseñada para procesar información visual mediante la extracción automática de características presentes en las imágenes [15], [23]. Estas redes emplean operaciones de convolución para identificar patrones como bordes, texturas, formas y estructuras, permitiendo construir representaciones cada vez más complejas a medida que

avanza el procesamiento [16]. Esta capacidad las ha convertido en una de las arquitecturas más utilizadas para el análisis automático de imágenes.

Las CNN han demostrado un desempeño sobresaliente en tareas como clasificación de imágenes, segmentación, reconocimiento facial y detección de objetos [23]. En aplicaciones agrícolas, estas redes se emplean para identificar enfermedades, reconocer frutos, estimar estados de madurez y analizar diferentes características visuales de los cultivos a partir de imágenes capturadas en campo [20], [25]. Su capacidad para aprender directamente de los datos reduce la necesidad de diseñar manualmente descriptores de imagen.

El desempeño de una CNN depende de factores como la arquitectura utilizada, la cantidad de datos disponibles y el proceso de entrenamiento aplicado. Estos aspectos influyen en la capacidad del modelo para reconocer correctamente nuevos ejemplos y mantener un comportamiento consistente durante su utilización.

2.3.4 Modelo YOLO

YOLO (*You Only Look Once*) es una familia de modelos de detección de objetos ampliamente utilizada en aplicaciones de visión por computador debido a su capacidad para localizar y clasificar objetos en una sola etapa de procesamiento [27], [29]. Esta característica permite obtener tiempos de respuesta reducidos sin perder un buen nivel de precisión, lo que ha favorecido su utilización en aplicaciones que requieren resultados en tiempo real [30].

En esta investigación se utilizó la variante YOLOv8n, ya que ofrece un equilibrio entre velocidad de procesamiento y precisión, condiciones adecuadas para analizar imágenes capturadas desde dispositivos móviles durante las inspecciones de campo.

2.4 Métricas utilizadas para evaluar los modelos de inteligencia artificial.

Un modelo no demuestra ser útil si, simplemente, repite bien los ejemplos que ha estado entrenando. La verdadera prueba sucede cuando ve imágenes que no había visto antes. Y también en visión por computador no basta con saber cuántos objetos es capaz de ver: resulta muy importante en dónde los encuentra, qué clase les asigna y cuántos ejemplos deja pasar. Para examinar estas dimensiones y comparar arquitecturas se utilizan métricas estandarizadas [31], [32].

En las tareas de detección de objetos, las métricas evalúan al mismo tiempo dos aspectos fundamentales: la adecuada categorización del objeto y la exactitud espacial con la que se ubica dentro de la fotografía. Esto posibilita una evaluación más integral del rendimiento del modelo. que empleando solo el porcentaje de aciertos

2.5 Métricas de evaluación de modelos de detección

La valoración de los sistemas de detección de objetos osibilita establecer su efectividad para localizar e identificar componentes en una imagen. [31], [32]. Para ello, se utilizan diversas métricas que comparan la predicción del modelo con la situación real en la imagen [32], [33]. De esta forma, se puede evaluar el funcionamiento del modelo.

Los parámetros que se toman en cuenta al evaluar los sistemas de detección de objetos abarcan dos aspectos: la asignación de nombres a los objetos y la localización de los mismos en la imagen [32]. Algunas de las métricas que se emplean son la precisión (*Precision*), la exhaustividad (*Recall*), la medida F1-score, la Intersección sobre Unión (IoU) y la Precisión Media Promedio (mAP), pudiendo así analizar diferentes aspectos del comportamiento del modelo [31], [32]. Conocer el significado de estas métricas permite interpretar los resultados que se obtuvieron durante el proceso de entrenamiento y validación.

2.5.1 Precisión (*Precision*)

La precisión mide la proporción de detecciones positivas realizadas por el modelo que corresponden realmente a objetos de la clase evaluada [33]. Un valor elevado indica que el modelo produce pocos falsos positivos y que la mayoría de las detecciones realizadas son correctas [32]. Esta métrica resulta útil para evaluar la confiabilidad de las predicciones generadas.

La precisión se calcula mediante la Ecuación 2.2.

$$Precision = \frac{VP}{VP + FP} \quad (2.2)$$

donde:

- *VP*: Verdaderos positivos.

- *FP*: Falsos positivos.

En esta investigación, la precisión permite evaluar qué tan confiables son las detecciones realizadas por el modelo para identificar los estados de madurez y las enfermedades presentes en las mazorcas de cacao.

2.5.2 Exhaustividad (*Recall*)

La exhaustividad o *Recall* mide la capacidad del modelo para detectar todos los objetos que realmente están presentes en las imágenes [33]. Un número alto desea significar que el modelo omitió pocas detecciones al hacer inferencia, lo cual significa que la numeración de falsos negativos es pequeña [32]. Esta métrica sirve como complemento a la información que ofrece la precisión.

La exhaustividad es calculada mediante la Ecuación 2.3.

$$Recall = \frac{VP}{VP + FN} \quad (2.3)$$

donde:

- *VP*: Son los verdaderos positivos.
- *FN*: Representan los falsos negativos.

El análisis conjunto de precisión y exhaustividad facilita el estudio del equilibrio entre detectar correctamente objetos y la detección errónea.

2.5.3 Medida *F1*

La medida *F1* combina la precisión y la exhaustividad en un único indicador mediante su media armónica, proporcionando una evaluación equilibrada del desempeño del modelo [33]. Esta métrica resulta especialmente útil cuando es necesario considerar simultáneamente la presencia de falsos positivos y falsos negativos [32]. Su utilización permite comparar modelos considerando ambos criterios de evaluación.

La medida *F1* se calcula mediante la Ecuación 2.4.

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (2.4)$$

Un valor alto de F1 indica que el modelo mantiene un buen equilibrio entre la capacidad para detectar correctamente los objetos y la confiabilidad de las predicciones realizadas.

2.5.4 Intersección sobre Unión (IoU)

La Intersección sobre Unión (*Intersection over Union*, IoU) es una métrica utilizada para evaluar el grado de coincidencia entre el cuadro delimitador predicho por el modelo y la anotación de referencia correspondiente [31], [32]. Su valor se obtiene comparando el área compartida entre ambos cuadros respecto al área total que ocupan en conjunto [32]. Esta métrica permite evaluar la precisión espacial de las detecciones realizadas.

La IoU se calcula mediante la Ecuación 2.5.

$$IoU = \frac{\text{Área de intersección}}{\text{Área de unión}} \quad (2.5)$$

Valores elevados de IoU indican que la ubicación estimada por el modelo coincide de manera más precisa con la posición real del objeto presente en la imagen.

2.5.5 Precisión Media Promedio (mAP)

La Precisión Media Promedio (*mean Average Precision*, mAP) constituye una de las métricas más utilizadas para evaluar modelos de detección de objetos, ya que resume el desempeño obtenido para todas las clases consideradas durante la evaluación [31], [32]. La base de sus cálculos es la precisión media alcanzada para cada clase a uno o varios umbrales de IoU, por lo que se puede comparar un modelo de detección respecto a otro [32]. Esta métrica viene a ser un buen resumen del rendimiento de dicho modelo.

En los modelos YOLO es habitual la aparición de algunas métricas como mAP@0.5 o mAP@0.5:0.95, que se refieren a opciones diferentes de los criterios de coincidencia entre las predicciones y las anotaciones de verdad [27]. Estas métricas permitirán evaluar el rendimiento en la tarea de clasificación y la precisión de la localización de los objetos detectados. [32]. En el capítulo de resultados se emplearán estas métricas para analizar el desempeño del modelo desarrollado en esta investigación.

2.6 Estimación de la severidad de la enfermedad

La severidad representa el porcentaje estimado del área afectada por una enfermedad con respecto al área total de las mazorcas detectadas en una imagen. Esta medida permite cuantificar el nivel de afectación observado y constituye un indicador para evaluar el estado sanitario del cultivo. En modelos de detección de objetos, la severidad puede estimarse a partir de las áreas de las cajas delimitadoras (*bounding boxes*) generadas para cada detección. La severidad se calcula mediante la Ecuación 2.X.

$$\text{Severidad} = \min \left(\frac{A_e}{A_m} \times 100, 100 \right) \quad (2.6)$$

donde:

- A_e : Suma de las áreas de las cajas delimitadoras clasificadas como enfermedades.
- A_m : Suma de las áreas de las cajas delimitadoras correspondientes a las mazorcas detectadas.

En esta investigación, la severidad permite estimar el porcentaje de afectación presente en las mazorcas detectadas por el modelo de visión artificial. El valor obtenido se limita al 100 % para evitar resultados superiores ocasionados por la superposición de las cajas delimitadoras.

2.7 Sistemas de información para el monitoreo agrícola

Los sistemas de información integran personas, procesos, datos y recursos tecnológicos con el propósito de recopilar, almacenar, procesar y presentar información que apoye la toma de decisiones dentro de una organización [9]. En el ámbito agrícola, estos sistemas permiten registrar actividades de campo, consultar información histórica y facilitar el seguimiento de los cultivos mediante herramientas digitales accesibles desde diferentes dispositivos [9], [25]. Estas funcionalidades contribuyen a mejorar la organización de la información generada durante las labores agrícolas.

El crecimiento de las tecnologías móviles y de los servicios web ha favorecido el desarrollo de plataformas que integran información proveniente de diferentes fuentes, como sensores, imágenes y registros de inspección [9]. La disponibilidad de esta información facilita el monitoreo

continuo de los cultivos y proporciona un mayor respaldo para la planificación de las actividades agrícolas [20], [25]. En este contexto, los sistemas de información constituyen una herramienta complementaria para apoyar la gestión de la producción agrícola.

2.7.1 Aplicaciones web

Las aplicaciones web son sistemas informáticos que se ejecutan mediante un navegador y permiten acceder a diferentes funcionalidades sin necesidad de instalar software específico en cada equipo cliente, se basa en la comunicación con un servidor que procesa las solicitudes, administra la información y devuelve los resultados solicitados por los usuarios [9]. Esta arquitectura facilita el acceso a la información desde diferentes ubicaciones con conexión a Internet.

En el sector agrícola, las aplicaciones web se utilizan para administrar usuarios, consultar registros históricos, visualizar reportes y gestionar la información generada durante las actividades de campo [25]. La centralización de los datos permite mantener información actualizada y simplifica las tareas de administración realizadas por técnicos y responsables del cultivo [9]. Estas características las convierten en un componente importante dentro de las plataformas de gestión agrícola.

2.7.2 Aplicaciones móviles

Las aplicaciones móviles permiten ejecutar procesos directamente desde teléfonos inteligentes y tabletas, aprovechando las capacidades de estos dispositivos para registrar información durante actividades realizadas fuera de una oficina [9]. Su utilización en el sector agrícola facilita el ingreso de datos en tiempo real, la captura de fotografías y la consulta de información durante las inspecciones de campo [25]. Estas funcionalidades reducen la necesidad de registrar la información posteriormente en otros sistemas.

La incorporación de aplicaciones móviles mejora la disponibilidad de la información y favorece la actualización inmediata de los registros generados durante el monitoreo del cultivo [9]. Además, permite integrar herramientas de visión por computador para analizar imágenes capturadas directamente desde el dispositivo móvil [20]. Estas capacidades amplían las posibilidades de apoyo tecnológico durante las actividades desarrolladas en campo.

2.7.3 Arquitectura cliente-servidor

La arquitectura cliente-servidor organiza una aplicación mediante la separación entre los componentes encargados de presentar la información al usuario y aquellos responsables del procesamiento de los datos y de la lógica del negocio [9]. En este modelo, los clientes realizan solicitudes a un servidor, el cual procesa las peticiones, accede a la información almacenada y devuelve las respuestas correspondientes [9]. Esta organización favorece el desarrollo de aplicaciones modulares y facilita el mantenimiento del sistema.

Una de las principales ventajas de esta arquitectura consiste en que múltiples clientes pueden acceder simultáneamente a los mismos servicios y compartir una única fuente de información centralizada [9]. Asimismo, la separación entre la interfaz de usuario y el servidor permite actualizar cada componente de manera independiente cuando sea necesario [25]. Estas características resultan adecuadas para aplicaciones que requieren acceso desde plataformas web y dispositivos móviles.

2.7.4 API REST

Una API REST (*Representational State Transfer*) constituye un mecanismo de comunicación que permite el intercambio de información entre diferentes aplicaciones mediante el protocolo HTTP utilizando recursos identificados por direcciones URL [9]. Las operaciones más comunes corresponden a la consulta, creación, actualización y eliminación de información, las cuales se implementan mediante métodos como GET, POST, PUT y DELETE [9]. Este enfoque facilita la interoperabilidad entre sistemas desarrollados con diferentes tecnologías.

En aplicaciones distribuidas, las API REST permiten desacoplar el cliente del servidor, de manera que cada componente pueda evolucionar de forma independiente mientras mantiene un mecanismo estandarizado de comunicación [9]. Esta característica facilita la integración de aplicaciones web, aplicaciones móviles y servicios especializados dentro de una misma plataforma [25]. Por esta razón, las API REST son ampliamente utilizadas en el desarrollo de sistemas modernos basados en arquitecturas cliente-servidor.

2.8 Estado del Arte

La aplicación de técnicas de visión por computador e inteligencia artificial en la agricultura ha crecido de forma considerable durante los últimos años. En el cultivo de cacao, estas tecnologías han despertado interés debido a su potencial para apoyar la detección de enfermedades, reconocer el estado de madurez de las mazorcas y mejorar las actividades de monitoreo realizadas en campo [20], [24]. A continuación, se revisan algunos de los trabajos más representativos relacionados con esta temática.

2.8.1 Aplicaciones de YOLO en el cultivo de cacao

Los modelos de la familia YOLO han sido utilizados en investigaciones recientes para detectar frutos de cacao, identificar enfermedades y clasificar el estado de madurez de las mazorcas mediante imágenes obtenidas en condiciones de campo [17], [34]. Estos trabajos muestran que la detección automática puede contribuir a reducir el tiempo requerido para realizar inspecciones y proporcionar resultados consistentes durante el monitoreo del cultivo [24], [35]. La disponibilidad de arquitecturas más eficientes ha favorecido el desarrollo de nuevas aplicaciones para este cultivo.

Los resultados obtenidos en estas investigaciones evidencian que el desempeño de los modelos depende principalmente de la calidad del conjunto de datos, de la variabilidad de las imágenes utilizadas durante el entrenamiento y de las condiciones presentes durante la captura [36], [37]. Elementos tales como las condiciones de iluminación, la existencia de oclusiones, la existencia de hojas y la variabilidad de las variedades, son retos habituales en los sistemas de detección automática[24], siendo estos desafíos que deben tenerse en cuenta a la hora de realizar el diseño y la evaluación de aplicaciones basadas en visión por computador.

La revisión sistemática realizada por Alvarado et al. [24] consideró los trabajos publicados desde 2019 hasta el 2024 en cuanto a la detección de enfermedades del cacao mediante técnicas de visión por computador. Los autores identificaron un uso creciente de modelos de aprendizaje profundo y arquitecturas de detección de objetos como YOLO y SSD, principalmente sobre imágenes RGB. La revisión también evidencia que gran parte de las investigaciones se concentra en el desempeño experimental de los modelos, mientras que la integración de estas técnicas en herramientas completas de apoyo al productor continúa siendo limitada.

Nyarko et al. [34], por ejemplo, propusieron una versión mejorada de YOLOv5m para la detección de enfermedades mediante la incorporación de Swin Transformer, agrupamiento K-means++ y una función de pérdida EIoU. Dichos avances reflejan que las arquitecturas de detección pueden adaptarse a diferentes condiciones visuales complejas, pero las pruebas se centran en las métricas del modelo en sí, pero no en su gestión posterior de la información que se produce. Por otro lado se han desarrollado aplicaciones para teléfonos móviles haciendo uso de modelos de aprendizaje profundo para hacer asistentes a los agricultores durante la inspección fitosanitaria, de esta manera Kumi et al. [17] desarrollaron una aplicación para teléfonos móviles para detectar enfermedades del cacao y, por su parte, Buenaño Vera et al. [18] desarrollaron un modelo basado en EfficientDet-Lite4 para detectar moniliasis y mazorca negra y mazorcas sanas. Estas investigaciones reflejan que es viable usar modelos de inteligencia artificial a partir de dispositivos móviles, pero el uso es relativo a la producción y el diagnóstico sobre imágenes individuales.

Con respecto a la madurez de la fruta, Ayikpa et al. [37] se evaluaron métodos de aprendizaje conjunto para clasificar mazorcas utilizando características de color y textura. Por otro lado, Restrepo-Arias et al. [35] evaluaron arquitecturas como Faster R-CNN, Mask R-CNN y variantes de YOLOv8 para localizar mazorcas en etapas variadas de madurez. Estos indican que la visión por computador es aplicable para identificar fases de madurez, pero están dirigidos a la evaluación de los modelos y no para aplicar las predicciones en procesos de planificación de cosecha.

Como se muestra en la Tabla 1, la mayoría de los trabajos relacionados son para formular modelos basados en inteligencia artificial para detectar enfermedades o clasificar la madurez del mazorca de cacao. Este trabajo demuestra que técnicas de visión por computador dan resultados satisfactorios en diversas condiciones de prueba; no obstante, el alcance fue a través del análisis del rendimiento de los algoritmos y en menor medida a la integración de estas capacidades en plataformas para el manejo de información agrícola.

La revisión de Alvarado et al. [24] confirma esta tendencia al evidenciar que las investigaciones recientes utilizan principalmente arquitecturas como YOLO, SSD y otras redes neuronales convolucionales para resolver tareas específicas de detección o clasificación. Asimismo, trabajos como los de Kumi et al. [17], Buenaño Vera et al. [18], Ayikpa et al. [37] y Restrepo-Arias et al.

[35] muestran aplicaciones enfocadas en el diagnóstico de enfermedades o en la identificación del estado de madurez, sin incorporar funcionalidades orientadas al seguimiento integral del cultivo y planificación de actividades agrícolas.

A partir del análisis efectuado se desprende que la mayor laguna investigativa no se encuentra solo en alcanzar mayor precisión en los modelos de visión por computador, sino en usar su salida para ser empleada dentro de plataformas que permitan registrar las inspecciones, conservar los datos históricos y que éstos puedan ser utilizados como soporte para la toma de decisión. Es así que esta investigación presenta una plataforma web y móvil que integra la detección automática de enfermedades y la clasificación en seis estados de madurez junto con el manejo de usuarios, lotes, inspecciones y reportes, y suma un módulo para la planificación de la cosecha en base a Grados Día de Desarrollo.

Tabla 1

Comparación de trabajos relacionados con la presente investigación

Autor	Año	Técnica	Aporte principal	Limitación
Kumi et al. [17]	2022	SSD MobileNet V2	Aplicación móvil para detectar enfermedades del cacao.	No incluye historial, gestión agrícola ni planificación.
Ferraris et al. [25]	2023	YOLO	Uso de IA como apoyo a productores de cacao.	Enfoque experimental, sin plataforma de gestión.
Buenaño Vera et al. [18]	2024	EfficientDet-Lite4	Detección de moniliasis y mazorca negra desde dispositivos móviles.	Solo realiza diagnóstico de imágenes.
Ayikpa et al. [37]	2024	Stacking + Voting	Clasificación automática de estados de madurez.	No contempla enfermedades ni planificación.
Restrepo-Arias et al. [35]	2025	YOLOv8	Comparación de modelos para detectar etapas de madurez.	Evaluación del modelo sin gestión del cultivo.
Alvarado et al. [24]	2025	Revisión sistemática	Resume el estado del arte en visión por computador aplicada al cacao.	Identifica la falta de plataformas integrales.

2.9 Síntesis del estado del arte

La revisión realizada en este capítulo permitió reunir los conceptos necesarios para comprender el desarrollo de la plataforma propuesta. Se abordaron aspectos relacionados con el cultivo del

cacao, las enfermedades de mayor impacto, la agricultura de precisión, los Grados Día de Desarrollo y los fundamentos de la visión por computador utilizados durante la investigación. Además se revisaron la literatura reciente sobre modelos de inteligencia artificial aplicados en cultivo de cacao. Básicamente, se centran en aumentar la precisión de los modelos para detectar enfermedades o estados de madurez. No obstante, son aún escasas las propuestas que incorporan estas capacidades en plataformas que se orientan a gestionar la información generada en las inspecciones apoyando la planificación de la cosecha.

Capítulo 3

Metodología

En este capítulo se describe la metodología seguida para el desarrollo de la plataforma de apoyo a la planificación de la cosecha del cultivo de cacao. Se expone el enfoque metodológico elegido, la metodología de desarrollo, la recopilación de requerimientos y las actividades efectuadas en las fases de diseño, implementación, evaluación y validación

3.1 Metodología de desarrollo de la investigación.

Este estudio se clasifica como investigación aplicada, dado que tiene como objetivo solucionar un problema particular vinculado a la planificación de la cosecha del cultivo de cacao a través de la creación de una plataforma computacional que combina técnicas de visión por computador y manejo agrícola.

El enfoque de la investigación es predominantemente cuantitativo, debido a que la validación de la solución considera métricas objetivas obtenidas durante la evaluación del modelo de inteligencia artificial, así como pruebas funcionales realizadas sobre la plataforma desarrollada. De forma complementaria, también incorpora un componente descriptivo al analizar las características del proceso agrícola y los requerimientos operativos de los diferentes actores involucrados.

La investigación se desarrolló en seis fases: problema de investigación, revisión bibliográfica, levantamiento de requerimientos, diseño de la solución, implementación de los componentes y validación con pruebas funcionales y de campo. Cada una de ellas contribuyó en mayor o menor medida al desarrollo de la plataforma, desde la definición de las necesidades del proyecto hasta la verificación de su funcionamiento en condiciones reales. La secuencia seguida durante este proceso se muestra en la Figura 1.




Figura 1

Metodología de desarrollo de la investigación

3.2 Metodología de desarrollo

Para el desarrollo del software se seleccionó el modelo en cascada, debido a que permitía organizar el trabajo de forma ordenada y mantener una secuencia clara entre las diferentes etapas del proyecto. Este enfoque facilitó la planificación de las actividades, la documentación del proceso y el seguimiento de la implementación.

Aunque durante el desarrollo fue necesario realizar pequeños ajustes derivados de la integración de los diferentes componentes, las principales actividades siguieron el orden establecido por el modelo, iniciando con el análisis de requerimientos, continuando con el diseño del sistema, la implementación de los módulos, las pruebas funcionales y finalmente la validación de la plataforma. Como se observa en la Figura 2, el desarrollo del sistema siguió una secuencia ordenada de actividades, iniciando con el levantamiento de requerimientos y finalizando con la validación de la plataforma.




Figura 2

Etapas del modelo de desarrollo en cascada empleadas durante la implementación del sistema.

La Tabla 2 resume la forma en que cada etapa del modelo en cascada fue aplicada durante el desarrollo del proyecto.

Tabla 2

Aplicación del modelo en cascada durante el desarrollo del proyecto

Etapas	Aplicación en el proyecto
Requerimientos	Definición de necesidades del agricultor, técnico y administrador.
Diseño	El diseño de la estructura del sistema, la base de datos y las interfaces de usuario.
Implementación	Creación de la aplicación web, la aplicación móvil, el sistema de backend y el servicio de inteligencia artificial.
Pruebas	Validación funcional de cada módulo y verificación de la interconexión entre los diversos componentes.
Validación	Evaluación de campo llevada a cabo en el área de Valle Hermoso para comprobar el desempeño de la plataforma en situaciones reales.

3.2.1 Fase 1. Levantamiento de requerimientos

El levantamiento de requerimientos permitió identificar las funcionalidades necesarias para apoyar el monitoreo sanitario y la planificación de la cosecha del cacao. Para esto, se estudiaron las acciones realizadas por distintos usuarios de la plataforma, en los procesos administrativos y las tareas técnicas desarrolladas en el monitoreo del cultivo. Con base en este estudio se

definieron los requisitos de funcionales y no funcionales que se utilizaron para la elaboración de la solución. Los requisitos funcionales detallan los servicios que el sistema debe ofrecer, en tanto que los requisitos no funcionales establecen atributos de seguridad, rendimiento, usabilidad y capacidad.

La Figura 3 muestra los casos de uso más importantes del sistema, clasificados según las funciones de cada categoría de usuario. El administrador se encarga de la información general de la plataforma, el técnico lleva a cabo las tareas de seguimiento y recolección de datos en el campo, y el agricultor revisa los resultados que produce el sistema para ayudar en la planificación de la cosecha.




Figura 3

Diagrama general de casos de uso del sistema.

Los requisitos definidos permitieron definir el alcance funcional de la plataforma y fueron una guía para el diseño de la arquitectura, para la implementación de los diferentes módulos y para las pruebas desarrolladas durante la validación del sistema.

Tabla 3*Requerimientos funcionales del sistema*

Código	Descripción
RF01	Autenticar usuarios mediante credenciales y tokens JWT.
RF02	Gestionar la información de agricultores y técnicos.
RF03	Registrar y administrar los lotes de cultivo.
RF04	Registrar capturas fotográficas de las mazorcas de cacao.
RF05	Enviar imágenes al servicio de inteligencia artificial para su análisis.
RF06	Mostrar los resultados de detección de enfermedades y estados de madurez.
RF07	Generar la planificación de la cosecha mediante el cálculo de los Grados Día de Desarrollo (GDD), utilizando información meteorológica obtenida desde la API Open-Weather y parámetros agronómicos asociados a la variedad del cultivo.
RF08	Revisar informes y registro de seguimiento.

Tabla 4*Requerimientos no funcionales del sistema*

Código	Descripción
RNF01	La plataforma tiene que proporcionar una interfaz que sea intuitiva y sencilla de usar.
RNF02	El sistema necesita ser compatible con navegadores de internet y dispositivos móviles Android.
RNF03	La autenticación tiene que llevarse a cabo utilizando JWT y encriptación de contraseñas a través de bcrypt.
RNF04	Las fotografías deben guardarse de manera segura en Cloudflare R2, mientras que los datos estructurados deben administrarse a través de una base de datos PostgreSQL hospedada en Supabase.
RNF05	La arquitectura debe permitir la integración independiente del servicio de inteligencia artificial mediante una API REST.
RNF06	El sistema debe facilitar futuras ampliaciones sin afectar el funcionamiento de los módulos existentes.

3.2.2 Fase 2. Diseño del sistema

Una vez definidos los requerimientos funcionales y no funcionales, se procedió al diseño de la solución propuesta. En esta etapa se estableció la arquitectura general del sistema, el modelo de datos, la interacción entre los diferentes componentes y la distribución de las funcionalidades entre la aplicación web, la aplicación móvil, el backend y el servicio de inteligencia artificial. Durante esta etapa se definió la estructura general de la plataforma y la forma en que se comunicarían sus diferentes componentes mediante una API REST. Este diseño sirvió como referencia para la implementación desarrollada en las siguientes fases del proyecto.

Diseño de la arquitectura

A partir de los requerimientos identificados se diseñó una arquitectura modular que integrara todos los componentes de la plataforma. Para ello se consideró una aplicación web, una aplicación móvil, un backend, una base de datos relacional y un servicio independiente de

inteligencia artificial encargado del análisis de imágenes.

La arquitectura fue creada para enfocarse en el un modelo cliente-servidor, donde las aplicaciones cliente consumen los servicios expuestos mediante una API REST. Esta organización facilita la comunicación entre los componentes, favorece el mantenimiento del sistema y permite incorporar futuras funcionalidades sin afectar la estructura general de la plataforma. La Figura 4 presenta la arquitectura diseñada para la solución propuesta.




Figura 4

Arquitectura de plataforma web y móviil para planificación de cosecha de cacao basada en visión artificial.

Diseño de la base de datos

Durante esta etapa se diseñó el modelo de datos que soporta el funcionamiento de la plataforma. La estructura fue definida considerando la información requerida para la gestión de usuarios, agricultores, técnicos, lotes, capturas realizadas en campo y la planificación de la cosecha. La Figura 5 muestra el modelo entidad-relación diseñado para la base de datos.



Figura 5

Modelo entidad-relación de la base de datos.

Diseño de las interfaces de usuario

El diseño de las interfaces de usuario se realizó considerando las funcionalidades definidas durante el levantamiento de requerimientos y las actividades desarrolladas por cada uno de los roles de la plataforma: administrador, técnico y agricultor. Para ello se estableció una organización de pantallas que facilitara el acceso a las operaciones de gestión, monitoreo y consulta desde la aplicación web y la aplicación móvil.

En esta fase se definieron la organización de los elementos de navegación, los formularios para el ingreso de información, las vistas para consultas de diagnósticos y planificación de cosecha, y los elementos necesarios para interactuar con el servicio de visión artificial. El diseño intentó seguir una línea homogénea en ambas aplicaciones, presentando la información según la capacidad de cada dispositivo.

Las interfaces implementadas como resultado de este diseño se presentan en el Capítulo IV. En particular, las Figuras 12, 13, 14 y 15 muestran las principales interfaces correspondientes al rol

de administrador. De igual manera, las Figuras 16, 17, 18, 19, 20 y 21 presentan las funcionalidades implementadas para el técnico, mientras que las Figuras 22, 23 y 24 corresponden a las interfaces desarrolladas para el agricultor.

3.2.3 Fase 3. Implementación

Con el diseño ya definido, se inició la implementación de los componentes que conforman la plataforma. El desarrollo se llevó a cabo en módulos, incorporando de forma gradual la aplicación web, la aplicación móvil, el backend, la base de datos y el servicio de inteligencia artificial responsable del análisis de imágenes de mazorcas de cacao. Se desarrolló la solución empleando tecnologías de código abierto en una arquitectura cliente-servidor fundamentada en servicios REST. Esta entidad permitió mantener separados los distintos módulos y facilitó su integración y mantenimiento.

Implementación del backend

El backend se desarrolló utilizando Node.js junto con Express y TypeScript, implementando una API REST responsable de centralizar la lógica de negocio de la plataforma. Este componente administra las solicitudes provenientes de las aplicaciones web y móvil, procesa la información recibida y coordina la comunicación con la base de datos y el servicio de inteligencia artificial. Durante esta etapa se implementaron los diferentes módulos encargados de la autenticación de usuarios, administración de agricultores, técnicos, lotes, capturas, diagnósticos y planificación de la cosecha. De igual manera, se implementó autenticación con tokens JWT y encriptación de contraseñas usando bcrypt para asegurar el acceso a la plataforma. Al registrar un nuevo lote, la app móvil captura automáticamente las coordenadas geográficas usando el GPS del dispositivo, siempre que el usuario conceda los permisos necesarios. La base de datos guarda la latitud y longitud como parte de los datos del lote y luego el backend las utiliza para obtener las condiciones climáticas a través de la API OpenWeather, información requerida para calcular los Grados Día de Desarrollo (GDD).

La Figura 6 presenta la organización del proyecto backend implementado en Node.js y Express, donde la lógica del sistema se encuentra distribuida en controladores, servicios, rutas y módulos de configuración.




Figura 6

Estructura del Backend.

Implementación del módulo de planificación de la cosecha

El módulo de planificación de la cosecha fue implementado dentro del backend de la plataforma con el propósito de estimar el avance del desarrollo de las mazorcas mediante la acumulación de Grados Día de Desarrollo. Este procedimiento combina la información del lote, los parámetros relacionados con la variedad y los datos climáticos procedentes de su localización geográfica. Cada lote registrado está vinculado a una variedad de cacao. Para llevar a cabo el cálculo, el backend revisa los parámetros guardados para esa variedad, que incluyen la temperatura base y el GDD deseado. La temperatura mínima es el límite térmico desde el cual se considera que hay acumulación de calor útil para el crecimiento del fruto, mientras que el GDD objetivo es el valor que utiliza el sistema como referencia para evaluar el progreso hacia la fase prevista de cosecha. El GDD meta se refiere al valor de acumulación térmica que la plataforma utiliza como base para calcular el instante en que un lote se acerca a la fase de recolección. Dado que las

propiedades fisiológicas pueden diferir entre las distintas variedades de cacao, este aspecto se guarda de manera separada para cada variedad en la base de datos, lo que permite que el proceso de planificación se ajuste a la variedad vinculada al lote.

En las variedades configuradas en la plataforma se estableció una temperatura base de 10 °C. Este valor fue definido a partir de antecedentes relacionados con el cálculo del tiempo térmico para el crecimiento de las mazorcas de cacao, descritos en el Capítulo II. Los parámetros se almacenan en la base de datos y son recuperados automáticamente por el backend, por lo que el técnico no debe ingresarlos durante cada operación de planificación.

Para acceder a la información del clima, el sistema emplea la latitud y longitud guardadas en el momento de registrar el lote. Las coordenadas se obtienen de manera automática a través del GPS del dispositivo móvil y se utilizan luego en el backend para interactuar con la API de OpenWeather, de la cual se extraen las temperaturas máxima y mínima en grados Celsius. Estos datos se utilizan para determinar el GDD diario a través de la Ecuación 2.1.

El valor obtenido se agrega al acumulado térmico previamente registrado para el lote. Este procedimiento puede expresarse mediante la Ecuación 3.1.

$$GDD_{\text{acumulado},n} = GDD_{\text{acumulado},n-1} + GDD_{\text{diario},n} \quad (3.1)$$

donde:

- $GDD_{\text{acumulado},n}$ corresponde al total acumulado después del registro del día actual.
- $GDD_{\text{acumulado},n-1}$ representa el total almacenado hasta el día anterior.
- $GDD_{\text{diario},n}$ corresponde al valor calculado con las temperaturas del día actual.

Tras actualizar el acumulado, el backend contrasta el resultado con el GDD meta correspondiente a la variedad. La ecuación 3.2 expresa la condición utilizada para establecer el estado de la planificación.

$$Estado = \begin{cases} \text{Lista para cosecha,} & GDD_{\text{acumulado}} \geq GDD_{\text{objetivo}} \\ \text{En seguimiento,} & GDD_{\text{acumulado}} < GDD_{\text{objetivo}} \end{cases} \quad (3.2)$$

Al llegar los GDD acumulados al valor objetivo o al superarlo, el sistema modifica el estado de la planificación a *Lista para cosecha*. Mientras el valor se mantenga por debajo del límite, el lote retiene el estado *En seguimiento* y sigue recolectando datos meteorológicos. El procedimiento se lleva a cabo de forma automática desde el backend a través de una tarea programada que revisa de manera periódica los datos meteorológicos de los lotes activos. Así, el técnico colabora en el monitoreo y control del lote, pero no necesita introducir de forma manual las temperaturas máximas y mínimas ni realizar los cálculos térmicos. La estimación resultante se presenta como una referencia para organizar las actividades de cosecha y debe complementarse con las inspecciones realizadas en campo.

Implementación de la base de datos

La base de datos fue implementada utilizando PostgreSQL alojado en Supabase, siguiendo el modelo entidad-relación definido durante la fase de diseño. En ella se almacenan los registros correspondientes a usuarios, agricultores, técnicos, lotes, capturas, diagnósticos y planificación de la cosecha.

Durante la implementación se definieron las relaciones entre las diferentes entidades y se establecieron las restricciones necesarias para garantizar la integridad de la información.

Asimismo, las imágenes tomadas en las inspecciones de campo fueron almacenadas con Cloudflare R2, conservando solo las referencias necesarias en la base de datos.

La Figura 7 muestra la realización física en la base de datos PostgreSQL en Supabase, donde son observadas las tablas que fueron creadas con base en el modelo entidad-relación definido durante la etapa de diseño.

Implementación del servicio de inteligencia artificial

El servicio de inteligencia artificial fue implementado utilizando FastAPI y organizado de forma modular. El proyecto se organizó en módulos que agrupan la API, la lógica de procesamiento de imágenes, los modelos entrenados y los directorios utilizados durante la inferencia. La Figura 8 muestra la estructura implementada.

Esta organización permitió mantener el servicio de inteligencia artificial independiente del resto de la plataforma, facilitando la actualización de los modelos sin afectar el funcionamiento del backend ni de las aplicaciones cliente.

The screenshot shows the Supabase Table Editor for the 'planificacion_cosecha' table. The table structure is as follows:

id	lote_id	fecha_inicio_ciclo	gdd_acumulados_actuales	proyeccion_kg_secos	fecha_estimada_di
57cd4ce0-069a-48ef-b495-b39f655d	11111111-1111-1111-1111-111111111111	2026-04-05	163.64	1809.03	2026-05-05
86f6bc65-be8f-444e-bc7d-3ce96406	57c7624b-d3ab-4d3b-833a-58...	2026-06-03	42.82	0.00	2026-07-05
921fc63f-6a12-4e7a-b2d8-37e0be825f	fa660a99-2e3e-4b39-afa9-94...	2026-02-18	713.54	1440.00	2026-02-18
aa119baa-127d-4025-a10f-6f343c4eaf	05e411c7-5ea7-44de-9da9-c6...	2026-05-20	155.74	2467.11	2026-06-21

Figura 7

Implementación física de la base de datos en PostgreSQL (Supabase).

3.2.4 Preparación del conjunto de datos

Para entrenar los modelos de visión artificial se utilizaron dos conjuntos de datos organizados en la plataforma Roboflow. El primero estuvo destinado a la detección de enfermedades y estuvo conformado por 827 imágenes. El segundo se empleó para la clasificación del estado de madurez de las mazorcas y reunió un total de 4390 imágenes.

Las imágenes utilizadas provinieron principalmente de fuentes públicas disponibles en Internet. Además, se incorporaron fotografías obtenidas durante el desarrollo del proyecto con el fin de complementar algunas clases y disponer de ejemplos más representativos. Una vez reunidas, todas las imágenes fueron etiquetadas en Roboflow y exportadas al formato YOLO para realizar el entrenamiento de los modelos.

Las fotografías tomadas durante las visitas a la finca Valle Hermoso no formaron parte del entrenamiento. Estas imágenes se utilizaron únicamente durante las pruebas de la plataforma para verificar el funcionamiento de los modelos en un entorno real.

```

50 def procesar_ia(archivo_local):
51     # --- 1. INFERENCIA CON UMBRALES AJUSTADOS ---
52     # Subimos madurez a 0.5 para evitar falsos sobremaduros
53     res_madurez = model_madurez(archivo_local, conf=0.5)[0]
54     # Bajamos enfermedad a 0.2 para intentar capturar Phyto dudosa
55     res_enfermedad = model_enfermedad(archivo_local, conf=0.2)[0]
56
57     # Diccionarios de trabajo (en español para la lógica interna)
58     conteos_madurez = {"pequeno": 0, "verde": 0, "pinton": 0, "maduro": 0, "sobremaduro": 0, "danado": 0}
59     enfermedades_detectadas = [] # Guardaremos (clase, area)
60     area_total_mazorcas = 0
61
62     # --- 2. PROCESAR MADUREZ ---
63     if res_madurez.bboxes is not None:
64         for box in res_madurez.bboxes:
65             cls_id = int(box.cls[0])
66             label_ingles = res_madurez.names[cls_id]
67
68             # Traducir para el conteo JSON
69             label_es = TRADUCCION_ANOTACIONES.get(label_ingles, label_ingles).replace("-", "_")
70             if label_es in conteos_madurez:
71                 conteos_madurez[label_es] += 1
72
73             # Sumar área para cálculos de severidad
74             area_total_mazorcas += calcular_area(box.xyxy[0].tolist())
75
76     # --- 3. PROCESAR ENFERMEDADES Y CALCULAR SEVERIDAD REAL ---
77     area_total_enfermedad = 0
78     severidad_json = {"monilia": 0, "phytophthora": 0}
79
80     if res_enfermedad.bboxes is not None:
81         for box in res_enfermedad.bboxes:
82             cls_id = int(box.cls[0])
83             label_orig = res_enfermedad.names[cls_id] # Puede ser "Monilia", "Fitofthora" o "Sana"
84

```

Figura 8

Servicio de IA implementado utilizando FastAPI.

Implementación de la aplicación web

La aplicación web fue desarrollada utilizando React y TypeScript, proporcionando una interfaz destinada principalmente a las actividades de administración y consulta de información. Durante esta etapa se implementaron los diferentes módulos asociados con la gestión de usuarios, lotes, diagnósticos, planificación de la cosecha y reportes. La comunicación con el backend se realizó mediante solicitudes HTTP a la API REST, permitiendo mantener sincronizada la información almacenada en la plataforma. Las interfaces implementadas y las funcionalidades disponibles para cada rol se presentan en el Capítulo IV.

Implementación de la aplicación móvil

La aplicación móvil fue desarrollada utilizando React Native y Expo con el propósito de facilitar el registro de información directamente durante las actividades de monitoreo en campo. Entre las funcionalidades implementadas se incluyen la consulta de lotes, el registro de capturas, la visualización de diagnósticos y la consulta de la planificación de la cosecha.

Al igual que la aplicación web, la versión móvil consume los servicios proporcionados por el backend mediante la API REST, garantizando que ambos clientes compartan la misma información almacenada en la plataforma. Las principales interfaces desarrolladas para dispositivos móviles se presentan en el Capítulo IV.

Integración de los componentes

Una vez implementados todos los módulos, se realizó su integración para conformar una única plataforma funcional como se observa en la Figura 9. Tanto la aplicación web como la aplicación móvil envían las solicitudes al backend mediante una API REST. A su vez, el backend administra la comunicación con la base de datos PostgreSQL, el almacenamiento de imágenes en Cloudflare R2 y el servicio de inteligencia artificial desarrollado con FastAPI.




Figura 9

Flujo de procesamiento de una captura y entrega de resultados.

Esta integración permitió automatizar el flujo completo del sistema, desde el registro de información en campo hasta la generación de diagnósticos y el apoyo a la planificación de la cosecha, garantizando la consistencia de los datos entre todos los componentes implementados. Para verificar el funcionamiento del backend se realizaron pruebas sobre los diferentes endpoints implementados mediante una API REST. Estas pruebas permitieron comprobar el acceso a los recursos protegidos mediante autenticación basada en tokens JWT y validar la correcta respuesta del servidor en formato JSON. La Figura 10 presenta la consulta del endpoint correspondiente a los lotes registrados en la plataforma.




Figura 10

Prueba de funcionamiento de un endpoint de la API REST implementada para la consulta de lotes mediante autenticación JWT.

3.2.5 Fase 4. Pruebas

Las pruebas tuvieron como finalidad verificar el correcto funcionamiento de cada uno de los módulos desarrollados y comprobar la integración entre los diferentes componentes del sistema. Se llevaron a cabo pruebas funcionales en los procesos de autenticación, gestión de usuarios, administración de lotes, registro de capturas, comunicación con el servicio de inteligencia artificial y generación de la planificación de cosecha. Los resultados logrados posibilitaron la

rectificación de inconsistencias halladas durante el desarrollo y asegurar el correcto funcionamiento de la plataforma previo a su validación en condiciones reales.

3.2.6 Fase 5. Validación

La validación de la plataforma se realizó mediante una prueba de campo en el recinto Valle Hermoso como se puede apreciar en la Figura 11, utilizando imágenes capturadas durante las actividades de monitoreo del cultivo de cacao. Esta fase permitió validar el funcionamiento de la plataforma en campo, con la evaluación de funcionalidades desarrolladas y la integración del servicio de inteligencia artificial para la detección de enfermedades y el reconocimiento del nivel de madurez de las espigas. La plataforma fue verificada que cumple con los requisitos especificados para soportar la supervisión de salud y la planificación de la cosecha con éxito a través de los resultados obtenidos durante la validación.



Figura 11

Procesamiento de grabación de imágenes de mazorcas de cacao durante la validación funcional de la plataforma en el lote Valle Hermoso.

3.3 Disponibilidad del código fuente

Con el propósito de favorecer la reproducibilidad de la presente investigación, el código fuente desarrollado para la plataforma se encuentra disponible en repositorios públicos de GitHub. En estos repositorios se guardan los componentes desarrollados durante la creación del sistema, abarcando la plataforma web, la app móvil, el backend y el servicio de inteligencia artificial

empleado para el análisis de imágenes. Los enlaces a los repositorios son los siguientes:

- **Sitio web, app móvil y servidor backend:**

<https://github.com/MelanyMoreiraZambrano/tesis-cacao>

- **Servicio de IA (FastAPI + YOLO):**

https://github.com/gregoryNa9/Tesis_Plataforma_Cacao

Capítulo 4

Análisis y discusión de los resultados

4.1 Resultados funcionales

La validación funcional tuvo como propósito comprobar el funcionamiento de los principales módulos desarrollados y verificar que las funcionalidades disponibles correspondan con los permisos asignados a cada usuario. La plataforma soporta tres roles, administrador, técnico, agricultor y los usuarios pueden acceder a través de la aplicación web o la aplicación para móvil. Sin embargo, los comandos permitidos en cada perfil a nivel de sistema son diferentes. Fue validado funcionalmente en la unidad de producción Valle Hermoso, para ello se realizó la toma de imágenes de mazorcas mediante la aplicación móvil. En esta fase se verificó la operación de todo el proceso, desde la captura de imágenes en campo, hasta la recepción de diagnósticos producidos por alguno de los modelos de visión artificial y su almacenamiento en la plataforma. Para organizar los resultados obtenidos, la validación se presenta de acuerdo con los tres roles implementados. En cada caso se muestran evidencias obtenidas desde las aplicaciones web y móvil, permitiendo comprobar el funcionamiento de las operaciones disponibles para cada usuario. Posteriormente, se presenta el flujo de análisis realizado con información correspondiente al lote Valle Hermoso, desde el registro de una captura hasta la consulta de los resultados obtenidos.

4.1.1 Validación de las funcionalidades del administrador

El rol de administrador dispone de las funcionalidades necesarias para supervisar la información general de la plataforma. Entre sus principales responsabilidades se encuentran la gestión de usuarios, la administración de lotes, la consulta de diagnósticos, la revisión de planificaciones y el acceso a los reportes generados por el sistema. Estas funciones se encuentran disponibles tanto en la aplicación web como en la aplicación móvil, permitiendo realizar las operaciones desde diferentes tipos de dispositivos.

Durante la validación se comprobó que el administrador puede consultar los usuarios registrados, identificar el rol asignado a cada cuenta y acceder a las opciones de creación y

edición. También se verificó que la información presentada mantiene las operaciones principales disponibles en ambas aplicaciones, adaptando únicamente su distribución al dispositivo utilizado. La Figura 12 presenta el resultado obtenido durante esta validación.




Figura 12

Gestión de usuarios disponible para el rol administrador en las aplicaciones web y móvil.

El manejo de lotes es también una función central disponible para el administrador, con ello se puede dar de alta y mantener actualizada la información de las parcelas que se utilicen en el seguimiento del cultivo. Se almacena para cada lote información como nombre, ubicación, superficie, variedad cultivada, responsable y usuarios. Esta información se utiliza como base para luego asociar las capturas, diagnósticos y planificación.

Como se observa en la Figura 13, el administrador puede consultar los lotes registrados desde las aplicaciones web y móvil. En ambas interfaces es posible crear nuevos registros, modificar la información existente y acceder a las opciones relacionadas con cada parcela. De esta manera, se verificó que la gestión de lotes se mantiene disponible desde las dos plataformas implementadas.




Figura 13

Gestión de lotes disponible para el rol administrador en las aplicaciones web y móvil.

Una vez registrados los lotes y almacenada la información obtenida durante el seguimiento, el administrador puede consultar el módulo de planificación de cosecha. En esta sección la plataforma presenta automáticamente los Grados Día de Desarrollo (GDD) acumulados, el GDD objetivo asociado a la variedad registrada para cada lote, la estimación de los días restantes para alcanzar dicho objetivo y el estado actual de la planificación. Esta información es calculada por el backend a partir de los datos meteorológicos obtenidos mediante la API OpenWeather y constituye una herramienta de apoyo para la programación de las actividades agrícolas.

La Figura 14 presenta el módulo de planificación disponible desde las aplicaciones web y móvil. La información mostrada corresponde al cálculo automático realizado por el backend para cada lote registrado, permitiendo consultar el avance de los GDD acumulados, el valor objetivo definido para la variedad y el estado actual de la planificación. De esta forma, el administrador puede supervisar la evolución de los lotes desde cualquiera de las plataformas implementadas.




Figura 14

Consulta de la planificación de cosecha desde las aplicaciones web y móvil.

La plataforma incorpora además un módulo de reportes que consolida la información registrada durante el seguimiento del cultivo. Este módulo permite consultar indicadores relacionados con los lotes, diagnósticos y planificación, además de generar reportes a partir de la información almacenada. Su disponibilidad permite reunir los principales resultados del seguimiento dentro de una misma sección para su posterior consulta.

Como se observa en la Figura 15, el módulo se encuentra disponible tanto en la aplicación web como en la aplicación móvil. Desde estas interfaces el administrador puede consultar los resultados registrados y generar reportes generales o correspondientes a un lote específico. Con ello se comprobó que la información recopilada puede ser presentada posteriormente mediante los reportes generados por la plataforma.



Figura 15

Módulo de reportes disponible para el rol administrador en las aplicaciones web y móvil.

4.1.2 Validación de las funcionalidades del técnico

El rol de técnico está orientado al seguimiento de los lotes agrícolas y al monitoreo del estado del cultivo. Entre sus principales funciones se encuentran la consulta de los lotes asignados, el registro de capturas, la revisión de los diagnósticos generados por los modelos de inteligencia artificial, la consulta de la planificación y el acceso a los reportes. Estas funcionalidades permiten realizar el seguimiento desde la aplicación web o directamente desde la aplicación móvil durante las actividades de campo.

Durante la validación se comprobó el acceso del técnico a los lotes que se encuentran bajo su responsabilidad. Desde este módulo puede visualizar la información general de cada parcela y acceder a las opciones disponibles para realizar su seguimiento. La Figura 16 muestra los lotes asignados al técnico Melany desde las dos aplicaciones implementadas.




Figura 16

Consulta de lotes desde las aplicaciones web y móvil para el rol técnico.

Una vez seleccionado un lote, el técnico puede registrar imágenes de las mazorcas para realizar el análisis correspondiente. La captura seleccionada es enviada al servicio de inteligencia artificial, donde se procesa para identificar información relacionada con el estado sanitario y el

nivel de madurez observado en las mazorcas. Los resultados obtenidos quedan asociados con el lote desde el cual se realizó el registro, permitiendo mantener una relación entre la imagen analizada, la parcela correspondiente y la información generada durante el proceso.

La Figura 17 presenta una captura utilizada durante la validación realizada en el lote Valle Hermoso. La imagen corresponde a una de las entradas empleadas para comprobar el flujo de análisis implementado desde la aplicación móvil. A partir de este registro se inicia el procesamiento realizado por los modelos de visión artificial integrados en la plataforma.



Figura 17

Registro de capturas para el análisis del cultivo desde la aplicación móvil.

Después de procesar la imagen, la plataforma presenta el resultado del análisis indicando el número de mazorcas detectadas, el estado de madurez identificado y el diagnóstico sanitario correspondiente. Esta información permite que el técnico consulte los resultados generados a

partir de la captura sin separarlos del contexto del lote donde fue realizado el registro. Como se observa en la Figura 18, el análisis realizado con una captura del lote Valle Hermoso generó los resultados correspondientes a los modelos integrados en la plataforma. La información obtenida queda disponible dentro del sistema para su consulta posterior. Con ello se comprobó el flujo comprendido entre el registro de la imagen, su procesamiento y la presentación del diagnóstico.




Figura 18

Resultado del análisis obtenido para una captura del lote Valle Hermoso.

Los análisis realizados quedan registrados dentro del historial de diagnósticos de la plataforma. Este módulo permite consultar las capturas procesadas anteriormente y revisar nuevamente los

resultados obtenidos durante cada análisis. La conservación de estos registros permite relacionar los diagnósticos generados en diferentes momentos con el lote correspondiente y mantener disponible la información obtenida durante el seguimiento.

La Figura 19 presenta el historial de capturas procesadas durante el monitoreo de un lote, donde para cada registro el sistema identifica las mazorcas presentes y muestra de manera diferenciada su estado de maduración y el diagnóstico sanitario. La sección correspondiente al estado de maduración clasifica los frutos según las etapas definidas por el sistema, por lo que los valores mostrados en este apartado no representan la presencia o ausencia de enfermedades; en cambio, el apartado Diagnóstico del modelo presenta el análisis sanitario, en el cual se determina la existencia de posibles indicios de moniliasis y, cuando corresponde, su nivel estimado de afectación. De esta manera, una misma mazorca puede encontrarse en una determinada etapa de maduración y, al mismo tiempo, presentar síntomas de enfermedad, debido a que ambas características son evaluadas de forma independiente por el modelo.

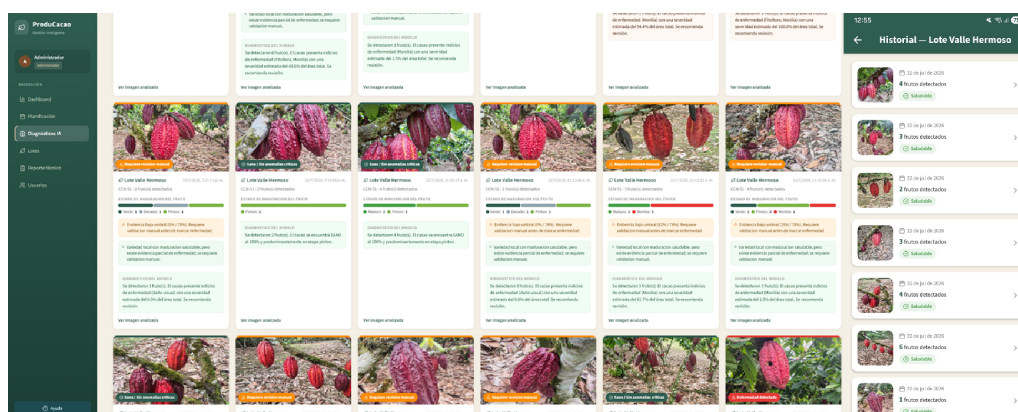


Figura 19

Historial de capturas ingresadas.

El técnico también puede consultar la planificación de cosecha asociada con los lotes asignados. Este módulo presenta la información correspondiente al avance del cultivo y los indicadores utilizados durante el seguimiento de cada parcela. Su disponibilidad permite revisar la planificación conjuntamente con los registros obtenidos durante las actividades de monitoreo. Como se observa en la Figura 20, la planificación se presenta de acuerdo con los lotes disponibles para el técnico. Desde esta sección puede revisar el progreso registrado y la información correspondiente a la estimación de la cosecha. Esto permitió comprobar el acceso

del perfil técnico a los datos utilizados para el seguimiento de los lotes asignados.




Figura 20

Planificación de la cosecha desde el rol de técnico.

Como parte de sus funciones, el técnico dispone del módulo de reportes para consultar y exportar la información registrada durante las actividades de monitoreo. Este módulo reúne los datos correspondientes a los diagnósticos y a la planificación de los lotes, permitiendo presentar la información obtenida durante el seguimiento en un formato preparado para su posterior utilización.

La Figura 21 muestra el módulo de reportes disponible para este perfil. Desde esta sección el técnico puede consultar y descargar los reportes relacionados con los lotes disponibles. Con ello se verificó que la información recopilada durante el seguimiento puede ser posteriormente presentada mediante los documentos generados por el sistema.



Figura 21

Reporte técnico de planificación de cosecha.

4.1.3 Validación de las funcionalidades del agricultor

El rol de agricultor está orientado principalmente a la consulta de la información correspondiente a los lotes que tiene asignados. Desde este perfil es posible revisar las parcelas registradas, los diagnósticos obtenidos y la planificación de cosecha asociada con cada lote. Estas funcionalidades se encuentran disponibles tanto en la aplicación web como en la aplicación móvil, permitiendo acceder a la información desde diferentes dispositivos.

Durante la validación se comprobó que el agricultor puede visualizar la información relacionada con sus lotes asignados. Desde este módulo puede consultar los datos generales de cada parcela y acceder a las funciones habilitadas para realizar el seguimiento del cultivo. La Figura 22 presenta la información disponible desde este perfil.




Figura 22

Vista de lotes asignados por agricultor.

El módulo de diagnósticos permite que el agricultor consulte los resultados generados por los modelos de visión artificial para sus lotes asignados. La información presentada incluye el estado sanitario identificado, la clasificación de madurez de las mazorcas y las observaciones asociadas con cada análisis. De esta manera, los resultados obtenidos durante el monitoreo quedan disponibles para ser revisados por el usuario responsable de la parcela.

Como se observa en la Figura 23, los diagnósticos almacenados pueden ser consultados desde el perfil del agricultor. El módulo presenta la información asociada con los análisis realizados y permite revisar los resultados generados previamente. Con ello se comprobó que este usuario

puede acceder a la información obtenida durante el seguimiento de sus lotes.




Figura 23

Diagnósticos desde el rol de agricultor.

El agricultor también dispone del módulo de planificación de cosecha para los lotes que tiene asignados. En esta sección se presentan los datos relacionados con los grados-día de desarrollo (GDD) y el progreso registrado para cada parcela. Esta información proporciona una referencia para realizar el seguimiento de la evolución del cultivo dentro del proceso de planificación implementado.

La Figura 24 presenta la información de planificación disponible para el agricultor. Desde esta vista puede consultar el estado registrado para sus lotes y revisar la información relacionada con la estimación de la cosecha. De esta forma, se verificó el acceso del usuario a los resultados de planificación correspondientes a las parcelas que tiene asignadas.




Figura 24

Planificación de cosecha de lotes asignados al agricultor.

4.2 Resultados no funcionales

Además de las operaciones asociadas con cada rol, durante la validación se observaron aspectos relacionados con la integración de los componentes, el control de acceso, el funcionamiento de las aplicaciones web y móvil y la permanencia de la información registrada. Estos resultados se obtuvieron a partir de las mismas pruebas realizadas sobre los módulos implementados, por lo que complementan la validación funcional sin incorporar procesos diferentes a los desarrollados durante las pruebas.

Los aspectos observados permiten analizar el comportamiento general de la plataforma más allá de una operación individual. Para ello se consideran la comunicación entre sus componentes, las restricciones aplicadas según los perfiles de usuario, la disponibilidad de las funcionalidades en las aplicaciones web y móvil y la conservación de los registros generados durante el monitoreo.

4.2.1 Integración entre los componentes

La integración de los componentes se comprobó durante las operaciones realizadas desde las aplicaciones web y móvil. Las solicitudes generadas por ambas interfaces son procesadas mediante el backend y utilizan la información almacenada en la misma base de datos. Como resultado, los registros generados desde una aplicación permanecen disponibles para ser consultados posteriormente desde los módulos correspondientes.

El flujo de análisis de imágenes permitió además comprobar la comunicación con el servicio de inteligencia artificial. Una captura registrada desde la aplicación es enviada para su procesamiento y los resultados obtenidos quedan disponibles dentro de la plataforma. De esta manera, la comunicación entre las aplicaciones, el backend, el almacenamiento, la base de datos y el servicio de análisis se mantuvo dentro del flujo previsto para el funcionamiento del sistema.

4.2.2 Control de acceso

La validación realizada con los perfiles de administrador, técnico y agricultor permitió comprobar que las funcionalidades disponibles se presentan de acuerdo con las responsabilidades asignadas a cada usuario. El administrador dispone de funciones de gestión general, mientras que el técnico concentra sus actividades en el seguimiento de los lotes y el agricultor accede principalmente a la consulta de la información correspondiente a sus parcelas.

Este comportamiento se mantuvo durante las pruebas realizadas desde las aplicaciones web y móvil. Cada perfil pudo acceder a las opciones previstas dentro de su funcionamiento y las operaciones disponibles variaron de acuerdo con el rol autenticado. Con ello se verificó la aplicación de las restricciones definidas para los diferentes tipos de usuario registrados dentro de la plataforma.

4.2.3 Compatibilidad entre las aplicaciones

Las pruebas realizadas permitieron utilizar las funcionalidades implementadas tanto desde la aplicación web como desde la aplicación móvil. Ambas interfaces permiten consultar la información almacenada y ejecutar las operaciones disponibles para cada rol, aunque la presentación de los elementos se adapta a las características del dispositivo desde el cual se utiliza la plataforma.

La versión web presenta los módulos dentro de una interfaz orientada a equipos de escritorio, mientras que la aplicación móvil organiza las operaciones para su utilización desde dispositivos móviles. A pesar de estas diferencias de presentación, ambas aplicaciones utilizan la misma información administrada por el backend. Esto permitió comprobar el acceso a los principales módulos desde los dos entornos implementados.

4.2.4 Persistencia de la información

Durante las pruebas se comprobó que la información registrada permanece disponible después de finalizar las operaciones realizadas desde las aplicaciones. Los usuarios, lotes, capturas, diagnósticos y datos de planificación pudieron ser consultados posteriormente desde los módulos correspondientes. Esto permitió conservar los registros generados durante el uso de la plataforma y mantenerlos asociados con la información correspondiente.

En el caso de las capturas procesadas, los resultados obtenidos permanecieron disponibles dentro del historial de diagnósticos. Desde este módulo fue posible revisar análisis realizados anteriormente y relacionarlos nuevamente con el lote correspondiente. De esta forma, la información generada durante el monitoreo pudo mantenerse disponible para posteriores consultas.

4.3 Evaluación de los modelos de visión artificial

La plataforma integra dos modelos de visión artificial basados en YOLOv8. El primero se utiliza para identificar el estado de madurez de las mazorcas, mientras que el segundo permite reconocer indicios asociados con la condición fitosanitaria del fruto. La separación de estas tareas permite analizar de manera independiente el comportamiento alcanzado por cada modelo durante el proceso de validación.

Para evaluar su desempeño se utilizaron las métricas descritas en el Capítulo II precisión, sensibilidad, F1-score y precisión media promedio. También se analizaron las matrices de confusión para identificar las clases que presentan un mayor número de predicciones correctas y aquellas donde existen dificultades de diferenciación. A continuación se presentan los resultados obtenidos para los modelos de madurez y enfermedades.

4.3.1 Evaluación del modelo de madurez

El modelo de madurez fue entrenado para identificar seis categorías asociadas con el desarrollo y la condición visual de las mazorcas: *young*, *immature*, *mature-unripe*, *ripe*, *overripe* y *spoilt*. Estas clases permiten diferenciar frutos en etapas tempranas, intermedias y avanzadas de maduración, además de reconocer aquellos que presentan signos de deterioro dentro del conjunto utilizado durante el entrenamiento.

Las curvas generadas por YOLOv8 durante la validación permitieron analizar el comportamiento del modelo frente a diferentes umbrales de confianza. A partir de ellas es posible observar cómo varían la precisión, la sensibilidad y el equilibrio entre ambas métricas conforme cambia el criterio utilizado para aceptar una detección.

También permiten comparar el desempeño entre diferentes grupos de clases. a las distintas clases evaluadas. en función del umbral de confianza en la Figura 25, esta métrica combina precisión y sensibilidad en un solo número, y es útil para determinar dónde ambas logran un mejor equilibrio. El F1-score más alto obtenido fue 0.71 con un umbral de confianza de 0.480. Cuando el modelo considera predicciones de confianza cercana a 48 %, obtiene ese óptimo equilibrio para detectar la máxima cantidad de mazorcas y minimizar las falsas clasificaciones. 48 %, por tanto, admite el mejor equilibrio entre detecciones verdaderas y falsas.

Este comportamiento también evidencia que las etapas iniciales del desarrollo presentan una mayor dificultad de clasificación, ya que comparten características visuales similares entre sí y generan más confusiones que las categorías correspondientes a estados de madurez avanzados.




Figura 25

Curva F1-score confianza del modelo de madurez basado en YOLOv8.

La curva correspondiente a la clase *ripe* se mantiene por encima de las demás durante gran parte del intervalo analizado, mostrando un mejor comportamiento para la identificación de mazorcas maduras. En cambio, las clases *young* e *immature* tienen valores bajos del F1-score. Esta diferencia es indicativa de que es más difícil distinguir entre dos fases tempranas del desarrollo, que fueron capturadas en las imágenes.

La Figura 26 ilustra la variación de la precisión con el incremento del umbral de confianza. Este indicador representa el porcentaje de detecciones que estaban correctamente clasificadas, y así se pudo estudiar el efecto de aplicar criterios más severos para aceptar predicciones desde el modelo.




Figura 26

Curva precisión–confianza del modelo de madurez basado en YOLOv8.

Un umbral es demasiado alto y puede hacer que se pierdan predicciones válidas con una confianza moderada. Por ello, la precisión se debe observar en conjunto con la sensibilidad con el fin de asegurar un balance entre disminuir los falsos positivos y conservar un mayor número de detecciones verdaderas. Entre todas las clases contempladas, *ripe* mantiene los valores de precisión más altos, mientras que *immature* se comporta peor durante buena parte del intervalo. La Figura 27 muestra la sensibilidad (*Recall*) en función del umbral de confianza durante la

validación. Esta medida es una indicación de la habilidad del modelo para identificar correctamente las mazorcas que realmente pertenecen a clase particular. Su funcionamiento es tal que es posible observar la tasa de elementos identificados cuando aumenta o disminuye el nivel mínimo de confianza que se acepta.




Figura 27

Curva sensibilidad–confianza del modelo de madurez basado en YOLOv8.

Conforme se eleva el umbral de confianza, la sensibilidad va decayendo de forma paulatina. Esto ocurre porque el modelo solo guarda aquellas predicciones que tienen la cifra de confianza más alta y descarta otras predicciones que pueden ser correctas pero con una cifra de confianza inferior. Por ello algunas espigas que aparecen en las fotografías no son detectadas.

Un umbral demasiado alto puede llegar a reducir los falsos positivos pero también puede llegar a suponer un incremento de la probabilidad de perder detecciones válidas. La elección del umbral es un compromiso entre ambas posibilidades.

La figura 28 contiene la curva de Precisión-Sensibilidad (*Precision–Recall*) calculada durante la validación. La presentación de la misma permite tener una visión de ambas métricas por clase y

la mean Average Precision (mAP). De esta forma le permite para ser tomada como una visualización general sobre la capacidad del modelo en detectar los distintos niveles de madurez.




Figura 28

Curva Precisión–Sensibilidad del modelo de madurez basado en YOLOv8.

Tal como se puede observar en la figura, el modelo alcanzó un valor de mAP@0.5 de 0.710 en las seis clases en el transcurso del entrenamiento. Este resultado es una medida de la capacidad del modelo en conjunto cuando se combinan la precisión media por clase y el recall planeado en las distintas clases. Además, se puede ver el contraste de los diferentes valores para cada uno de los niveles de madurez analizados.

El valor de mAP@0.5 resume el desempeño general del modelo, pero también resulta útil revisar el comportamiento individual de cada categoría. La clase *ripe* alcanzó el mayor AP con 0.788, seguida por *mature-unripe* (0.758) y *overripe* (0.748). En cambio, *immature* obtuvo el menor resultado (0.609), seguida por *young* (0.658). Estas diferencias indican que las primeras etapas de desarrollo presentan una mayor dificultad de identificación debido a su similitud visual.

Tabla 5

Resultados de precisión promedio por clase del modelo de madurez.

Clase	AP@0.5
young	0.658
immature	0.609
mature-unripe	0.758
ripe	0.788
overripe	0.748
spoilt	0.698
mAP@0.5	0.710

Los resultados presentados en la Tabla 5 muestran diferencias entre las categorías evaluadas. Las clases correspondientes a etapas avanzadas de maduración alcanzaron los valores más altos de AP, mientras que las etapas iniciales registraron resultados inferiores. En su conjunto, el mAP@0.5 de 0.710 podría resumir el comportamiento de generalización del modelo en las seis clases de objetos.

El modelo de madurez obtenido en la validación está representado en la matriz de confusión mostrada en la Figura 29. A partir de esta figura se puede observar cómo se comporta cada una de las clases particulares, siendo la diagonal principal la que contiene las predicciones correctas, mientras que en los lados de la diagonal se muestran las predicciones erradas debido a confusiones con otras clases. Este análisis complementa el resultado mostrado en las curvas que se han expuesto anteriormente.

La mayoría de las predicciones están localizadas en la diagonal. Esto sugiere que muchas muestras fueron clasificadas de forma correcta. De las clases que estaban en consideración, *mature-unripe* fue la que más aciertos logró, con 247 clasificaciones. Por su parte, la clase *ripe* obtuvo 118 aciertos, comportamiento que es consistente con el hecho de haber alcanzado el mayor AP para dicha clase.




Figura 29

Matriz de confusión del modelo de madurez basado en YOLOv8.

Las principales confusiones se presentan entre estados cercanos dentro del proceso de maduración. La clase *immature* muestra mayores dificultades de diferenciación, lo que coincide con su menor AP de 0.609. En conjunto, la matriz confirma que el modelo presenta un mejor desempeño en las categorías con características visuales más diferenciables y mayores dificultades en etapas con mayor similitud visual.

4.3.2 Evaluación del modelo de enfermedades

El segundo modelo de visión artificial implementado en la plataforma tiene como objetivo identificar el estado fitosanitario de las mazorcas de cacao mediante tres categorías: *Fitóftora*,

Monilia y *Sana*. El modelo de enfermedades fue examinado a través de las mismas métricas que el modelo de desarrollo. Se analizaron las curvas de validación, los valores de precisión promedio y la matriz de confusión para analizar su desempeño, lo que ayudó a entender el comportamiento. visión general del modelo y las distinciones entre las categorías. La conexión entre el F1 y el nivel de confianza se ilustra en la Figura 30. Esta línea de combinación de precisión y sensibilidad posibilita establecer el óptimo equilibrio entre ambas métricas para el algoritmo.




Figura 30

Curva F1-modelo de confianza en enfermedades fundamentado en YOLOv8.

El mejor rendimiento global se alcanzó con un valor F1 de 0.75 y un umbral de confianza de cerca de 0.445. Este resultado señala que este umbral logra la mejor armonía entre la exactitud de las clasificaciones y la habilidad del modelo para prever correctamente las categorías de las imágenes analizadas. El valor conseguido se utilizará como referencia para determinar el comportamiento del modelo en la inferencia.

Al analizar las curvas individuales se observa que las categorías *Monilia* y *Sana* alcanzan valores F1 superiores a los obtenidos por *Fitóftora*. Esta diferencia muestra un comportamiento más consistente para las dos primeras categorías durante la validación. En contraste, la clasificación de *Fitóftora* presenta mayores dificultades a lo largo del intervalo de confianza analizado.

La Figura 31 muestra el comportamiento de la precisión conforme varía el umbral de confianza. Éste es un índice que da cuenta de la proporcionalidad entre detecciones bien clasificadas (es decir, correctamente clasificadas) y que puede ser usado para abstraer e ilustrar cómo el aplicar requisitos de confianza de cada vez más estrictos para poder mantener la predicción. Cuanto más grande sea el umbral, mayor será la precisión ya que el modelo descarta todas las detecciones de una manera determinada como menos confiables para mantener la predicción, pero si los umbrales son demasiado altos se descartarán predicciones correctamente clasificadas que poseían un nivel de confianza medio. Por esta razón la precisión y sensibilidad deben ir de la mano en la interpretación.




Figura 31

Curva precisión–confianza del modelo de enfermedades basado en YOLOv8.

La Figura 32 muestra la relación entre la sensibilidad y el umbral de confianza empleado por el modelo. Esta métrica permite analizar la capacidad para detectar correctamente los casos pertenecientes a cada una de las categorías evaluadas. Su comportamiento disminuye progresivamente conforme aumenta el nivel mínimo de certeza requerido para conservar las predicciones.




Figura 32

Curva de sensibilidad–nivel de confianza del modelo de enfermedades fundamentado en YOLOv8.

La sensibilidad se reduce a medida que crece el umbral de confianza, ya que el modelo ignora predicciones con una certeza inferior. Como resultado, disminuye el número de predicciones erróneas, pero también pueden excluirse muestras que efectivamente pertenecen a alguna de las categorías analizadas. Este comportamiento vuelve a demostrar la conexión entre sensibilidad y precisión.

La Figura 33 presenta la curva Precisión–Sensibilidad obtenida durante la validación del modelo de enfermedades. Esta representación permite observar conjuntamente ambas métricas para cada categoría y determinar el AP correspondiente. A partir de estos resultados se obtiene el valor de mAP@0.5 utilizado para resumir el desempeño general del modelo.




Figura 33

Curva Precisión–Sensibilidad del modelo de enfermedades basado en YOLOv8.

El modelo alcanzó un valor de $mAP@0.5$ de 0.750 para las tres categorías fitosanitarias consideradas. Entre las clases evaluadas, *Monilia* obtuvo el mejor resultado con un AP de 0.840, seguida por la categoría *Sana* con 0.790. Por su parte, *Fitóftora* registró un AP de 0.620, siendo la categoría que presentó el menor resultado durante la evaluación.

Tabla 6

Resultados de precisión promedio por clase del modelo de enfermedades.

Clase	AP@0.5
Fitóftora	0.620
Monilia	0.840
Sana	0.790
mAP@0.5	0.750

Los resultados de la Tabla 6 muestran diferencias entre las tres categorías evaluadas. Monilia presenta el mayor nivel de precisión promedio, mientras que Fitóftora obtiene el menor valor de AP. El resultado global de 0.750 resume el comportamiento alcanzado por el modelo considerando conjuntamente las tres categorías utilizadas durante el entrenamiento.

La Figura 34 presenta la matriz de confusión normalizada obtenida durante la validación. Esta representación permite observar el porcentaje de muestras clasificadas correctamente para cada categoría y las principales confusiones generadas entre ellas. Los valores ubicados en la diagonal principal corresponden a las predicciones realizadas correctamente por el modelo.




Figura 34

Matriz de confusión normalizada del modelo de enfermedades basado en YOLOv8.

La clase *Sana* fue la que tuvo el mayor rango de aciertos, con una sensibilidad estimada en 0.82. Le siguió *Monilia* con un valor próximo a 0.78 y después *Fitóftora* con alrededor de 0.68. Estos resultados indican que el modelo que predice la normalidad tiene un rendimiento mucho más alto que el que predice la enfermedad InFITer muestra un mejor rendimiento en predecir muestras normales en todas las clases, pero tienen más dificultades para distinguir las muestras de *Fitóftora*.

Principalmente hay confusión entre *Fitóftora* y *Monilia* que es congruente con lo que se observa en las curvas de evaluación. En general, las curvas de validación, el AP por clase, y la matriz de confusión indica que para *Monilia* y *Sana* el modelo se comporta mejor, independientemente a que *Fitóftora* representa la mayor dificultad encontrada en dichas evaluaciones.

4.4 Discusión de resultados

Los resultados obtenidos durante las pruebas funcionales y no funcionales permitieron comprobar el comportamiento de los principales componentes desarrollados para la plataforma. La validación realizada con los roles de administrador, técnico y agricultor mostró que las funcionalidades se presentan de acuerdo con las responsabilidades definidas para cada perfil. Esto permitió comprobar el funcionamiento de las operaciones previstas desde las aplicaciones web y móvil.

Durante la validación se evidenció que el técnico podía ingresar a sus lotes, donde podía introducir nuevas capturas y ver los diagnósticos que ofrecían los modelos de visión artificial. El productor, a su vez, podía acceder a la información de sus lotes, a los resultados del monitoreo y a la planificación de la cosecha.

Las pruebas evidenciaron la correcta integración entre el cliente aplicativo y el backend y la base de datos con el servicio de inteligencia artificial, funcionando conjuntamente todos los módulos de la plataforma. También se comprobó el funcionamiento del módulo de planificación de la cosecha, controlando que el cálculo automatizado de los Grados Día de Desarrollo (GDD), la actualización de su acumulado y la proyección del estado de la planificación se ejecutan correctamente para los lotes dados de alta.

A su vez, la integración con el servicio de inteligencia artificial concluyó el flujo que se llevaba a cabo entre la subida de una captura más la consulta a los resultados que se obtuvieron. Las

imágenes procesadas fueron asociadas con el respectivo lote y el diagnóstico seguía accesible en el historial. La validación con datos de la campá Valle Hermoso ha permitido comprobar este proceso en un escenario del uso previsto, en el de la plataforma.

En relación con los modelos de visión artificial, el modelo de madurez alcanzó un $mAP@0.5$ de 0.710, mientras que el modelo de enfermedades obtuvo un valor de 0.750. Respecto al desempeño de los modelos, el sistema de clasificación de madurez alcanzó un $mAP@0.5$ de 0.710, mientras que el modelo de enfermedades obtuvo 0.750. En el primero, la categoría *ripe* registró el mayor AP (0.788) y *immature* el menor (0.609). En el modelo fitosanitario, *Monilia* obtuvo el mejor resultado (0.840), mientras que *Fitóftora* presentó el valor más bajo (0.620). El estudio de las curvas de validación y de las matrices de confusión corroboró estas diferencias. Las fases iniciales de madurez resultaron ser las más complicadas de identificar, mientras que en el modelo de enfermedades las principales confusiones se centraron en la categoría *Fitóftora*. La adición de los modelos de visión artificial a la plataforma facilitó la integración de los diagnósticos fitosanitarios y la clasificación del estado de madurez con el módulo de planificación de cosechas. De esta manera, la información generada durante el monitoreo permanece asociada a cada lote y complementa la estimación basada en los Grados Día de Desarrollo (GDD), proporcionando un mayor soporte para la toma de decisiones relacionadas con el seguimiento del cultivo y la programación de la cosecha.

En conjunto, los resultados obtenidos evidencian que la plataforma cumple con el objetivo planteado en esta investigación al integrar una aplicación web, una aplicación móvil, un backend, una base de datos y modelos de visión artificial para apoyar el monitoreo del cultivo y la planificación de la cosecha. La validación realizada en el lote Valle Hermoso permitió comprobar el funcionamiento del flujo completo del sistema, desde la captura de imágenes hasta la generación de diagnósticos y la estimación automática de la planificación de la cosecha basada en Grados Día de Desarrollo (GDD).

Capítulo 5

Conclusiones y recomendaciones

Este capítulo reúne las principales conclusiones obtenidas durante el desarrollo de la investigación. También se presentan recomendaciones derivadas de la validación realizada y algunas propuestas de trabajo futuro orientadas a ampliar las funcionalidades de la plataforma y favorecer su aplicación en escenarios agrícolas.

5.1 Conclusiones

El objetivo general de la investigación se alcanzó mediante el desarrollo de una plataforma web y móvil que integra modelos de visión artificial para identificar el estado sanitario de las mazorcas, reconocer su nivel de madurez y apoyar la planificación de la cosecha del cacao CCN-51. La solución satisface los requisitos de registro de información del cultivo, análisis automático de imágenes y consulta de resultados en una única plataforma, lo que permite realizar el seguimiento de la actividad de campo.

El primer objetivo concreto consistió en elaborar los conjuntos de datos que se emplearon para entrenar los modelos de visión por computadora. Se utilizaron 827 imágenes para identificar enfermedades y 4390 imágenes para la capacitación del modelo de madurez. Los dos conjuntos fueron estructurados y etiquetados en Roboflow antes de exportarlos en el formato YOLO. Las imágenes obtenidas en la finca Valle Hermoso se destinaban a la validación de la plataforma. El segundo objetivo específico se alcanzó mediante el diseño e integración de la estructura de la plataforma. La solución permite administrar usuarios, lotes, capturas, diagnósticos y la planificación de la cosecha dentro de un mismo sistema. Además, la integración de los diferentes componentes hizo posible almacenar, procesar y consultar la información registrada durante las inspecciones de campo.

El tercer objetivo específico se alcanzó mediante el desarrollo de una aplicación web y una aplicación móvil dirigidas a los diferentes perfiles de usuario. Cada rol dispone únicamente de las funciones necesarias para sus actividades, permitiendo registrar información, consultar diagnósticos, realizar el seguimiento de los lotes y revisar la planificación de la cosecha tanto

desde equipos de escritorio como desde dispositivos móviles.

El cuarto objetivo específico se verificó durante la validación funcional realizada en el lote Valle Hermoso. Las pruebas permitieron validar el correcto funcionamiento de las principales funcionalidades implementadas, y nos proporcionaron información sobre el desempeño de los modelos de visión artificial en un entorno real de aplicación. Los resultados obtenidos muestran que la plataforma puede ser utilizada como herramienta para seguir el desarrollo del cultivo y para planificar la cosecha.

5.2 Recomendaciones

Con base en los resultados del desarrollo y validación de la plataforma se plantean las siguientes recomendaciones:

Ampliar de manera escalonada el conjunto de imágenes usados para entrenar los modelos de visión artificial, agregando fotografías tomadas en distintas fincas, estaciones del año y bajo diferentes condiciones de iluminación con el fin de aumentar la capacidad de generalización de los modelos.

Probar en más fincas de producción de cacao con más técnicos y agricultores la plataforma para analizar su desempeño en diferentes ambientes productivos y obtener retroalimentación que permita mejorar la misma.

Desarrollar un sistema de avisos que informe con suficiente antelación de nuevos diagnósticos, actividades programadas y las fechas estimadas de cosecha para facilitar a los usuarios el seguimiento de los lotes y asistirle la toma de decisiones.

5.3 Trabajos futuros

Como continuidad de la presente investigación, se proponen las siguientes líneas de trabajo para ampliar las capacidades de la plataforma y mejorar su aplicación en escenarios agrícolas reales:

Analizar el uso de modelos de Redes Neuronales Convolucionales (CNN) especializados en clasificación de imágenes para el reconocimiento de enfermedades del cacao. Estas arquitecturas podrían mejorar la identificación de características como lesiones, cambios de textura y variaciones de color presentes en las mazorcas.

Implementa una funcionalidad «offline» en la aplicación móvil, que permita el registro de

capturas y el almacenamiento temporal de datos. Cuando haya acceso a Internet, los datos podrán sincronizarse de manera automática con el servidor.

Ampliar el modelo para incluir la identificación de nuevas enfermedades, plagas y fases fenológicas del cultivo, lo que permitirá obtener diagnósticos más detallados durante el seguimiento.

Conectar sensores o estaciones meteorológicas agrícolas a esta plataforma para recopilar datos ambientales que ayuden en la planificación de la cosecha.

Referencias Bibliográficas

- [1] Instituto Nacional de Investigaciones Agropecuarias (INIAP), «Manual Técnico del Cultivo de Cacao CCN-51 en Ecuador», Ministerio de Agricultura y Ganadería, Quito, Ecuador, inf. téc., 2021.
- [2] J. Ávila y M. Cortés, *El cultivo de cacao CCN-51: Manual de buenas prácticas en el trópico*. Editorial Agropecuaria, 2021.
- [3] J. Reyes y L. Pérez, «Precision agriculture for cacao (*Theobroma cacao* L.) management: A review», *Agronomy*, vol. 11, 2021.
- [4] R. C. Ploetz, «Cacao diseases: important threats to chocolate production worldwide», *Phytopathology*, vol. 105, n.º 12, págs. 1540-1545, 2015.
- [5] B. A. Bailey y L. W. Meinhardt, «Cacao diseases: A history of old enemies and new encounters», *Springer*, 2018.
- [6] Ministerio de Agricultura y Ganadería del Ecuador, *Boletín Situacional del Cacao*, <https://www.agricultura.gob.ec>, Consultado en 2025, 2023.
- [7] International Cocoa Organization, *Quarterly Bulletin of Cocoa Statistics*, <https://www.icco.org>, Consultado en 2025, 2024.
- [8] N. Zhang, M. Wang y N. Wang, «Precision Agriculture—A Worldwide Overview», *Computers and Electronics in Agriculture*, vol. 36, n.º 2–3, págs. 113-132, 2002. DOI: 10.1016/S0168-1699(02)00096-0
- [9] S. Wolfert, L. Ge, C. Verdouw y M.-J. Bogaardt, «Big Data in Smart Farming—A Review», *Agricultural Systems*, vol. 153, págs. 69-80, 2017. DOI: 10.1016/j.agsy.2017.01.023
- [10] V. Anzules, R. Borjas-Ventura, V. Castro-Cepero y A. Julca-Otiniano, «Caracterización de fincas productoras de cacao (*Theobroma cacao* L.) en Santo Domingo de los Tsáchilas, Ecuador», *Bosques Latitud Cero*, vol. 8, n.º 2, 2018.
- [11] D. J. Mulla, «Twenty Five Years of Remote Sensing in Precision Agriculture: Key Advances and Remaining Knowledge Gaps», *Biosystems Engineering*, vol. 114, n.º 4, págs. 358-371, 2013. DOI: 10.1016/j.biosystemseng.2012.08.009

- [12] R. C. Ploetz, «The Impact of Diseases on Cacao Production: A Global Overview», en *Cacao Diseases: A History of Old Enemies and New Encounters*, B. A. Bailey y L. W. Meinhardt, eds., Cham: Springer International Publishing, 2016, págs. 33-59. DOI: 10.1007/978-3-319-24789-2_2
- [13] W. Phillips-Mora y M. J. Wilkinson, «Frosty Pod of Cacao: A Disease with a Limited Geographic Range but Unlimited Potential for Damage», *Phytopathology*, vol. 97, n.º 12, págs. 1644-1647, 2007. DOI: 10.1094/PHYTO-97-12-1644
- [14] P. Delgadillo-Durán, H. Allés, M. Rojas-Molina, D. Moser, C. Viot y C. Lanaud, «A New Method for the Inoculation of *Phytophthora palmivora* and Assessment of Cacao Pod Resistance», *Plant Methods*, vol. 16, 2020. DOI: 10.1186/s13007-020-00656-8
- [15] R. Szeliski, *Computer Vision: Algorithms and Applications*, 2.^a ed. Cham: Springer, 2022. DOI: 10.1007/978-3-030-34372-9
- [16] Y. LeCun, Y. Bengio y G. Hinton, «Deep Learning», *Nature*, vol. 521, n.º 7553, págs. 436-444, 2015. DOI: 10.1038/nature14539
- [17] S. Kumi, D. Kelly, J. Woodstuff, R. Lomotey, R. Orji y R. Deters, «Cocoa Companion: Deep Learning-Based Smartphone Application for Cocoa Disease Detection», *Procedia Computer Science*, vol. 203, págs. 87-94, 2022. DOI: 10.1016/j.procs.2022.07.013
- [18] D. Buenaño Vera, B. Oviedo, W. Chiriboga Casanova y C. Zambrano-Vega, *Deep Learning-Based Computational Model for Disease Identification in Cocoa Pods (Theobroma cacao L.)* 2024. DOI: 10.48550/arXiv.2401.01247 arXiv: 2401.01247 [cs.CV].
- [19] B. A. Bailey y L. W. Meinhardt, eds., *Cacao Diseases: A History of Old Enemies and New Encounters*. Cham: Springer International Publishing, 2016, ISBN: 978-3-319-24789-2. DOI: 10.1007/978-3-319-24789-2
- [20] A. Kamilaris y F. X. Prenafeta-Boldú, «Deep Learning in Agriculture: A Survey», *Computers and Electronics in Agriculture*, vol. 147, págs. 70-90, 2018. DOI: 10.1016/j.compag.2018.02.016

- [21] G. S. McMaster y W. W. Wilhelm, «Growing Degree-Days: One Equation, Two Interpretations», *Agricultural and Forest Meteorology*, vol. 87, n.º 4, págs. 291-300, 1997. DOI: 10.1016/S0168-1923(97)00027-0
- [22] R. Bonhomme, «Bases and Limits to Using Degree-Day Units», *European Journal of Agronomy*, vol. 13, n.º 1, págs. 1-10, 2000. DOI: 10.1016/S1161-0301(00)00058-7
- [23] I. Goodfellow, Y. Bengio y A. Courville, *Deep Learning*. Cambridge, Massachusetts: MIT Press, 2016, ISBN: 978-0-262-03561-3.
- [24] J. Alvarado, J. F. Restrepo-Arias, D. Velásquez y M. Maiza, «Disease Detection on Cocoa Crops Based on Computer-Vision Techniques: A Systematic Literature Review», *Agriculture*, vol. 15, n.º 10, pág. 1032, 2025. DOI: 10.3390/agriculture15101032
- [25] S. Ferraris, R. Meo, S. Pinardi, M. Salis y G. Sartor, «Machine Learning as a Strategic Tool for Helping Cocoa Farmers in Côte d'Ivoire», *Sensors*, vol. 23, n.º 17, pág. 7632, 2023. DOI: 10.3390/s23177632
- [26] Food and Agriculture Organization of the United Nations, *FAOSTAT*, <https://www.fao.org/faostat>, Consultado en 2025, 2023.
- [27] G. Jocher, A. Chaurasia y J. Qiu, *Ultralytics YOLO*, Software de detección y segmentación de objetos, 2023.
- [28] A. P. Romero Vergel, A. V. Camargo Rodriguez, O. D. Ramirez, P. A. Arenas Velilla y A. M. Gallego, «A Crop Modelling Strategy to Improve Cacao Quality and Productivity», *Plants*, vol. 11, n.º 2, pág. 157, 2022. DOI: 10.3390/plants11020157
- [29] J. Redmon, S. Divvala, R. Girshick y A. Farhadi, «You Only Look Once: Unified, Real-Time Object Detection», en *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016, págs. 779-788. DOI: 10.1109/CVPR.2016.91
- [30] J. Redmon y A. Farhadi, *YOLOv3: An Incremental Improvement*, 2018. DOI: 10.48550/arXiv.1804.02767 arXiv: 1804.02767 [cs.CV].

- [31] M. Everingham, S. M. A. Eslami, L. Van Gool, C. K. I. Williams, J. Winn y A. Zisserman, «The Pascal Visual Object Classes Challenge: A Retrospective», *International Journal of Computer Vision*, vol. 111, n.º 1, págs. 98-136, 2015. DOI: 10.1007/s11263-014-0733-5
- [32] R. Padilla, W. L. Passos, T. L. B. Dias, S. L. Netto y E. A. B. da Silva, «A Comparative Analysis of Object Detection Metrics with a Companion Open-Source Toolkit», *Electronics*, vol. 10, n.º 3, pág. 279, 2021. DOI: 10.3390/electronics10030279
- [33] D. M. W. Powers, «Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness and Correlation», *Journal of Machine Learning Technologies*, vol. 2, n.º 1, págs. 37-63, 2011.
- [34] B. N. E. Nyarko, W. B. Wu, J. Zhou y M. M. J. Mohd, «Improved YOLOv5m Model Based on Swin Transformer, K-Means++, and Efficient Intersection over Union (EIoU) Loss Function for Cocoa Tree (*Theobroma cacao*) Disease Detection», *Journal of Plant Protection Research*, vol. 64, n.º 3, 2024.
- [35] J. F. Restrepo-Arias, M. J. Montoya-Castaño, M. F. Moreno-De La Espriella y J. W. Branch-Bedoya, «An Application of Deep Learning Models for the Detection of Cocoa Pods at Different Ripening Stages: An Approach with Faster R-CNN and Mask R-CNN», *Computation*, vol. 13, n.º 7, pág. 159, 2025. DOI: 10.3390/computation13070159
- [36] K. J. Ayikpa, A. B. Ballo, D. Mamadou y P. Gouton, «Classification of Cocoa Pod Maturity Using Similarity Tools for Feature Extraction and Machine Learning», *Data*, vol. 8, n.º 6, pág. 99, 2023. DOI: 10.3390/data8060099
- [37] K. J. Ayikpa, A. B. Ballo, D. Mamadou y P. Gouton, «Optimization of Cocoa Pods Maturity Classification Using Stacking and Voting with Ensemble Learning Methods in RGB and LAB Spaces», *Journal of Imaging*, vol. 10, n.º 12, pág. 327, 2024. DOI: 10.3390/jimaging10120327