UNIVERSIDAD TÉCNICA DE COTOPAXI

FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS

CARRERA DE INGENIERÍA EN SISTEMAS DE INFORMACIÓN

PROPUESTA TECNOLÓGICA

Desarrollo de una aplicación móvil para el control de enfermedades de las hojas de maíz amarillo utilizando inteligencia artificial (CNN), Docker, en el barrio Santo Samana del Cantón Latacunga.

Propuesta tecnológica presentada previo a la obtención del título de ingeniero en sistemas de información

AUTORES:

Cisneros Valencia Diego Isaac

Zela Arias César Alejandro

TUTOR:

Ing. Manuel Villa, Mg.

Latacunga, marzo 2026

Latacunga, marzo, 2026

DECLARACIÓN DE AUTORÍA

Yo Cisneros Valencia Diego Isaac y Zela Arias Césaar Alejandro declaramos ser autores del proyecto de titulación "DESARROLLO DE UNA APLICACIÓN MÓVIL PARA EL CONTROL DE ENFERMEDADES DE LAS HOJAS DE MAÍZ AMARILLO UTILIZANDO INTELIGENCIA ARTIFICIAL (CNN), DOCKER, EN EL BARRIO SANTO SAMANA DEL CANTÓN LATACUNGA.", siendo el Ing. Manuel William Villa Quishpe tutor del presente trabajo de titulación; y eximo expresamente a la Universidad Técnica de Cotopaxi y a sus representantes legales de posibles reclamos o acciones legales.

Además, certifico que las ideas, conceptos, procedimientos y resultados vertidos en el presente trabajo de titulación, son de nuestra exclusiva responsabilidad.

Cisneros Valencia Diego Isaac
CC. 1727653600

Zela Arias César Alejandro
CC. 0503766321

Latacunga, Marzo 2026

AVAL DEL TUTOR DEL PROYECTO DE INVESTIGACIÓN

En calidad de Tutor del Trabajo de Investigación sobre el título: **"DESARROLLO DE UNA APLICACIÓN MÓVIL PARA EL CONTROL DE ENFERMEDADES DE LAS HOJAS DE MAÍZ AMARILLO UTILIZANDO INTELIGENCIA ARTIFICIAL (CNN), DOCKER, EN EL BARRIO SANTO SAMANA DEL CANTÓN LATACUNGA."**, propuesto por los estudiantes **Diego Isaac Cisneros Valencia** con C.I: **1727653600** y **César Alejandro Zela Arias** con C.I: **0503766321** de la Carrera de Sistemas de Información, considero que dicho proyecto de titulación cumple con los requerimientos metodológicos y aportes científico-técnicos suficientes para ser sometidos al tribunal de lectores.

Ing. Manuel William Villa Quishpe, Mg.
C.C. 1803386950
TUTOR

Latacunga, Marzo 2026

AVAL DE APROBACIÓN DE LECTORES

Cumpliendo con el Reglamento de Titulación de la Universidad Técnica de Cotopaxi, en calidad de Lectores de Tribunal de Proyecto de Investigación con el Título "Desarrollo de una aplicación móvil para el control de enfermedades de las hojas de maíz amarillo utilizando inteligencia artificial (CNN), Docker, en el barrio Santo Samana del Cantón Latacunga.", propuesto por los estudiantes Zela Arias César Alejandro y Cisneros Valencia Diego Isaac de la Carrera de Sistemas de Información, me permito indicar que los estudiantes ha concluido todas las observaciones y realizado las correcciones señaladas por el Tribunal de Lectores, además de validar el funcionamiento de la propuesta (aplica para propuesta tecnológica) , por lo cual presentamos el Aval de aprobación del Proyecto de Titulación correspondiente a la modalidad_ Propuesta Tecnológica en virtud de lo cual los postulantes pueden presentarse a la Defensa de su Proyecto de Titulación.

Particular que pongo en su conocimiento para los fines legales pertinentes.

Atentamente,

Lector 1 (Presidente)	Lector 2	Lector 3
Nombre: Ing. Luis René Quisaguano Collaguazo	Nombre: Ing. Diego Geovanny Falconí Punguil	Nombre: Ing. Karla Susana Cantuña Flores
CC:1721895181	CC: 05500800774	CC: 0502305113

BARRIO SANTO SAMANA
67F338RX+44, Cantón Latacunga, Provincia Cotopaxi
Telf. 098 701 2622

AVAL DE IMPLEMENTACIÓN

Mediante el presente pongo a consideración que los señores estudiantes: **Cisneros Valencia Diego Isaac**, con cedula de identidad 1727653600 y **Zela Arias César Alejandro,** con cedula de identidad 0503766321 realizaron su tesis a beneficio del **Barrio Santo Samana** con el tema: "**Desarrollo de una aplicación móvil para el control de enfermedades de las hojas del maíz amarillo utilizando inteligencia artificial (CNN), Docker, en el barrio Santo Samana del Cantón Latacunga**", trabajo que fue presentado y aprobado de manera satisfactoria.

Cesar Augusto Pillo Chango

Sr. Cesar Agusto Pillo Chango

Presidente del Barrio Santo Samana

C.C 0500820121

COMITÉ PRO-MEJORAS DEL BARRIO SANTO SAMANA

Personería Jurídica: Resolución Nro. MIDUVI-OTPSCO-2024-0001-R de fecha Latacunga, 3 de enero del 2024.

NÓMINA DE LOS DIRECTIVOS ELECTOS DEL COMITÉ PRO-MEJORAS DEL BARRIO SANTO SAMANA

N°	NOMBRES Y APELLIDOS	CEDULA	CARGO
1	PILLO CHANGO CESAR AUGUSTO	0500820121	PRESIDENTE
2	PILATASIG GERVACIO SEGUNDO AMABLE	0500742440	VICEPRESIDENTE
3	PICHUCHO PILLO VERÓNICA LEONOR	0503054033	SECRETARIA
4	TIPANLUISA TANDALLA NANCY PIEDAD	0503210288	TESORERA
5	SOPALO MISE MARTHA SILVIA	0502633282	PRIMER VOCAL PRINCIPAL
6	PILLO CHANGO SEGUNDO ANTONIO	0500462437	SEGUNDO VOCAL PRINCIPAL
7	CAMALLE MAIGUA BLANCA HERLINDA	0502823206	PRIMERA VOCAL SUPLENTE
8	MARTINEZ CRUZ MARIA ZENAIDA	0401488135	SEGUNDA VOCAL SUPLENTE

AGRADECIMIENTO

Finalizar esta etapa en la Ingeniería de Sistemas no ha sido solo una cuestión de intelecto, sino de resistencia y lealtad, y no habría llegado a la meta sin mi equipo de vida.

Mi agradecimiento más profundo es para mis padres, Diego Cisneros y Norma Valencia. Gracias por darme las herramientas necesarias para forjar mi futuro y por creer en mi talento desde el primer día. Ver su orgullo al final de este camino es mi mayor recompensa y el motor que me impulsa a ser un mejor profesional y un mejor hijo cada día.

A mi novia, por ser mi refugio en los momentos de mayor estrés y por estar presente en cada trasnocho y cada café. Gracias por entender mis ausencias, por apoyarme en cada línea de código y por ser la motivación extra para superar cualquier obstáculo. Gracias por caminar a mi lado en este gran proyecto de vida.

A mis amigos y colegas de la facultad, con quienes compartí risas, retos y códigos. Gracias por hacer que el paso por la universidad fuera más ligero y por demostrar que el verdadero éxito se construye en equipo.

Diego Isaac Cisneros Valencia

AGRADECIMIENTO

Agradezco en primer lugar a Dios por brindarme salud, vida y la fortaleza necesaria para seguir adelante y permitirme culminar esta importante etapa de mi formación universitaria.

Expreso un profundo agradecimiento a mis padres, Silvia Narcisa Arias López y César Zela Fierro, por educarme con amor, enseñarme valores y brindarme siempre su apoyo incondicional. Gracias a su esfuerzo, sacrificio y confianza he podido alcanzar este importante logro en mi vida.

De igual manera, agradezco a mis hermanos, Mateo Aponte y Alejandra Zela, quienes con su compañía y alegría supieron animarme en los momentos difíciles, acompañándome y alegrando mis días cuando las cosas no iban bien.

También expreso un agradecimiento especial a Jennifer, por su apoyo constante, sus consejos y por brindarme la motivación necesaria para seguir adelante y mantenerme enfocado en mi objetivo de culminar mis estudios y alcanzar este logro académico.

Finalmente, agradezco a nuestro tutor William Villa, por compartir sus conocimientos, orientarnos durante el desarrollo de este trabajo y brindarnos su apoyo en cada etapa de este proceso académico.

César Alejandro Zela Arias

DEDICATORIA

Dedico este trabajo de titulación a los pilares que sostienen mi vida: Diego Roberto Cisneros Gualsaqui y Norma Lisandra Valencia Navarro.

A ustedes, que con su ejemplo de trabajo duro y honestidad me enseñaron a construir mi propio camino. Gracias por ser mi guía, mi fuerza y mi motor incondicional. Sin su apoyo y su fe en mí, nada de esto sería posible; este título no es solo un logro personal, es el fruto de sus sacrificios y el testimonio de mi eterna gratitud. Todo lo que soy se lo debo a ustedes. Los amo con toda mi alma.

Diego Isaac Cisneros Valencia

DEDICATORIA

Dedico este logro en primer lugar a Dios, por darme salud, vida y la fortaleza necesaria para poder culminar esta importante etapa de mi formación universitaria y permitirme alcanzar una meta más en mi vida.

A mis padres, Silvia Narcisa Arias López y César Zela Fierro, quienes han sido el pilar fundamental en mi camino. Gracias por su amor, apoyo, sacrificio y por enseñarme los valores que me han guiado para llegar hasta este momento tan importante.

A mis hermanos, Mateo Aponte y Alejandra Zela, por su compañía, por alegrar mis días y por brindarme su apoyo en los momentos difíciles a lo largo de esta etapa.

Y de manera muy especial, dedico este logro a mi querido abuelito Ceferino Zela, quien, aunque ya no se encuentra físicamente con nosotros, siempre vivirá en mi corazón. Gracias por sus enseñanzas, su cariño y por haber sido una inspiración en mi vida. Donde quiera que esté, este logro también es para usted, porque sé que desde el cielo sigue guiando mis pasos y acompañándome en cada momento de mi vida.

César Alejandro Zela Arias

UNIVERSIDAD TÉCNICA DE COTOPAXI

CENTRO DE IDIOMAS

AVAL DE TRADUCCIÓN

En calidad de Docente del Idioma Inglés del Centro de Idiomas de la Universidad Técnica de Cotopaxi; en forma legal **CERTIFICO** que:

La traducción del resumen al idioma Inglés de la Propuesta Tecnológica cuyo título versa: **" DESARROLLO DE UNA APLICACIÓN MÓVIL PARA EL CONTROL DE ENFERMEDADES DE LAS HOJAS DE MAÍZ AMARILLO UTILIZANDO INTELIGENCIA ARTIFICIAL (CNN), DOCKERS, EN EL BARRIO SANTO SAMANA DEL CANTÓN LATACUNGA.**", presentado por los estudiantes: **Cisneros Valencia Diego Isaac** y **Zela Arias César Alejandro**, de la carrera de **Sistemas de Información**, perteneciente a la **Facultad de Ciencias De La Ingeniería Y Aplicadas**, lo realizaron bajo mi supervisión y cumple con una correcta estructura gramatical del Idioma.

Es todo cuanto puedo certificar en honor a la verdad por lo que autorizo a los peticionarios hacer uso del presente aval para los fines académicos legales.

Latacunga, Marzo del 2026

Atentamente,

Mg. EDISON MARCELO PACHECO PRUNA.

DOCENTE DEL CENTRO DE IDIOMAS-UTC

CI: 0502617350

ÍNDICE GENERAL

1. INFORMACIÓN GENERAL 1
2. INTRODUCCIÓN 2
2.1 SITUACIÓN PROBLEMÁTICA 2
2.2 FORMULACIÓN DEL PROBLEMA 3
2.3 OBJETO Y CAMPO DE ACCIÓN 4
2.3.1 Objeto de Investigación 4
2.3.2 Campo de Acción 4
2.4 BENEFICIARIOS 4
2.4.1 Beneficiarios directos 4
2.4.2 Beneficiarios indirectos 4
2.5 JUSTIFICACIÓN 5
2.6 OBJETIVOS 6
2.6.1 Objetivo general 6
2.6.2 Objetivos específicos 6
2.7 SISTEMA DE TAREAS 6
3. FUNDAMENTACIÓN TEÓRICA 8
3.1 ANTECEDENTES 8
3.2 APLICACIONES MÓVILES 9
3.2.1 Arquitectura Cliente-Servidor 10
3.3 INTELIGENCIA ARTIFICIAL. 10
3.3.1 Machine Learning 11
3.3.2 Red Neuronal Convolucional 12
3.3.3 Transfer Learning 13
3.3.4 Modelo ResNet50 13

3.3.5 Modelo InceptionV3 14
3.3.6 Modelo VGG19 14
3.3.7 Modelo EfficientNet 14
3.3.8 Modelo MobileNetV2 15
3.3.9 Capa Convolucional 15
3.3.10 Capa Pooling 16
3.3.11 Capa Fully Connected 16
3.3.12 Comparación de arquitecturas CNN 17
3.4 CONTAINERIZACIÓN Y MICROSERVICIOS: DOCKER 18
3.4.1 Docker. 18
3.4.2 Dockerfile 18
3.4.3 Imagen Docker 19
3.4.4 Contenedor 19
3.4.5 Docker Hub 20
3.5 HERRAMIENTAS 20
3.5.1 Visual Studio Code 20
3.5.2 Node.js 21
3.5.3 PostgreSQL 21
3.5.4 Tensorflow 21
3.5.5 TensorFlow Lite 22
3.5.6 Tensorflow Keras 22
3.5.7 Google Colab 23
3.5.8 Python 23
3.5.9 FastApi 23
3.6 METODOLOGÍAS 24
3.6.1 Metodología XP 24

3.6.2 Metodología KDD 25
3.7 MAÍZ AMARILLO 26
3.7.1 Fitopatología 26
3.8 Santo Samana 30
4. MÉTODOS Y PROCEDIMIENTOS 31
4.1 ENFOQUE DE LA INVESTIGACIÓN 31
4.2 TIPO DE INVESTIGACIÓN 31
4.2.1 Investigación documental 31
4.2.2 Investigación de campo 32
4.2.3 Investigación tecnológica 32
4.3 TÉCNICAS DE INVESTIGACIÓN 33
4.3.1 Revisión bibliográfica 33
4.3.2 Encuesta 33
4.3.3 Entrevista 33
4.4 TÉCNICA ESPECIFICA 34
4.4.1 Metodología XP 34
4.4.2 Metodología KDD (Knowledge Discovery in Databases) 34
4.5 INSTRUMENTOS DE INVESTIGACIÓN 35
4.5.1 Guía de la entrevista 35
4.5.2 Cuestionario 35
4.6 POBLACION Y MUESTRA 36
4.7 FLUJO DEL SISTEMA 37
4.8 HERRAMIENTAS DE DESARROLLO 40
4.8.1 Herramientas del Frontend 40
4.8.2 Herramientas del Backend 40
4.8.3 Entorno de desarrollo y SaaS 41

5. ANÁLISIS DE RESULTADOS 42
5.1 RESULTADOS DE LA ENTREVISTA 42
5.2 RESULTADO DE LA ENCUESTA 45
5.3 RESULTADOS DE LA METODOLOGÍA XP 55
5.3.1 Roles. 55
5.3.2 Planificación 55
5.3.3 Release Planning 61
5.3.4 Diseño 64
5.3.5 Codificación 69
5.3.6 Prueba 72
5.3.7 Implementación 86
5.4 RESULTADOS DE LA METODOLOGÍA KDD 91
5.4.1 Selección de datos 91
5.4.2 Preprocesamiento de datos 92
5.4.3 Transformación de datos 93
5.4.4 Minería de datos 93
5.4.5 Interpretación y evaluación 94
5.5 COSTO DEL SOFTWARE 99
5.6 COSTO DEL DOCKER E INFRAESTRUCTURA 102
5.7 RESULTADO A LA PREGUNTA DE INVESTIGACIÓN 103
6. CONCLUSIONES Y RECOMENDACIONES 104
6.1 CONCLUSIONES 104
6.2 RECOMENDACIONES 105
7. REFERENCIAS 106
8. ANEXOS 109

ÍNDICE DE TABLAS

Tabla 1.1 Área del conocimiento relacionado al proyecto clasificación de la UNESCO 1
Tabla 2.1 Beneficiarios directos.....4
Tabla 2.2 Beneficiarios indirectos.....4
Tabla 2.3 Tareas por objetivo.....6
Tabla 3.1 Comparación de arquitecturas.....17
Tabla 4.1 Población y muestra objetivo de la entrevista.....37
Tabla 4.2 Población y muestra objetivo de la encuesta.....37
Tabla 5.1. ¿Con qué frecuencia se presentan enfermedades en las hojas del maíz amarillo en su cultivo? (Tabulación).....45
Tabla 5.2. ¿Las enfermedades foliares afectan significativamente el rendimiento de su producción? (Tabulación).....46
Tabla 5.3 ¿Tiene dificultades para identificar correctamente las enfermedades de las hojas del maíz? (Tabulación).....47
Tabla 5.4. Actualmente, ¿cómo identifica las enfermedades del cultivo? (Tabulación). 47
Tabla 5.5. ¿Dispone de un teléfono inteligente (smartphone) con cámara? (Tabulación). 48
Tabla 5.6. ¿Con qué frecuencia utiliza aplicaciones móviles? (Tabulación) 50
Tabla 5.7. ¿Considera útil una aplicación móvil que identifique enfermedades del maíz mediante fotografías y uso de inteligencia artificial? (Tabulación).....51
Tabla 5.8. ¿Cree que una aplicación móvil ayudaría a reducir pérdidas económicas en su producción? (Tabulación).....52
Tabla 5.9. ¿Estaría dispuesto/a a utilizar una aplicación móvil para el monitoreo y control de enfermedades del maíz? (Tabulación).....53
Tabla 5.10. ¿Considera importante que la aplicación sea fácil de usar y funcione sin conexión a internet? (Tabulación).....54
Tabla 5.11 Roles de la metodología XP. 55
Tabla 5.12 Iniciar sesión 56
Tabla 5.13 Recuperar contraseña 56
Tabla 5.14 Registrar parcelas 56
Tabla 5.15 Seleccionar parcela.....57
Tabla 5.16. Capturar fotografía para diagnóstico.....57
Tabla 5.17. Cargar imagen desde la galería 57
Tabla 5.18. Visualizar diagnóstico de enfermedad 58
Tabla 5.19. Ver detalles y recomendaciones.....58
Tabla 5.20. Cerrar sesión.....59
Tabla 5.21. Visualizar parcelas de usuarios 59
Tabla 5.22. Visualizar diagnósticos realizados 59
Tabla 5.23. Visualizar dashboard de KPIs 60
Tabla 5.24. Listado de prioridad de historias de usuario.....60
Tabla 5.25. Iteración Nº1 62
Tabla 5.26. Iteración Nº2 62
Tabla 5.27. Iteración Nº3 63
Tabla 5.28. Iteración Nº4 63
Tabla 5.29 Prueba funcional CP001.....72
Tabla 5.30. Prueba funcional CP002.....74
Tabla 5.31. Prueba funcional CP003.....76
Tabla 5.32. Prueba funcional CP004.....77
Tabla 5.33. Prueba funcional CP005.....78
Tabla 5.34. Prueba funcional CP006.....79
Tabla 5.35. Prueba funcional CP007.....80
Tabla 5.36 Prueba funcional CP008.....81

Tabla 5.37. Prueba funcional CP009....82
Tabla 5.38. Prueba funcional CP010....83
Tabla 5.39. Prueba funcional CP011....84
Tabla 5.40. Prueba funcional CP012....85
Tabla 5.41. Distribución del dataset....93
Tabla 5.42. Configuración de hiperparámetros del modelo MobileNetV2 94
Tabla 5.43. Métrica de evaluación del modelo MobileNetV2 96
Tabla 5.44. Tamaños referentes para estimar....99
Tabla 5.45. Asignación de tamaños a las historias de usuario....99
Tabla 5.46. Estimación del costo del software 101
Tabla 5.47. Estimación anual de costos de infraestructura con Docker en AWS 102

ÍNDICE DE FIGURAS

Figura 3.1 Arquitectura Cliente-Servidor....10
Figura 3.2 La inteligencia artificial es capaz de ver, oír y comprender. 11
Figura 3.3 Tipos de Aprendizaje automático. 12
Figura 3.4 Convolución**.**....16
Figura 3.5 Secuencia de la construcción de un contenedor**.**....19
Figura 3.6 Roya Común del Maíz....28
Figura 3.7 Tizón foliar del maíz.....29
Figura 3.8 Mancha foliar del maíz. 30
Figura 4.1 Recomendaciones de la app.....38
Figura 4.2 Flujo General del sistema 39
Figura 5.1 ¿Con qué frecuencia se presentan enfermedades en las hojas del maíz amarillo en su cultivo? (Pastel).....45
Figura 5.2 ¿Las enfermedades foliares afectan significativamente el rendimiento de su producción? (Pastel).....46
Figura 5.3 ¿Tiene dificultades para identificar correctamente las enfermedades de las hojas del maíz? (Pastel).....47
Figura 5.4 Actualmente, ¿cómo identifica las enfermedades del cultivo? (Pastel).....48
Figura 5.5 ¿Dispone de un teléfono inteligente (smartphone) con cámara? (Pastel). 49
Figura 5.6 ¿Con qué frecuencia utiliza aplicaciones móviles? (Pastel). 50
Figura 5.7 ¿Considera útil una aplicación móvil que identifique enfermedades del maíz mediante fotografías y uso de inteligencia artificial? (Pastel). 51
Figura 5.8 ¿Cree que una aplicación móvil ayudaría a reducir pérdidas económicas en su producción? (Pastel).....52
Figura 5.9 ¿Estaría dispuesto/a a utilizar una aplicación móvil para el monitoreo y control de enfermedades del maíz? (Pastel).....53
Figura 5.10 ¿Estaría dispuesto/a a utilizar una aplicación móvil para el monitoreo y control de enfermedades del maíz? (Pastel).....54
Figura 5.11 Inicio de Sesión.....64
Figura 5.12. Registro de usuarios.....65
Figura 5.13. Gestión de parcelas.....65
Figura 5.14. Historial de diagnóstico 66
Figura 5.15. Gestión de usuarios (Administrador).....66
Figura 5.16. Diagrama caso de uso general 67
Figura 5.17. Diagrama de la base de datos.....68
Figura 5.18. Código de inicio de sesión.....69
Figura 5.19. Código de gestión de parcelas 70
Figura 5.20. Código de envío de imágenes.....71
Figura 5.21 Código de visualización de diagnóstico.....71
Figura 5.22. Código de historial de diagnóstico.....72
Figura 5.23. Iniciar sesión.....73
Figura 5.24. Sesión iniciada.....74
Figura 5.25. Recuperar Contraseña.....75
Figura 5.26. Registrar Parcelas 76
Figura 5.27. Selección de parcela para poder diagnosticar.....77
Figura 5.28. Tomar captura.....78
Figura 5.29. Subir fotos desde la galería.....79
Figura 5.30. Ver diagnóstico de la IA.....80
Figura 5.31. Recomendaciones del diagnóstico.....81
Figura 5.32. Cerrar sesión 82
Figura 5.33 Ver parcelas registradas de los usuarios 83
Figura 5.34 Ver dashboard de administrador.....84

Figura 5.35 Ver KPIs 85
Figura 5.36 Instancia EC2....86
Figura 5.37 Configuración de registros DNS del dominio en Namecheap. 87
Figura 5.38 Instalación del servidor Nginx en la instancia Ubuntu de AWS EC2. 87
Figura 5.39 Creación del archivo de configuración del sitio en Nginx.....88
Figura 5.40 Configuración del proxy inverso en Nginx.....88
Figura 5.41 Configuración de reglas de seguridad en AWS EC2. 89
Figura 5.42 Ejecución de los contenedores Docker 90
Figura 5.43 Código docker.yml 90
Figura 5.44. Preprocesamiento de imágenes....92
Figura 5.45. Evolución de la precisión del modelo durante el entrenamiento y la validación....95
Figura 5.46. Evolución de la función de pérdida del modelo durante el entrenamiento y validación. .95
Figura 5.47. Matriz de confusión del modelo MobileNetV2 96
Figura 5.48. Curvas ROC basado en MobileNetV2. 98

1. INFORMACIÓN GENERAL

- **Tema de proyecto:**

Desarrollo de una aplicación móvil para el control de enfermedades de las hojas de maíz amarillo utilizando inteligencia artificial (CNN), dockers, en el barrio Santo Samana del cantón Latacunga.

- **Modalidad de Titulación:**

Propuesta Tecnológica. [X]

Proyectos de Investigación. [ ]

- **Carrera:**

Sistemas de Información.

- **Trabajo de Titulación Vinculado al Proyecto:**

No Aplica.

- **Equipo de Trabajo del Trabajo de Titulación:**

Ing. Manuel Villa Mgtr., Sr. Diego Isaac Cisneros Valencia, Sr. César Alejandro Zela Arias.

- **Área de Conocimiento:**

Tabla 1.1 Área del conocimiento relacionado al proyecto clasificación de la UNESCO

CAMPO AMPLIO	CAMPO ESPECÍFICO	CAMPO DETALLADO
06 Información y Comunicación(TIC)	**061** Información y Comunicación (TIC)	**0613** Software y desarrollo y análisis de aplicativos.

- **Línea de investigación:**

Tecnología de la Información y las comunicaciones, automatización y optimización de sistemas.

- **Sublínea de investigación de la Carrera:**

Inteligencia artificial y robótica en la industria, los negocios y la gestión de la información.

2. INTRODUCCIÓN

Durante un extenso periodo, la agricultura ha sido crucial para la evolución económica global. Con el fin de aumentar la eficacia del ámbito agrícola y garantizar un suministro adecuado de alimentos frente al aumento de la población y la urbanización, se han diseñado y puesto en práctica, a lo largo del tiempo, múltiples estrategias y enfoques agrícolas. Estas también han contribuido a elevar el volumen de las cosechas [1]. Asimismo, el maíz amarillo se encuentra entre los cultivos más característicos de Ecuador. Sin embargo, la existencia de varios patógenos puede influir en su producción al causar una reducción en el rendimiento y ocasionar efectos adversos en los rubros agrícola e industrial .En las industrias agrícola e industrial, la eficiencia puede ser perjudicada por el riesgo de sufrir ataques de diferentes patógenos .Además, la FAO [2] indica que en Ecuador se sembraron 365 .334 hectáreas de maíz, resultando en una producción completa de 1 .479 .700 toneladas (t) y un promedio de 4,58 t ha-1 por hectárea.

Cotopaxi sobresale como una de las zonas con más producción de alimentos, incluyendo el brócoli y el maíz. Sin embargo, el maíz dorado tiende a ser susceptible a varias enfermedades foliares, lo que pone en peligro la producción y ocasiona pérdidas económicas para los agricultores. En Ecuador, Santo Samana es un barrio que está en el cantón Latacunga, en la provincia de Cotopaxi, es parte de la parroquia Eloy Alfaro [3].

En este marco, se vio conveniente poner en práctica una solución tecnológica fundamentada en inteligencia artificial para ayudar a los agricultores a disminuir las pérdidas económicas y productivas. Por esta razón, la meta de esta investigación es crear una de aplicación móvil que incorpore un modelo dockerizado de CNN para detectar con oportunidad el diagnóstico foliar en la siembra de maíz amarillo en el barrio Santo Samana, cantón Latacunga.

2.1 SITUACIÓN PROBLEMÁTICA

La aparición y difusión de nuevas enfermedades que impactan en los cultivos agrícolas a escala global están íntimamente ligadas con el cambio climático. Este fenómeno se distingue por las modificaciones relevantes en los patrones medioambientales del mundo, si los comparamos con su conducta histórica [4]. Como consecuencia, se han desarrollado diversos instrumentos tecnológicos orientados a la detección y evaluación

de enfermedades en las plantas. Por ejemplo [5] se implementó la herramienta Assess para determinar el grado de severidad de las enfermedades de las plantas, mientras que [6] crearon una extensión para el programa ImageJ de código abierto, enfocada en el estudio de imágenes agrícolas.

Aunque estas soluciones han permitido detectar enfermedades con más precisión, muchas de ellas requieren equipamiento sofisticado o conocimientos técnicos especializados para ser implementadas. Esto limita su aplicación, especialmente en áreas rurales y entre pequeños productores.

En Ecuador, los efectos del cambio climático han influido de manera importante en la actividad agrícola. De acuerdo con [7], las alteraciones en la temperatura máxima absoluta son más pronunciadas en la Región Interandina que en la Región Litoral, lo cual agrava el riesgo de los cultivos.

Los estudios acerca del cultivo de maíz bajo condiciones controladas indican que las temperaturas más elevadas hacen que se acelere el desarrollo fenológico. Sin embargo, en la etapa de reproducción, las altas temperaturas provocan una disminución significativa en el rendimiento del grano, con pérdidas que pueden alcanzar entre un 80 y un 90 % si se contrasta con condiciones térmicas normales [8]. A pesar de estos antecedentes, es evidente que en el país no hay aplicaciones tecnológicas disponibles que contribuyan a la detección temprana de enfermedades foliares del maíz amarillo.

Se ha determinado que, en el cantón de Latacunga, específicamente en el barrio de Santo Samana, las plagas como los ácaros y la mosca blanca se desarrollan más cuando hay un incremento en la temperatura. La tensión térmica, que se presenta cuando las temperaturas diarias superan los 30 °C, es la causa de las alteraciones fisiológicas que impactan en el rendimiento y en el crecimiento de las cosechas [9].

Se reduce la posibilidad de producir y vender maíz amarillo porque esta circunstancia afecta directamente la capacidad competitiva y económica de los campesinos rurales.

2.2 FORMULACIÓN DEL PROBLEMA

¿Cómo se puede mejorar el control de enfermedades en las hojas de maíz amarillo mediante el uso de tecnologías móviles para el barrio Santo Samana del cantón

Latacunga?

2.3 OBJETO Y CAMPO DE ACCIÓN

2.3.1 Objeto de Investigación

El objeto de investigación del presente trabajo es el desarrollo de una aplicación móvil para la detección temprana de enfermedades en las hojas de maíz amarillo en el barrio Santo Samana del cantón Latacunga, enfocado a reducir las pérdidas productivas y económicas que enfrentan los agricultores por medio del uso de herramientas tecnológicas accesibles.

2.3.2 Campo de Acción

El campo de acción de este estudio se enmarca en el área 1203 Ciencia de los Ordenadores, específicamente en las subáreas 1203.17 Informática, 1203.18 Sistemas de Información y Diseño de Componentes y 1203.23 Lenguajes de Programación.

2.4 BENEFICIARIOS

2.4.1 Beneficiarios directos

Tabla 2.1 Beneficiarios directos

FUNCION/ CARGO	DESCRIPCIÓN	N.º DE PERSONAS
Agricultores	Agricultores rurales del barrio Santo Samana de la ciudad de Latacunga	215
	Total	**215**

2.4.2 Beneficiarios indirectos

Tabla 2.2 Beneficiarios indirectos

FUNCION/ CARGO	DESCRIPCIÓN	N.º DE PERSONAS
Consumidores	Consumidores locales y nacionales vinculados a la cadena productiva del maíz.	15.000
	Total	**15.000**

2.5 JUSTIFICACIÓN

El trabajo actual aporta al sector de la agricultura inteligente mediante el uso de métodos de inteligencia artificial para identificar enfermedades en cultivos. Se utilizan redes neuronales convolucionales, un tipo de inteligencia artificial profunda que se enfoca en detectar patrones visuales en fotografías. Su uso en el examen de hojas de maíz amarillo proporciona una mayor comprensión acerca de la aplicación de la visión por computadora en la agricultura, ofreciendo pruebas de su funcionalidad para detectar enfermedades de manera automatizada.

La investigación propone, desde un enfoque práctico, desarrollar una app móvil que tenga la capacidad de examinar imágenes de hojas de maíz amarillo y descubrir posibles enfermedades en etapas tempranas. Esta herramienta tiene la capacidad de simplificar el seguimiento de las cosechas y ayudar a que los agricultores tomen decisiones, posibilitando que se actúe en el momento adecuado ante problemas fitosanitarios y disminuyendo pérdidas en la producción.

Los principales beneficiarios son los agricultores del barrio Santo Samaná del cantón Latacunga, quienes dependen del cultivo de maíz amarillo como una fuente importante de ingresos. Asimismo, los resultados pueden servir como referencia para otros productores agrícolas, técnicos del sector agropecuario y futuros investigadores interesados en la aplicación de inteligencia artificial en la agricultura.

Esta investigación resulta importante porque plantea la implementación de tecnologías innovadoras para tratar una dificultad que afecta directamente la productividad agrícola. La utilización de herramientas fundamentadas en inteligencia artificial puede contribuir a mejorar los procesos de diagnóstico de enfermedades en los cultivos, lo que favorece una gestión más eficiente y sostenible de la producción agrícola.

La investigación es viable gracias a que hay herramientas tecnológicas disponibles que hacen posible crear modelos de inteligencia artificial y aplicaciones móviles. Asimismo, es viable crear una solución tecnológica que puede ser utilizada en situaciones agrícolas gracias al empleo de imágenes de hojas de maíz amarillo para el entrenamiento del modelo y la implementación de redes neuronales convolucionales.

2.6 OBJETIVOS

2.6.1 Objetivo general

Desarrollar una aplicación móvil para el control de enfermedades de las hojas de maíz amarillo utilizando inteligencia artificial (CNN) y Docker para disminuir pérdidas productivas en el barrio Santo Samana del cantón Latacunga.

2.6.2 Objetivos específicos

- Analizar información teórica sobre las enfermedades foliares del maíz amarillo mediante la consulta en fuentes bibliográficas, con la finalidad de obtener fundamentos para su identificación y clasificación.
- Aplicar la metodología KDD para descubrir patrones en las imágenes de hojas de maíz amarillo mediante un modelo de redes neuronales convolucionales que identifiquen las enfermedades foliares.
- Implementar una aplicación móvil que integre el modelo de redes neuronales convolucionales, utilizando Docker, permitiendo la detección temprana de enfermedades foliares en la hoja del maíz amarillo mediante imágenes.

2.7 SISTEMA DE TAREAS

Tabla 2.3 Tareas por objetivo

OBJETIVOS ESPECÍFICOS	ACTIVIDADES (TAREAS)	RESULTADOS ESPERADOS	TÉCNICAS, MEDIOS E INSTRUMENTOS
• Analizar información teórica sobre las enfermedades foliares del maíz amarillo mediante la consulta en fuentes bibliográficas, con la finalidad de obtener fundamentos	• Investigar y buscar información en diferentes fuentes bibliográficas. • Organizar la información relevante que contribuya en el desarrollo del sistema.	• Fundamentación teórica	• Técnicas: Revisión bibliográfica • Medios: Sitios web, artículos científicos y libros con autoría. • Instrumentos: Ficha bibliográfica

OBJETIVOS ESPECÍFICOS	ACTIVIDADES (TAREAS)	RESULTADOS ESPERADOS	TÉCNICAS, MEDIOS E INSTRUMENTOS
para su identificación y clasificación.			
• Aplicar la metodología KDD para descubrir patrones en las imágenes de hojas de maíz amarillo mediante un modelo de redes neuronales convolucionales que identifiquen las enfermedades foliares .	• Preparar la base de datos de imágenes de hojas de maíz amarillo. • Aplicar encuestas a agricultores del sector para recopilar información sobre la presencia y reconocimiento de enfermedades foliares del maíz. • Entrenar el modelo de redes neuronales convolucionales para la detección de enfermedades foliares. • Verificar el desempeño del modelo mediante métricas de evaluación.	• Modelo de redes neuronales convolucionales entrenado, validado y evaluado para la identificación de enfermedades foliares en hojas de maíz amarillo. • Información recopilada mediante encuestas y entrevistas que contribuya a la comprensión y validación del problema de investigación.	• Técnicas: Redes neuronales convolucionales (CNN), encuesta, entrevista. • Medios: Python, TensorFlow/Keras, Google Colab, Formularios digitales. • Instrumentos: Arquitectura CNN, métricas de evaluación, cuestionario de encuesta, guía de entrevista.
• Implementar una aplicación móvil que integre el modelo de redes neuronales convolucionales, utilizando Docker, permitiendo la	• Diseñar la arquitectura de la aplicación móvil. • Desplegar el modelo CNN en contenedores Docker para el análisis de imágenes. • Integrar la aplicación móvil con el servicio basado en CNN. • Implementar la captura y	• Aplicación móvil funcional que permita la detección de enfermedades foliares del maíz amarillo mediante un modelo CNN desplegado en contenedores Docker.	• Técnicas: Pruebas funcionales. • Medios: - Framework de desarrollo móvil Flutter. - Lenguaje de programación Python. - Librerías de aprendizaje

OBJETIVOS ESPECÍFICOS	ACTIVIDADES (TAREAS)	RESULTADOS ESPERADOS	TÉCNICAS, MEDIOS E INSTRUMENTOS
detección temprana de enfermedades foliares en la hoja del maíz amarillo mediante imágenes.	procesamiento de imágenes de hojas de maíz. Realizar pruebas funcionales y evaluar los resultados obtenidos.		profundo TensorFlow/Keras. - Contenedores Docker para el despliegue del modelo. - Dispositivos móviles para pruebas de la aplicación. • Instrumentos: Casos de prueba.

3. FUNDAMENTACIÓN TEÓRICA

3.1 ANTECEDENTES

En [10] se desarrolló una investigación titulada “Desarrollo de un prototipo para la identificación automática de plagas y enfermedades en el cultivo de papa utilizando técnicas de inteligencia artificial en la ciudad de Latacunga”, cuyo objetivo fue diseñar un sistema capaz de identificar enfermedades en hojas de papa mediante el uso de redes neuronales convolucionales y visión por computadora. Para ello se utilizó un conjunto de imágenes de hojas de papa clasificadas en diferentes categorías de enfermedades, aplicando la metodología KDD para el procesamiento y entrenamiento del modelo. Como resultado, el sistema permitió clasificar hojas sanas y hojas afectadas por diferentes enfermedades, alcanzando un nivel alto de precisión en la detección automática, lo que demuestra el potencial de las técnicas de inteligencia artificial para apoyar el diagnóstico temprano en cultivos agrícolas.

De manera similar, en el estudio realizado por [11] titulado “Implementación de una aplicación web y móvil basada en visión por computador para el control de la enfermedad Sigatoka Negra en el cultivo de banano”, se desarrolló una herramienta tecnológica orientada al análisis de imágenes de hojas de banano para detectar signos de la enfermedad mediante técnicas de procesamiento digital de imágenes y aprendizaje

automático. Los resultados evidenciaron que la implementación de la aplicación permitió mejorar el monitoreo del estado sanitario del cultivo y apoyar a los agricultores en la identificación temprana de la enfermedad, facilitando la toma de decisiones para su control.

Así mismo, en la investigación presentada en [12] titulada "Sistema basado en aprendizaje profundo para la detección de enfermedades en plantas mediante imágenes digitales", se propuso el uso de modelos de aprendizaje profundo para la clasificación automática de enfermedades en hojas de diferentes cultivos. El sistema fue entrenado con un conjunto de imágenes previamente etiquetadas, permitiendo identificar patrones visuales asociados a diferentes afecciones foliares. Los resultados demostraron que el uso de redes neuronales convolucionales mejora la precisión en la detección de enfermedades en plantas, evidenciando que la aplicación de técnicas de inteligencia artificial en la agricultura constituye una alternativa viable para apoyar el diagnóstico fitosanitario y reducir pérdidas productivas en los cultivos.

La inteligencia artificial y la visión por computadora permiten, según muestran los antecedentes, analizar imágenes de hojas con el fin de optimizar la identificación de enfermedades en las plantaciones agrícolas. Los agricultores pueden tomar decisiones anticipadamente gracias al uso de redes neuronales convolucionales, ya que estas contribuyen a identificar las enfermedades de las plantas.

3.2 APLICACIONES MÓVILES

Las aplicaciones para teléfonos móviles son programas creados específicamente para funcionar en dispositivos portátiles [13] .El concepto de móvil implica que se puede acceder a datos, programas y dispositivos desde cualquier ubicación .Al crear software de esta clase, es necesario considerar ciertas limitaciones del hardware de estos aparatos, como su tamaño reducido, capacidad de procesamiento limitada, almacenamiento escaso y ancho de banda restringido, entre otros .Algunos ejemplos de este tipo de aplicaciones incluyen: navegación y mapas, búsqueda, videojuegos, mensajería y herramientas para negocios .La aplicación móvil juega un papel crucial, ya que facilita el diagnóstico de plagas al llevar el servicio directamente al campo, superando las barreras geográficas en regiones con poco acceso a especialistas y adaptándose a las condiciones reales de los dispositivos que utilizan los agricultores .De esta manera, las

restricciones técnicas se transforman en pautas de diseño que permiten el desarrollo de una herramienta que sea accesible, práctica y de interés para los productores agrícolas de Cotopaxi.

3.2.1 Arquitectura Cliente-Servidor

La estructura de cliente-servidor es un esquema de sistemas distribuidos en el cual varios clientes envían solicitudes a múltiples servidores, que se encargan de procesar los datos y retornar los resultados apropiados [14]. Este tipo de arquitectura resulta ventajosa para el sistema de diagnóstico de plagas y enfermedades, ya que facilita una escalabilidad controlada, distribuye efectivamente las tareas entre el servidor y la aplicación móvil, y centraliza el modelo de red neuronal convolucional para asegurar diagnósticos consistentes .En la práctica, la aplicación captura la imagen y el servidor ejecuta el modelo de red neuronal convolucional a través de un contenedor Docker, lo que permite realizar diagnósticos precisos sin demandar mucho poder de procesamiento en los dispositivos móviles de los agricultores .

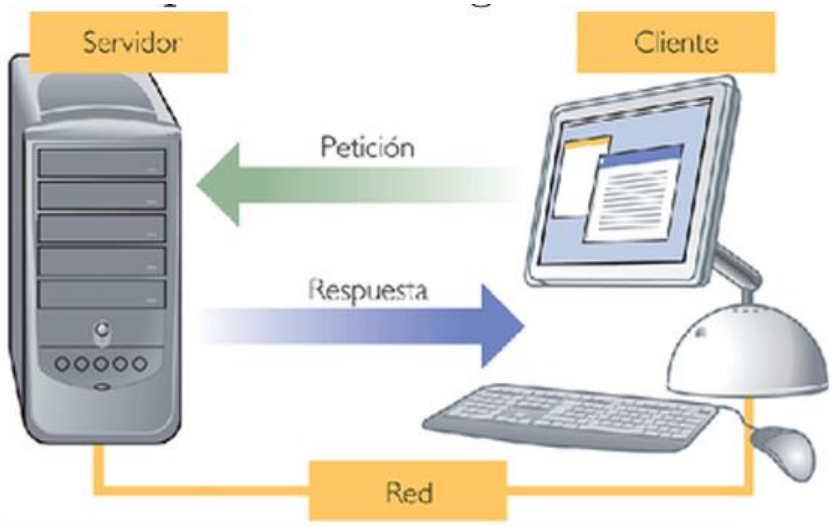


Figura 3.1 Arquitectura Cliente-Servidor.

3.3 INTELIGENCIA ARTIFICIAL.

La inteligencia artificial (IA) es una de las áreas de la ciencia computacional que ha suscitado el mayor interés en estos días, por su vasto campo de aplicación. La exploración de métodos que nos sirvan para entender la inteligencia y construir modelos y simulaciones de ella ha sido un incentivo para que numerosos científicos opten por

esta rama investigativa [15]. La IA es considerada como una herramienta con un gran potencial en el ámbito agrícola, ya que posibilita la solución de problemas y permite automatizar el diagnóstico de plagas. Esto hace posible que las observaciones visuales se conviertan en clasificaciones exactas.

La técnica seleccionada es el aprendizaje guiado, ya que se utiliza un modelo que ha sido entrenado con un conjunto de imágenes previamente categorizadas como hojas saludables o afectadas. Este procedimiento de formación posibilita que el modelo identifique patrones y, luego, reconozca las nuevas imágenes obtenidas en el campo. Esta habilidad para automatizar el reconocimiento visual es la base tecnológica que sostiene el desarrollo de la aplicación móvil.

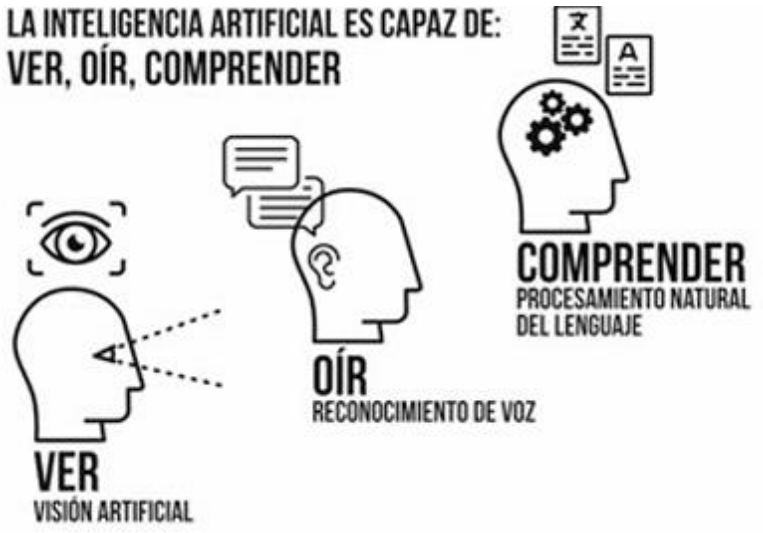


Figura 3.2 La inteligencia artificial es capaz de ver, oír y comprender.

3.3.1 Machine Learning

El machine learning, o aprendizaje automático, es uno de los métodos clave dentro de la inteligencia artificial. En términos simples, consiste en un área de la computación donde los ordenadores o dispositivos pueden adquirir conocimientos sin necesidad de una programación específica. Un resultado típico serían las sugerencias o predicciones en una situación particular [16]. En el marco de este proyecto, el aprendizaje supervisado le otorga relevancia particular al aprendizaje automático. En este modelo, se entrena utilizando un conjunto de datos etiquetados: imágenes de hojas de maíz que han sido clasificadas como sanas, con roya, con tizón o con mancha por curvularia, no

maíz. Durante esta etapa de entrenamiento, el modelo aprende los rasgos visuales que distinguen a cada categoría.



Figura 3.3 Tipos de Aprendizaje automático.

Aprendizaje Profundo (Deep Learning)

El aprendizaje profundo se produce mediante el uso de redes neuronales, que se organizan en capas para reconocer relaciones y patrones complejos en los datos. Su aplicación requiere un enorme conjunto de información y una potente capacidad de procesamiento. Actualmente, se utiliza en el reconocimiento de voz, el procesamiento del lenguaje natural, la visión artificial y la identificación de vehículos en los sistemas de asistencia al conductor [16]. El aprendizaje profundo, a través de Redes Neuronales Convolucionales (CNN), es especialmente apropiado para el diagnóstico automatizado de enfermedades foliares que se ha propuesto. Estas redes se han creado con el propósito de procesar datos visuales y pueden aprender propiedades jerárquicas directamente a partir de imágenes de hojas, desde los bordes y las texturas básicas hasta patrones más complejos como las pústulas de la roya o las heridas alargadas del tizón, sin que sea necesario extraer manualmente dichas características.

El sistema es capaz de clasificar con precisión, basándose en los patrones adquiridos durante el entrenamiento, gracias a la habilidad que tiene de aprender automáticamente rasgos visuales. Esto es esencial para la aplicación móvil, porque le da la posibilidad de interpretar las fotos que los agricultores han tomado.

3.3.2 Red Neuronal Convolucional

Es un tipo de Red Neuronal Artificial con aprendizaje supervisado que procesa sus capas

imitando el cortex visual del ojo humano para identificar distintas características en la entrada que definitivamente hacen que puedan identificar objetos [17]. Por ello gracias a estas características visuales se menciona que [18] las redes neuronales convolucionales (CNN, del inglés Convolutional Neural Networks) son el modelo de DL de mayor importancia en la actualidad.

3.3.3 Transfer Learning

Según [19] el Transfer Learning o aprendizaje por transferencia es un enfoque del aprendizaje automático que busca mejorar el desempeño de un modelo en una tarea objetivo mediante la transferencia de conocimiento obtenido previamente en otro dominio o tarea relacionada. A diferencia de los métodos tradicionales de aprendizaje automático, que asumen que los datos de entrenamiento y los datos futuros provienen de la misma distribución, el Transfer Learning permite que el conocimiento adquirido en un dominio fuente sea utilizado para apoyar el aprendizaje en un dominio diferente o en una tarea distinta.

El Transfer Learning posibilita que se use el conocimiento adquirido previamente por un modelo en una tarea específica para resolver otros problemas asociados. Esto es particularmente eficaz cuando no se cuenta con volúmenes considerables de datos para entrenar un modelo desde el principio, pues el sistema inicia a partir de una base de conocimiento que hace más sencillo el proceso de aprendizaje.

3.3.4 Modelo ResNet50

Según [20] nos dice que el modelo ResNet-50 es una arquitectura de red neuronal convolucional profunda que utiliza conexiones residuales para facilitar el entrenamiento de redes con un gran número de capas. Este modelo permite que la información fluya directamente entre capas mediante conexiones de salto, lo que ayuda a reducir problemas como la degradación del rendimiento en redes muy profundas y mejora la capacidad del modelo para aprender características complejas en imágenes.

ResNet-50 posibilita el entrenamiento de redes más profundas sin que se reduzca la eficacia del modelo, lo cual es beneficioso para extraer características importantes en trabajos de clasificación de imágenes.

3.3.5 Modelo InceptionV3

En [20] nos habla que Inception-V3 es una arquitectura de red neuronal convolucional que tiene como objetivo optimizar la eficacia del procesamiento de imágenes a través de módulos Inception, que posibilitan el análisis simultáneo de filtros de diversos tamaños dentro de la red. La estructura mencionada permite la captura de una variedad de atributos visuales y optimiza el modelo para clasificar imágenes con mayor exactitud.

Inception-V3 permite la evaluación simultánea de diferentes atributos de una imagen, lo cual optimiza el reconocimiento de patrones visuales complejos en trabajos de clasificación.

3.3.6 Modelo VGG19

Según [20] La arquitectura de red neuronal convolucional profunda llamada VGG-19 está formada por 19 capas que pueden ser entrenadas. Se distingue por el empleo de filtros de convolución pequeños, los cuales posibilitan la extracción de rasgos jerárquicos en las imágenes. La estructura sencilla de este modelo y su habilidad para aprender representaciones visuales detalladas hacen que sea muy empleado en trabajos de reconocimiento de imágenes.

VGG-19 permite la detección de patrones visuales en diversos niveles de profundidad dentro de una imagen, lo cual hace más sencillo su empleo para la clasificación y reconocimiento de objetos.

3.3.7 Modelo EfficientNet

Como se explica en [21], EfficientNet es una familia de redes neuronales convolucionales desarrolladas para tareas de visión por computador, como la clasificación de imágenes. Este modelo introduce un método de escalado compuesto que permite aumentar de manera equilibrada la profundidad de la red, el número de canales y la resolución de las imágenes de entrada, con el objetivo de mejorar el rendimiento del modelo manteniendo una alta eficiencia computacional.

EfficientNet posibilita la obtención de modelos de gran precisión sin la necesidad de incrementar los recursos computacionales en exceso, debido a que mejora el crecimiento de la red neuronal con equilibrio. Esto hace más sencillo su uso en diversas labores de

reconocimiento de imágenes, donde se persigue un desempeño óptimo con una utilización eficaz de los recursos.

3.3.8 Modelo MobileNetV2

Según [22] MobileNetV2 es una arquitectura de red neuronal convolucional ligera que se ha creado con el objetivo de optimizar la eficacia en trabajos de clasificación de imágenes. Este modelo disminuye la complejidad computacional de las redes profundas, lo que permite su implementación en contextos con recursos escasos, como los dispositivos móviles. Debido a su arquitectura optimizada, es capaz de conservar un alto grado de exactitud en la identificación de imágenes con menos parámetros y operaciones en comparación con las redes convolucionales tradicionales.

MobileNetV2 aparece como una opción eficaz para crear aplicaciones que se basen en el reconocimiento de imágenes. Este modelo ha sido elegido en el estudio actual para detectar enfermedades en hojas de maíz amarillo porque posibilita llevar a cabo procesos de clasificación con un alto grado de precisión y un uso reducido de recursos, cualidades requeridas para su implementación en una aplicación móvil destinada a los agricultores del barrio Santo Samaná, en el cantón Latacunga.

3.3.9 Capa Convolucional

La parte esencial de la CNN es la capa convolucional. La operación principal que realiza es la convolución, la cual consiste en emplear un filtro (kernel) sobre la imagen para extraer determinadas propiedades [23]. Este proceso genera un mapa de características que destaca específicamente estas estructuras, por ejemplo, mediante un kernel diseñado para detectar bordes. Este tipo de acción se ilustra en la Figura 3.4. En resumen, la función fundamental de la capa de convolución consiste en aplicar diseños (kernels) a las imágenes con el objetivo de reconocer y extraer características o patrones particulares que se encuentran en ellas.



Figura 3.4 Convolución**.**

3.3.10 Capa Pooling

La capa de reducción, que es la segunda en la CNN, tiene como función disminuir el flujo de datos provenientes de las capas de convolución. Esto lo hace al extraer los rasgos o datos más relevantes de la imagen convolucionada. De este modo, reduce la carga computacional que tendrá la red neuronal, lo cual contribuye a que este entrene y separe con mayor precisión cuál información es más importante para eliminar el ruido en la imagen [23].

Es fundamental añadir esta explicación técnica sobre la capa de agrupamiento, ya que establece de qué manera la estructura CNN aborda la eficiencia computacional y la extracción robusta de características. Estas son dos aspectos esenciales para una aplicación móvil que requiere funcionar en dispositivos con limitaciones de recursos. El pooling se refiere al método mediante el cual el modelo reduce la dimensionalidad sin perder la información esencial necesaria para detectar enfermedades, lo que influye directamente en la viabilidad técnica de la aplicación en el contexto de agricultores que utilizan teléfonos inteligentes de gama media.

3.3.11 Capa Fully Connected

Estas capas determinan la puntuación de cada clase de características que se han extraído previamente a la capacitación de la red neuronal, desde las capas de convolución y del max pooling, con el fin de conseguir una clasificación definitiva [23]. Se incluyó esta explicación técnica con el fin de que se comprenda con claridad cómo la aplicación llega a sus conclusiones. No es una "caja negra": se sigue un proceso

específico en el que las propiedades extraídas se convierten en calificaciones de clase, lo cual tiene relevancia ética para los instrumentos diagnósticos.

3.3.12 Comparación de arquitecturas CNN

Tabla 3.1 Comparación de arquitecturas

Arquitectura	Características principales	Ventajas	Desventajas
VGG19	Red profunda con múltiples capas convolucionales y filtros pequeños	Alta capacidad de extracción de características	Alto consumo de memoria y recursos computacionales
ResNet50	Utiliza conexiones residuales que permiten entrenar redes profundas	Reduce el problema de degradación del modelo	Requiere mayor capacidad computacional
InceptionV3	Analiza la imagen en diferentes escalas mediante módulos Inception	Buen equilibrio entre precisión y eficiencia	Arquitectura compleja
EfficientNet	Escalado eficiente de profundidad, ancho y resolución	Alta precisión con menor costo computacional	Requiere ajuste adecuado del modelo
MobileNetV2	Utiliza convoluciones separables en profundidad y bloques residuales invertidos	Modelo ligero optimizado para dispositivos móviles	Puede presentar menor precisión que redes muy profundas en ciertos casos

Según la comparación que se muestra en la Tabla 3.1, las diferentes estructuras de redes neuronales convolucionales son beneficiosas para clasificar imágenes. No obstante, modelos como VGG19, ResNet50 e InceptionV3 demandan más recursos computacionales y parámetros. MobileNetV2 se caracteriza por ser una arquitectura liviana creada para los dispositivos móviles, pues emplea convoluciones separables en profundidad que disminuyen la complejidad del modelo sin alterar de manera notable la

exactitud. Para esta investigación, se eligió MobileNetV2 por estas propiedades, pues posibilita la implementación eficaz de un sistema de detección de enfermedades en las hojas del maíz en una aplicación móvil.

3.4 CONTAINERIZACIÓN Y MICROSERVICIOS: DOCKER

La contenerización implica empaquetar el código de un software junto a las bibliotecas del sistema operativo y las dependencias necesarias para su funcionamiento. Esto resulta en un único ejecutable ligero, conocido como contenedor, que funciona de manera consistente en cualquier infraestructura [24].

Esta capacidad es esencial para el sistema de diagnóstico propuesto, ya que garantiza que el modelo de red neuronal convolucional opere de manera uniforme desde su desarrollo hasta su aplicación en el campo .Además, el empleo de contenedores livianos optimiza el uso de recursos en dispositivos con capacidad limitada, asegurando que la precisión y confiabilidad del diagnóstico permanezcan constantes sin importar el sistema operativo o el hardware utilizado .De esta forma, la contenerización se convierte en el soporte técnico que permite y asegura un diagnóstico fitosanitario confiable en áreas rurales como Santo Samana, utilizando inteligencia artificial .

3.4.1 Docker.

Docker es un proyecto de código abierto, cuya finalidad es automatizar el despliegue de aplicaciones informáticas contenedores de software [25]. Esta tecnología aborda un reto esencial para la implementación del sistema de diagnóstico fitosanitario sugerido: la diferencia entre los ambientes donde se ejecuta. Cuando se implementa en varios dispositivos móviles, el modelo CNN que ha sido entrenado tiene que actuar de la misma forma en los entornos de desarrollo, pruebas y producción.

Docker encapsula en un contenedor reproducible todo el ambiente de ejecución, que incluye la configuración, las bibliotecas, las dependencias y el modelo entrenado. Esto asegura que la exactitud del diagnóstico validado en el laboratorio se reproduzca de manera precisa en la aplicación móvil empleada por los agricultores de Santo Samana, suprimiendo las variaciones originadas por discrepancias en sistemas operativos, versiones de librerías o configuraciones del entorno.

3.4.2 Dockerfile

Un Dockerfile es, sencillamente, el fichero de texto plano que contiene las instrucciones necesarias para crear esta imagen, las cuales se expresarán en forma de comandos (por ejemplo, FROM, COPY, RUN, …) [25]. El Dockerfile opera como un documento ejecutable y versionado del entorno de la aplicación, puesto que especifica de manera explícita y reproducible todos los elementos requeridos para implementar el modelo CNN, incluyendo la imagen base del sistema, las dependencias, el modelo entrenado y la aplicación de inferencia. Asimismo, al permitir la supervisión de las versiones del entorno, automatizar el despliegue y funcionar como un documento técnico vivo, desempeña funciones fundamentales, ya que disminuye los errores humanos. En el caso de Santo Samana, esto asegura que las actualizaciones del modelo CNN se apliquen de manera uniforme en todos los aparatos, lo cual garantiza una consistencia diagnóstica entre los productores agrícolas.



Figura 3.5 Secuencia de la construcción de un contenedor**.**

3.4.3 Imagen Docker

Una imagen es una plantilla que los contenedores Docker utilizan para crear su contenedor en ejecución y son diseñadas para múltiples propósitos. Estas contienen una capa delgada de bibliotecas y binarios que son necesarias para que las aplicaciones funcionen [26]. La imagen concreta para este proyecto incluirá el modelo CNN entrenado para la detección de tizón, roya y mancha en maíz, así como todas las bibliotecas requeridas en una capa optimizada y delgada. Esta encapsulación asegura que el diagnóstico se realice de manera idéntica en el teléfono inteligente de cualquier agricultor de Santo Samana, sin importar las especificidades del aparato.

3.4.4 Contenedor

Los contenedores brindan una vía distinta de virtualización, así como una manera diferente de construir aplicaciones, pues posibilitan el aislamiento de recursos al

virtualizar el sistema operativo y reducir la cantidad de recursos necesarios para ejecutar un programa [27]. Esta propiedad es fundamental para el diagnóstico fitosanitario ya que permite ejecutar de forma efectiva el modelo CNN en teléfonos inteligentes con recursos limitados, proporciona un entorno aislado y confiable de inferencia, y asegura la portabilidad entre diferentes dispositivos y versiones variadas de Android. Esto se traduce en diagnósticos rápidos y coherentes que utilizan poca memoria y batería, lo cual facilita que los agricultores de Santo Samana adopten la herramienta de forma sostenible.

3.4.5 Docker Hub

Docker Hub es un repositorio en la nube de acceso público que difunde contenidos y publica una gran cantidad de imágenes gratuitas. Este es un servicio proporcionado por Docker para encontrar y distribuir imágenes de contenedor. Además, incluye imágenes de las tecnologías de código abierto más importantes; algunas de ellas son: PostgreSQL, Jupyter, Redis y MongoDB [28]. Docker Hub tiene un rol significativo en este proyecto porque facilita la utilización de imágenes base preconfiguradas, acelera el desarrollo, uniformiza el entorno tecnológico entre los desarrolladores y posibilita que las mejoras del modelo CNN se difundan con eficacia. Esto permite que en Santo Samana se apliquen de modo centralizado y uniforme las mejoras en la detección de enfermedades, asegurando que todos los integrantes de la comunidad agrícola puedan acceder a las actualizaciones sin requerir asistencia técnica individual.

3.5 HERRAMIENTAS DE DESARROLLO

3.5.1 Visual Studio Code

Visual Studio Code es un entorno de desarrollo integrado, que posee portabilidad para los diferentes Sistemas Operativos, entre sus características principales está presente la usabilidad ya que gracias a su soporte nativo se puede programar en diferentes lenguajes como JS, TypeScript y Node.js, además tiene múltiples extensiones como C ++, C #, Java, Python, PHP, Go. Por tanto, esta herramienta es ideal para el desarrollo de cualquier proyecto de software [29].

Visual Studio Code fue elegido como el entorno de desarrollo integrado principal, ya que ofrece un soporte extenso para los lenguajes y frameworks que se emplean en el

proyecto, además de ser portable entre sistemas operativos. El ecosistema de extensiones que tiene hace más fácil trabajar con Python, Docker, Flutter y Node.js. Esto posibilita una integración sin problemas entre los servicios en la nube, el desarrollo de la aplicación móvil y los modelos de inteligencia artificial, mejorando así el flujo de trabajo en proyectos multidisciplinarios.

3.5.2 Node.js

Node.JS es un entorno de ejecución para JavaScript el lado del servidor sin bloqueos y por eventos, construido con el motor de JavaScript V8 de Chrome [30].

Node.js se utilizará para crear servicios de soporte que necesiten un alto nivel de concurrencia y operaciones de entrada/salidas no bloqueantes, como la administración de notificaciones en tiempo real o la comunicación entre los distintos servicios. El ecosistema de paquetes hace más sencillo integrar AWS y otros servicios que se emplean en el proyecto.

3.5.3 PostgreSQL

PostgreSQL es un potente sistema de gestión de bases de datos objeto-relacional (SGBD) de código abierto, con más de dos décadas de desarrollo activo y una arquitectura robusta que garantiza alta fiabilidad e integridad de los datos. Funciona en una amplia variedad de sistemas operativos —incluyendo Linux, UNIX y Windows— y destaca como uno de los proyectos de software libre más maduros del mundo. Su licencia BSD permite el acceso, uso, modificación y distribución gratuita de su código fuente, respaldado por una amplia comunidad, empresas y desarrolladores que contribuyen continuamente a su evolución [31].

Para guardar la información estructurada de los usuarios, las imágenes de las hojas de maíz, los registros diagnósticos y los metadatos de los modelos de inteligencia artificial, se emplea PostgreSQL como el sistema principal de base de datos en la nube. Su carácter robusto, la conformidad con ACID y el respaldo para consultas complejas lo convierten en una opción perfecta para analizar después los datos agrícolas recogidos.

3.5.4 Tensorflow

TensorFlow es una librería de código abierto diseñada para ofrecer un alto rendimiento

en computación numérica. Posee una arquitectura flexible que facilita el desarrollo y la ejecución eficiente de modelos en diversas plataformas, incluyendo CPUs, GPUs y TPUs. Su capacidad de escalabilidad le permite funcionar tanto en equipos individuales como en clústeres de servidores. Desarrollada originalmente por el equipo de Google Brain, TensorFlow proporciona un sólido soporte para tareas de Machine Learning y Deep Learning, siendo además una herramienta ampliamente utilizada en distintos campos científicos gracias a la versatilidad que ofrece su enfoque de computación [32].

Para desarrollar y entrenar modelos de CNN que detecten enfermedades en las hojas de maíz, se emplea TensorFlow como marco base. Su flexibilidad, su amplia documentación y su habilidad para llevarse a cabo en GPUs (como las de Google Colab) agilizan el entrenamiento con grandes cantidades de imágenes.

3.5.5 TensorFlow Lite

TensorFlow Lite es una biblioteca de software desarrollada por Google para la implementación de modelos de redes neuronales en dispositivos móviles y sistemas con recursos computacionales limitados. Proporciona una plataforma eficiente para ejecutar modelos de aprendizaje automático en entornos como teléfonos inteligentes, dispositivos IoT y sistemas embebidos. Su función principal es optimizar modelos previamente entrenados, reduciendo su tamaño y mejorando la velocidad de inferencia para permitir una ejecución más eficiente en dispositivos con memoria y capacidad de procesamiento restringidas [33].

TensorFlow Lite es empleado para optimizar e implementar el modelo de CNN que se ha entrenado en la aplicación móvil, lo cual posibilita inferencias en tiempo real directamente en el dispositivo sin necesidad de conectarse a la nube. Esto disminuye la latencia, protege la privacidad de los datos (las imágenes no dejan el dispositivo) y opera incluso cuando no hay conexión.

3.5.6 Tensorflow Keras

Keras es una librería de alto rendimiento integrada en TensorFlow que permite crear y entrenar modelos de aprendizaje profundo de manera sencilla y eficiente. Está diseñada para facilitar el desarrollo rápido de prototipos, apoyar la investigación avanzada y ser

utilizada en entornos de producción, gracias a su enfoque modular y su facilidad de uso [34].

Keras, que está incorporado en TensorFlow, se utiliza para diseñar redes neuronales convolucionales de manera rápida y modular. Esto es posible por su API de alto nivel, la cual facilita el desarrollo, entrenamiento y validación de modelos, lo que acelera la etapa experimental del proyecto.

3.5.7 Google Colab

Google Colab es un entorno en la nube que utiliza notebooks Jupyter y que ya viene con varias bibliotecas científicas preinstaladas. Esto permite trabajar directamente desde el navegador sin necesidad de configuraciones adicionales en el equipo [35]. Para entrenar modelos de IA, se emplea Google Colab como ambiente en la nube, pues brinda GPUs preconfiguradas y sin costo con las librerías requeridas (Keras, TensorFlow, OpenCV). Esto hace posible la cooperación a distancia en el desarrollo de los algoritmos y elimina la necesidad de hardware local caro.

3.5.8 Python

Python es un lenguaje de programación moderno creado por Guido van Rossum a comienzos de los años noventa. Su implementación principal, conocida como CPython, se distribuye como software libre y puede descargarse gratuitamente desde su sitio oficial. Al ser una tecnología abierta, ofrece ventajas importantes frente a soluciones propietarias, ya que puede utilizarse sin costos de licencia. Esto permite que estudiantes o desarrolladores sigan empleando Python fuera de su institución educativa, ya sea para crear software en entornos comerciales o para continuar con estudios avanzados [36].

La razón por la que Python es el lenguaje principal para crear los modelos de IA y la API backend es porque tiene una sintaxis clara, un ecosistema de bibliotecas científicas (OpenCV, Pandas, NumPy) y se utiliza mucho en machine learning. También es compatible con TensorFlow y FastAPI, lo que permite integrar todos los elementos con facilidad.

3.5.9 FastApi

FastAPI es un framework para el desarrollo de API RESTful en Python. Está basado en

Pydantic y utiliza anotaciones de tipo para validar y serializar o deserializar datos, además de generar automáticamente documentación compatible con OpenAPI. Se trata de un framework moderno y de alto rendimiento, diseñado con un fuerte enfoque en la asincronía y compatible con Python a partir de la versión 3.6. Fue desarrollado por Sebastián Ramírez en diciembre de 2018 y su documentación oficial se encuentra disponible en su sitio web [37].

FastAPI es la elección para crear la API REST que conectará los servicios en la nube con la aplicación móvil. Su desempeño asíncrono, la creación automática de documentación OpenAPI y la validación de datos con Pydantic lo convierten en una opción excelente para desarrollar endpoints eficaces que se encarguen de las imágenes y los diagnósticos que provienen desde la aplicación.

3.6 METODOLOGÍAS

3.6.1 Metodología XP

La metodología Extreme Programming (XP), planteada por Kent Beck, establece que cuatro variables fundamentales definen cada proyecto de software: coste, alcance, calidad y tiempo. De acuerdo con este método, únicamente tres de ellas pueden ser determinadas externamente; la cuarta debe definirse por el equipo responsable del desarrollo, basándose en las restricciones establecidas por las otras tres, a fin de garantizar la calidad y la viabilidad técnica del producto [38].

Fases de la Metodología XP

- Planeación

La planeación en la metodología XP es la etapa inicial del proyecto, en la cual se establece la interacción entre el cliente y el equipo de desarrollo para identificar los requerimientos del sistema, determinar el número y la dimensión de las iteraciones y modificar la metodología conforme a los rasgos del proyecto [39].

- Diseño

La etapa de diseño en la metodología XP se basa en el diseño solo de las historias de usuario elegidas para la iteración presente, a partir de un diseño inicial sencillo que se conserva y mejora constantemente a lo largo del desarrollo del proyecto, impidiendo diseños anticipados extensos y permitiendo su corrección a medida que el sistema

evoluciona [39].

- Codificación

El procedimiento de codificación en la metodología XP es cuando el desarrollo del software se lleva a cabo conjuntamente con el diseño, integrando prácticas específicas de XP que pueden ser polémicas, como la programación en parejas y la rotación de programadores, para optimizar la calidad del código y la colaboración [39].

- Prueba

La etapa de pruebas en la metodología XP se centra en implementar y llevar a cabo rigurosamente exámenes durante el desarrollo del software, estableciendo de manera precisa quién, cuándo y cómo deben ser realizados. Esto tiene como objetivo asegurar que el sistema funcione correctamente, facilitar la refactorización del código y posibilitar que las nuevas versiones sean liberadas solo si todas las pruebas han sido aprobadas con éxito [39].

3.6.2 Metodología KDD

El método de KDD (Descubrimiento de Conocimiento en Bases de Datos) es una serie de pasos cíclicos y colaborativos que busca obtener conocimiento a partir de datos. En este enfoque, los resultados de una etapa pueden revisitar fases previas y necesitan la colaboración de un especialista en el área para la organización de los datos y la confirmación del conocimiento obtenido [40].

Fases de la Metodología KDD

- Selección de Datos

La etapa de elección de información en el proceso KDD implica reconocer y seleccionar los grupos de datos que son pertinentes para llevar a cabo el análisis y la obtención de información [40].

- Preprocesamiento de Datos

La etapa de preparación de datos en KDD se ocupa de la corrección de datos erróneos, incompletos o faltantes, con el fin de optimizar la calidad de la información antes de su evaluación.

- Transformación de Datos

La etapa de transformación de datos en el proceso KDD consiste en adaptar los datos y

disminuir su dimensionalidad, lo cual hace que sean más aptos para las técnicas analíticas posteriores [40].

- Minería de Datos

En KDD, la etapa de minería de datos es el momento en que se utilizan métodos para identificar patrones relevantes en los datos, con propósitos descriptivos o predictivos, dependiendo de la tarea de minería ejecutada [40].

- Interpretación y evaluación

La etapa de evaluación e interpretación en el proceso KDD implica examinar y validar el conocimiento adquirido, estableciendo su relevancia y significado en el ámbito de aplicación [40].

3.7 MAÍZ AMARILLO

En Ecuador, el maíz amarillo duro es uno de los cultivos más importantes, ya que tiene un gran valor en términos económicos y de producción. Esta gramínea es una materia prima esencial para la producción de alimentos balanceados para la ganadería industrial, en particular para el sector avícola, el cual tiene un papel destacado dentro del trabajo pecuario a nivel nacional. Por lo tanto, la salud y el rendimiento del cultivo de maíz amarillo duro son factores clave para garantizar que el sistema agro productivo se mantenga [41].

3.7.1 Fitopatología

Cada enfermedad tiene una serie de síntomas que van cambiando, dependiendo del momento en el que se encuentre la enfermedad, el estadio del hospedante y los efectos del entorno. Muchos síntomas son bastante característicos, pero otros pueden confundirse con deficiencias minerales, daños de insectos o ácaros, toxicidad de herbicidas, anormalidades genéticas y otros.

Enfermedades Foliares

En la Sierra ecuatoriana, la producción de maíz es esencial porque este cereal ayuda a garantizar que haya alimentos para la población. El MAG (Ministerio de Agricultura y Ganadería) reporta que, en 2020, esta especie de cereal fue sembrada en 74,018 hectáreas. Esto equivale a cerca del doble de la superficie destinada a otros cultivos

agrícolas relevantes desde el punto de vista socioeconómico, como son los frijoles, las cebadas, las papas, la quinua o el trigo [42]. El barrio Santo Samana, que se encuentra en la provincia de Cotopaxi, es parte de una de las cinco productoras más grandes del país. Sin embargo, este cultivo tiene limitaciones por varias causas; entre ellas se encuentran las enfermedades foliares, que son una de las razones más importantes para el rendimiento escaso en esta zona.

Por lo tanto, para examinar la problemática de manera eficaz, es relevante determinar las enfermedades con mayor prevalencia. La roya común y el tizón son los problemas que causan el mayor daño a las hojas de maíz en nuestra nación. Ambos son producidos por hongos: Puccinia sorghi, que es un hongo biotrófico, y Setosphaeria turcica (conocido también como Exserohilum turcicum en su forma anamorfa), que es un hongo necrotrófico [43]. En consecuencia, se puede concluir que estas son las dolencias más comunes en Ecuador y, por lo tanto, se estudian al monitorear las enfermedades de las hojas del maíz amarillo.

Síntomas y signos

Los síntomas son las manifestaciones que se pueden identificar o percibir de una enfermedad. Surgen de la interacción entre las reacciones defensivas del organismo huésped y los sistemas agresivos del patógeno, así como de las alteraciones fisiológicas que produce la enfermedad en sí. En contraste, se puede detectar una gran variedad de enfermedades mediante la aparición de signos, los cuales son indicios del patógeno y pueden ser identificados con facilidad [44]. Puesto que el modelo de CNN va a ser capaz de reconocer patrones sintomáticos específicos que serán visibles en imágenes, además que el diagnostico automatizado se centra en la identificación de manifestaciones foliares visibles gracias a su previo entrenamiento del sistema de Redes Neuronales Convolucionales. Cabe considerar, que la identificación directa de indicadores patológicos necesita de un equipo especializado, por ende, trasciende el alcance propuesto. Por esta razón los síntomas son señales primarias para realizar un diagnóstico presuntivo.

Enfermedades

3.7.1.1.1 Roya Común

La roya común se identifica como una de las enfermedades fúngicas que más a menudo impactan el cultivo de maíz. Las condiciones habituales de la estación lluviosa en la región andina, en particular las altas temperaturas y la humedad del ambiente, favorecen su crecimiento y expansión [45]. El impacto fisiológico de esta enfermedad incluye el mal funcionamiento y destrucción de los tejidos fotosintéticos. Esta limitación disminuye la captación de radiación solar y la translocación de foto-asimilados reduciendo las "fuentes" para el llenado de los granos [46]. Por lo tanto, la CNN no identifica la enfermedad de manera abstracta, sino que detecta el signo visual que anticipa el daño fisiológico previamente investigado.



Figura 3.6 Roya Común del Maíz

3.7.1.1.2 Tizón Foliar

Nombre de la enfermedad: tizón foliar o mancha norteña del maíz.

Los primeros síntomas se manifiestan con manchas pequeñas ligeramente ovaladas y acuosas que se producen en las hojas inferiores y prosiguen a las hojas superiores como lesiones foliares de forma elíptica y alargadas de color ceniza, a veces verde-grisáceas o pardas. En infecciones severas las lesiones en las hojas crecen y pueden provocar su

muerte prematura y la de la planta [47]. La morfología definida y el contraste, incluido el color grisáceo de las lesiones, proporcionan un patrón morfológico claro y consistente que las redes neuronales convolucionales (CNN) pueden aprender a segmentar y clasificar de manera eficiente, diferenciándolo de otros síntomas foliares.



Figura 3.7 Tizón foliar del maíz.

3.7.1.1.3 Mancha Cercospora

Organismo causal: Curvularia lunata (Wakker) Boedijn.

Nombre de la enfermedad: mancha foliar del maíz.

Los síntomas se presentan con manchas muy pequeñas de forma circular a oval y de apariencia aceitosa. En el centro de cada lesión se observa un punto pardo rodeado con halo ligeramente coloreado y márgenes de color rojizo marrón a marrón oscuro. Las manchas pueden coalescer y ocupar grandes áreas donde las hojas se tornan delgadas y rasgadas. En ataques severos de la enfermedad, las manchas cubren las hojas en su totalidad [47].

Similar a lo que ocurre con la roya y el tizón, la forma circular y los bordes claramente delineados de estas manchas proporcionan una firma visual única que es adecuada para el análisis utilizando Redes Neuronales Convolucionales (CNN). Este modelo tiene la capacidad de distinguir entre este patrón de manchas redondeadas y las lesiones

alargadas del tizón, así como las pústulas distintivas de la roya.



Figura 3.8 Mancha foliar del maíz.

3.8 Santo Samana

El barrio Santo Samaná está situado en la parroquia San Felipe, que se encuentra dentro del cantón Latacunga, de la provincia de Cotopaxi. Este sector se distingue por tener una dinámica agrícola significativa, debido a que un gran número de sus pobladores se ocupa de actividades vinculadas con la producción, el cultivo y la venta de productos agrícolas. En muchas familias, el trabajo agrícola es una de las principales fuentes de sustento; estas personas complementan sus labores con el comercio minorista, el trabajo informal y la prestación de servicios, sobre todo en las áreas más concurridas del cantón. Además, los líderes de la comunidad, las pequeñas empresas y los productores participan de manera activa en proyectos con el objetivo de mejorar la producción agrícola y cubrir las necesidades fundamentales de la población [48].

Según el censo del Instituto Nacional de Estadística y Censos de 2022, la ciudad más poblada de la provincia de Cotopaxi es Latacunga. Esto tiene un impacto directo en la dinámica demográfica de vecindarios como Santo Samaná. En esta situación, se aprecia que un segmento significativo de la población está compuesto por adultos y ancianos, los cuales a menudo participan en actividades de agricultura tradicional o en la venta de productos agrícolas. Sin embargo, este grupo tiene que lidiar con varios obstáculos para acceder a tecnologías digitales y utilizarlas, las cuales podrían simplificar procesos como conseguir información agrícola, ingresar a los mercados o mejorar la producción.

La escasa alfabetización digital es el núcleo de esta problemática, y todavía impacta a una gran parte de la población nacional, en particular a los adultos y a quienes tienen menos ingresos. Esta circunstancia limita su acceso a información, servicios digitales y oportunidades económicas que podrían ayudar a robustecer la actividad agrícola y a mejorar la producción de la comunidad.

En términos generales, los retos que enfrenta la comunidad de Santo Samaná son: mejorar las condiciones de vida de sus residentes, optimizar los procedimientos para comercializar productos agrícolas, incluir a más personas en el mundo digital y potenciar la producción agrícola.

4. MÉTODOS Y PROCEDIMIENTOS

4.1 ENFOQUE DE LA INVESTIGACIÓN

Esta investigación tiene un enfoque metodológico mixto que combina métodos cualitativos y cuantitativos para verificar la solución tecnológica. En la dimensión cuantitativa, se analizaron indicadores de desempeño objetivos, en particular, el grado de exactitud del modelo de red neuronal convolucional al identificar enfermedades en hojas de maíz amarillo y la latencia del sistema que está fundamentado en contenedores Docker. De la misma forma, en la etapa cualitativa se analizó cómo los usuarios apreciaban el uso de la aplicación móvil y la experiencia de interactuar con ella. Esta triangulación de datos empíricos y técnicos posibilita una evaluación integral del sistema, garantizando que la herramienta no solo satisfaga los requerimientos funcionales de la ingeniería de software, sino también que atienda eficazmente los requerimientos operativos del sector agrícola.

4.2 TIPO DE INVESTIGACIÓN

4.2.1 Investigación documental

La investigación documental fue importante para la realización de este proyecto, ya que permitió recopilar información relevante a partir de fuentes bibliográficas, informes técnicos, artículos científicos y documentos oficiales (INEC) relacionados con investigaciones previas y sugerencias similares. Este tipo de investigación fue una contribución significativa para establecer el marco teórico, ya que ayudó a descubrir y comprender conceptos fundamentales y los principios teóricos que apoyan el uso de

redes neuronales convolucionales, así como aplicaciones para dispositivos móviles y su implementación en el sector agrícola. Además, contribuyó con un rigor metodológico y apoyo académico a las soluciones y estrategias propuestas, lo que reforzó la validez y coherencia del trabajo efectuado.

4.2.2 Investigación de campo

La investigación de campo fue esencial porque posibilitó observar directamente el ambiente agrícola en el que se aplicará la solución. Las visitas proporcionaron información directa sobre los procedimientos tradicionales para identificar enfermedades en las hojas del maíz amarillo y sobre las condiciones reales en que los agricultores llevan a cabo esta actividad. También se realizaron encuestas a la población de dicho sector. Con estos datos descubrimos información relevante sobre las necesidades específicas de la población, y también sobre sus limitaciones tecnológicas, lo que más nos llamó la atención fue la necesidad de una herramienta tecnológica de uso sencillo, el acceso limitado a teléfonos inteligentes, y la capacidad de integrar la aplicación y las actividades agrícolas que tienen que ver con el reconocimiento de las enfermedades en las hojas del maíz amarillo.

4.2.3 Investigación tecnológica

Esta investigación fue de vital importancia en el desarrollo del proyecto, porque nos facilitó establecer los fundamentos teóricos y técnicos para desarrollar una aplicación móvil que se integre con un modelo de inteligencia artificial enfocado en detectar enfermedades en las hojas de maíz. Sobre la base del enfoque, desarrollamos una solución tecnológica que utiliza una arquitectura cliente-servidor. En este sistema, se intercambia información de forma estructurada con un servicio especializado en el análisis de imágenes, implementado a través de contenedores Docker.

Con este método, logramos implementar elementos claves como el procesamiento de imágenes, modelos de aprendizaje profundo y servicios backend, lo que hizo posible analizar fotografías de hojas de maíz en tiempo real. También nos aseguramos de que todos los módulos del sistema trabajaran en simultáneo, garantizando estabilidad, escalabilidad y elasticidad en su funcionamiento continuo.

Además, desde el desarrollo de la aplicación móvil pusimos especial atención en la

usabilidad y la experiencia del usuario. Esta orientación hizo que la herramienta final no solo fuera técnicamente sólida, sino también práctica y lista para ser usada por los agricultores.

4.3 TÉCNICAS DE INVESTIGACIÓN

4.3.1 Revisión bibliográfica

Se logró asociar el uso de redes neuronales convolucionales, la elaboración de aplicaciones para móviles y el empleo de contenedores con la revisión del estado del arte que se obtuvo a partir de libros, artículos científicos, bases de datos académicas y otras fuentes especializadas.

Docker y su aplicación en el ámbito agrícola. La recopilación y el estudio de información contribuyeron significativamente a la creación del marco teórico. Asimismo, proporcionó la fundamentación teórica necesaria para llevar a cabo la propuesta tecnológica presentada, garantizando de esta manera rigor académico y coherencia conceptual.

4.3.2 Encuesta

La encuesta que se utilizó como un método cuantitativo fue para recopilar cifras sobre la frecuencia con la que las enfermedades foliares aparecen en las hojas del maíz amarillo, la cantidad de agricultores que utilizan teléfonos móviles. Se utilizó esta herramienta con los agricultores del barrio Santa Samana.

Se empleó un cuestionario de diez preguntas cerradas con el propósito de examinar la condición de las enfermedades en los cultivos, las dificultades para detectarlas a tiempo y el nivel de acceso y comprensión de la tecnología móvil. Para analizar las respuestas, se empleó una escala Likert. Esto facilitó la obtención de datos numéricos que podían ser examinados mediante un estudio descriptivo en términos estadísticos.

4.3.3 Entrevista

La entrevista fue empleada como método de investigación cualitativa con el propósito de compilar datos acerca de las condiciones en las que se cultiva maíz amarillo en la localidad Santo Samana, cantón Latacunga. Para lograrlo, se entrevistó al presidente del sector y a expertos en el área agrícola, los cuales proporcionaron información importante

sobre las enfermedades de las hojas, los métodos actuales para identificarlas y controlarlas, y los principales retos que afrontan los agricultores.

Las entrevistas se llevaron a cabo con base en una guía previamente diseñada, organizada en apartados que abordaban información general del cultivo, el estado actual de las enfermedades, su incidencia en la producción, el uso de tecnología y la disposición hacia una aplicación móvil sustentada en inteligencia artificial. A pesar de que las preguntas se habían preparado con anterioridad, el formato posibilitó una interacción flexible que favoreció la profundización en aspectos importantes del contexto agrícola local.

4.4 TÉCNICA ESPECIFICA

4.4.1 Metodología XP

El aplicativo para dispositivos móviles se elaboró utilizando la metodología ágil de Programación Extrema (XP), debido a que su perspectiva es iterativa y adaptable, además de centrarse en la calidad del software. Por medio de esta metodología, fue posible administrar las tareas del proyecto eficientemente a través de ciclos de desarrollo cortos, entregas funcionales regulares y una retroalimentación continua. Esto permitió que se ajustara a lo que requerían los usuarios finales y las exigencias del entorno agrícola.

XP empleó la programación incremental, la verificación continua de funciones y el perfeccionamiento progresivo del sistema como métodos para estructurar el trabajo. Todo esto contribuyó a conseguir una aplicación móvil que es estable, funcional y se ajusta a los objetivos del proyecto, mientras se redujeron los errores y se mejoraron los plazos de desarrollo.

4.4.2 Metodología KDD (Knowledge Discovery in Databases)

La metodología KDD fue empleada para poner en funcionamiento el modelo de inteligencia artificial. Esta metodología ofrece un marco organizado para convertir los datos en conocimiento útil. La utilización de esta técnica posibilitó que se analizaran las imágenes de hojas de maíz amarillo de forma sistemática a través del uso de redes neuronales convolucionales, con el objetivo de detectar enfermedades en las hojas.

El proceso KDD incluyó la recolección y selección de imágenes, la limpieza y preprocesamiento de datos, la conversión y preparación del conjunto de datos, el minado de datos a través del entrenamiento del modelo CNN, así como la evaluación de los resultados obtenidos. La implementación de este método aseguró que el modelo desarrollado tuviera precisión técnica y que los resultados generados por el sistema de inteligencia artificial fueran confiables.

4.5 INSTRUMENTOS DE INVESTIGACIÓN

4.5.1 Guía de la entrevista

En el anexo B se presentan las preguntas hechas al presidente del barrio y a especialistas en agricultura. Dichas preguntas se dividieron en segmentos que cubrieron la información general acerca del cultivo de maíz amarillo, el estado actual de las enfermedades foliares y su efecto en la producción, la utilización de tecnologías en trabajos agrícolas y la disponibilidad de una aplicación para dispositivos móviles basada en inteligencia artificial con el objetivo de detectar esas enfermedades.

El presidente y los expertos en el sector agrícola fueron informados, antes de la entrevista, de que la información recopilada solo se utilizaría con fines académicos. Así, se aseguraba la privacidad de los datos y se promovía un ambiente confiable y transparente durante la entrevista. La guía también posibilitó una interacción flexible, lo que permitió abordar de manera exhaustiva temas importantes, fundamentados en los conocimientos y la experiencia de los entrevistados, aun cuando las preguntas se habían establecido previamente.

4.5.2 Cuestionario

Se empleó un cuestionario como herramienta para recolectar información numérica sobre la manera en que los agricultores de Santo Samana observan las enfermedades foliares del maíz amarillo y su disposición a usar una aplicación móvil con inteligencia artificial para asistir en el diagnóstico.

El instrumento contenía diez preguntas cerradas, organizadas en una escala de cinco puntos. La meta era analizar la frecuencia de las enfermedades, los obstáculos para detectarlas, la manera en que se accede y utiliza la tecnología móvil, así como la utilidad, el valor práctico y el beneficio de la solución tecnológica propuesta. Se les garantizó a los

participantes, antes de comenzar, que sus respuestas se utilizarían solo con fines académicos y que se guardarían en confidencialidad. En el Anexo C está la lista completa de preguntas.

4.6 POBLACION Y MUESTRA

La población está integrada por los residentes del barrio Santo Samana, ubicado en el cantón Latacunga, consiste en aproximadamente 215 habitantes. Se logró una muestra de 67 personas, elegidas a través del muestreo no probabilístico por conveniencia, utilizando la fórmula para poblaciones finitas y con un margen de error del 10% y un nivel de confianza del 95%.

$$n = \frac{N \cdot Z^2 \cdot p \cdot q}{d^2 \cdot (N-1) + Z^2 \cdot p \cdot q}$$

Donde:

- **n:** Tamaño de la muestra (valor a calcular).
- **N:** Tamaño de la población finita (215 habitantes).
- **Z:** Valor crítico de la distribución normal según el nivel de confianza (1.96 para 95%).
- **p:** Proporción esperada de la población con la característica de interés (generalmente 0.5 para máxima variabilidad y cálculo conservador).
- **q:** 1 - p (0.5 si p=0.5).
- **d:** Margen de error deseado (0.10 para 10%).

Resolución:

$$\boldsymbol{n = \frac{215 \times 1,96^2 \times 0,5 \times 0,5}{0,10^2(215-1) + 1,96^2 \times 0,5 \times 0,5}}$$

$$\boldsymbol{n = \frac{215 \times 3,8416 \times 0,25}{0,01 \times 214 + 3,8416 \times 0,25}}$$

$$\boldsymbol{n = \frac{206,486}{3,1004}}$$

$$\boldsymbol{n = 66,59\ (Aproximado\ a\ 67)}$$

Tabla 4.1 Población y muestra objetivo de la entrevista

Tipo de usuario	Cantidad	Instrumento de aplicación.
. Presidente del Barrio Santo Samana, Especialistas en el área de agronomía.	6	Entrevista

Tabla 4.2 Población y muestra objetivo de la encuesta

Tipo de usuario	Cantidad	Instrumento de aplicación.
. Habitantes del Barrio Santo Samana	67	Encuesta

4.7 FLUJO DEL SISTEMA

La interfaz principal del sistema es la aplicación móvil, ya que permite que el usuario capture y envíe fotografías de hojas de maíz amarillo para que sean analizadas por el sistema. Para garantizar una adecuada calidad en las imágenes utilizadas para el diagnóstico, la aplicación muestra previamente recomendaciones al usuario, tales como tomar la fotografía con luz natural, evitar el uso de flash para prevenir brillos que puedan afectar el análisis, mantener la hoja limpia y acercar la cámara entre 15 y 25 cm de la zona afectada, procurando enfocar correctamente el área dañada. Los datos recogidos son administrados en un backend que opera bajo una arquitectura cliente-servidor y que fue implementado mediante contenedores Docker. En este entorno se integra un modelo de redes neuronales convolucionales, cuya función es identificar posibles enfermedades presentes en las hojas.

El modelo funciona de manera independiente, lo que permite asegurar un procesamiento eficiente, escalable y confiable dentro de un entorno controlado. Por su parte, el backend se encarga de gestionar las peticiones provenientes de la aplicación móvil, almacenar y procesar las imágenes capturadas y coordinar la comunicación con el modelo de inteligencia artificial. De esta forma, actúa como intermediario entre el modelo de redes neuronales convolucionales y el sistema, garantizando que el flujo de información se realice de manera segura, eficiente y organizada.

Cuando la aplicación móvil envía una imagen al backend, este la redirige al servicio del modelo de redes neuronales convolucionales para su análisis. En esta etapa se utiliza un

sistema de inferencia que examina la imagen y compara sus características visuales con los patrones previamente aprendidos a partir de 4158 imágenes utilizadas en el proceso de entrenamiento. Con base en este análisis, el modelo determina la posible enfermedad que afecta a la hoja de maíz. Posteriormente, el backend devuelve el resultado generado por el modelo a la aplicación móvil, donde el diagnóstico es presentado al usuario de forma clara y comprensible, facilitando así la toma de decisiones para el manejo del cultivo.

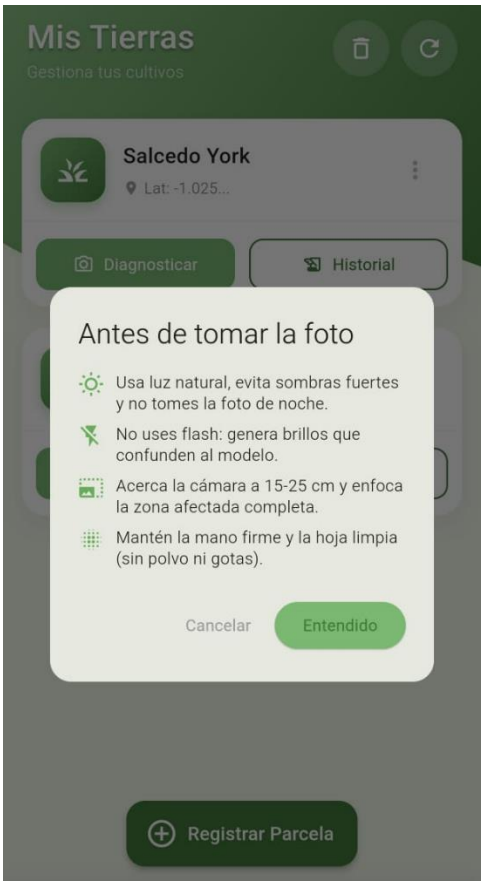


Figura 4.1 Recomendaciones de la app.

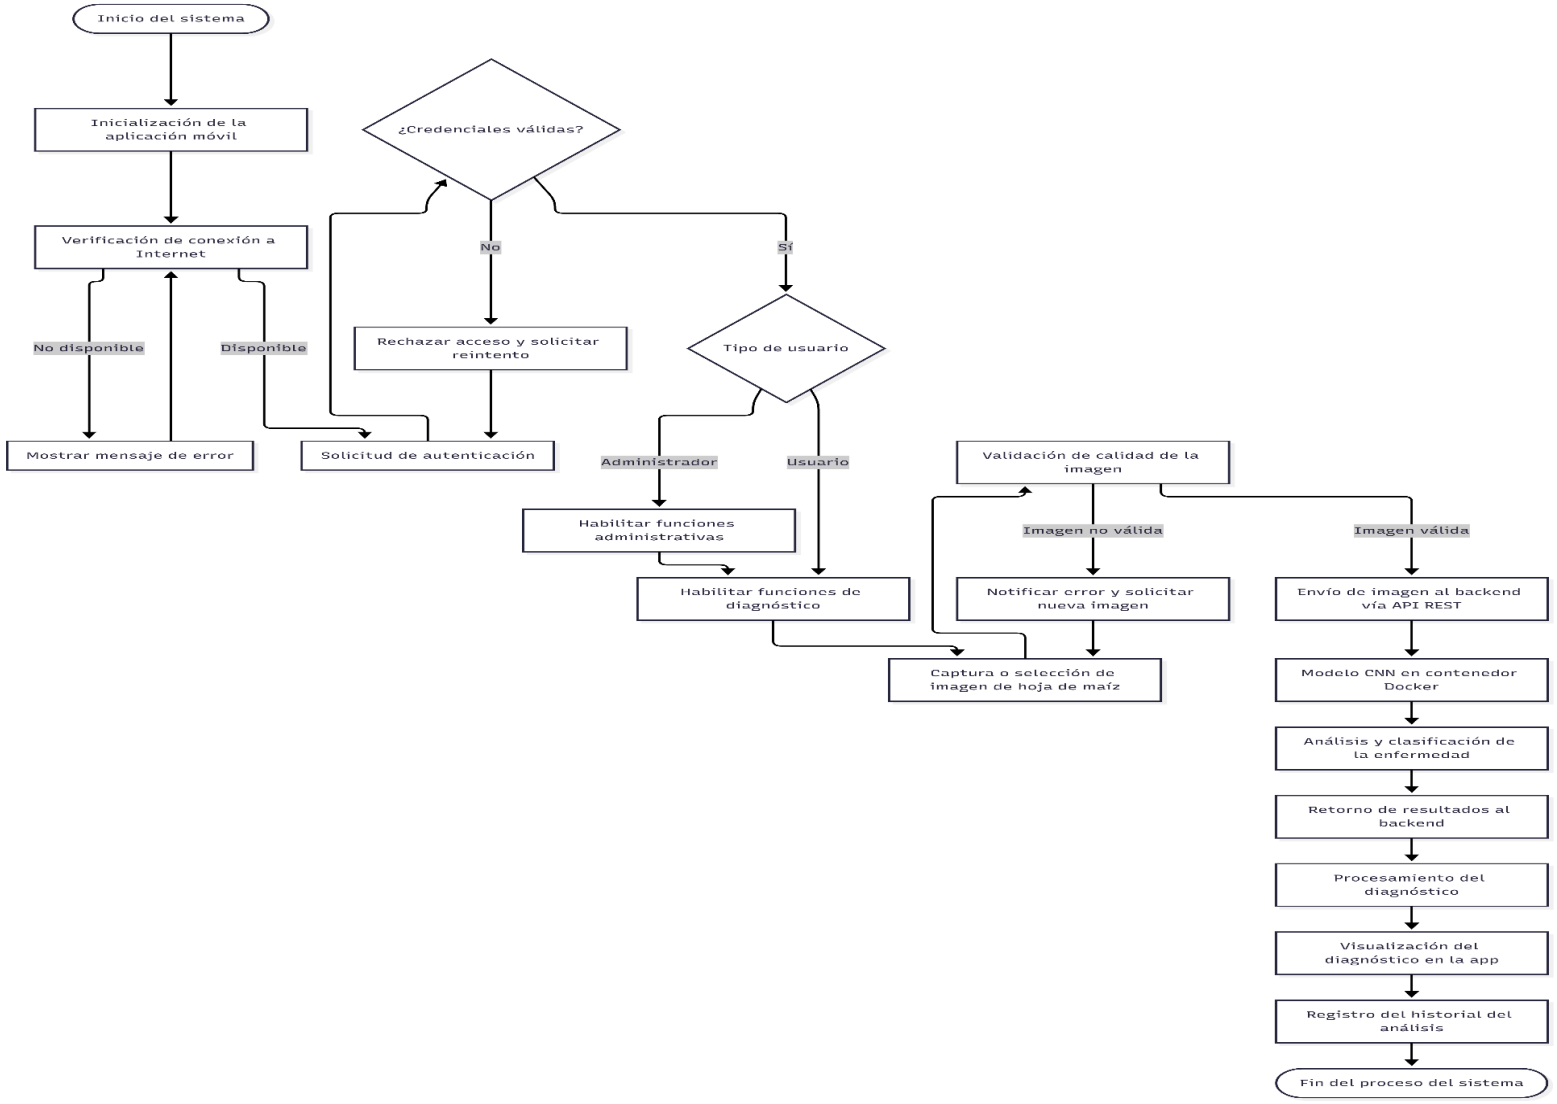


Figura 4.2 Flujo General del sistema

4.8 HERRAMIENTAS DE DESARROLLO

4.8.1 Herramientas del Frontend

El frontend del sistema corresponde a la aplicación móvil, la cual desarrollamos utilizando el framework Flutter junto con el lenguaje de programación Dart. Esta combinación permitió construir la app a partir de una única base de código, logrando un alto rendimiento, experiencia fluida y estable en dispositivos Android.

Se emplearon interfaces sencillas e intuitivas durante el desarrollo, lo que permitió capturar imágenes de las hojas de maíz y mandarlas al servidor para analizarlas. El empleo de Flutter posibilitó la integración eficaz de bibliotecas para el aprendizaje automático y también la administración de la comunicación con la API backend a través de peticiones HTTP.

Además, TensorFlow Lite se utilizó para mejorar el modelo de redes neuronales convolucionales que se deben ejecutarse en dispositivos móviles. Esto posibilitó la realización de inferencias locales en situaciones donde no existe conectividad hacia el internet.

4.8.2 Herramientas del Backend

Para crear el backend del sistema utilizamos Python, un lenguaje de programación, y FastAPI, un marco de trabajo (framework). Esta combinación posibilitó que la lógica de negocio se gestionara eficientemente, que las solicitudes de la aplicación móvil fueran validadas y que se coordinara la comunicación con los servicios de inteligencia artificial. Este método posibilitó la creación de una API REST efectiva, con buena capacidad de ampliación y un rendimiento elevado, que es adecuada para el procesamiento de imágenes y la provisión de diagnósticos.

Se logró la creación y validación de un modelo de red neuronal convolucional para identificar enfermedades en las hojas del maíz amarillo mediante imágenes gracias a Keras y TensorFlow, instrumentos que facilitaron el desarrollo y entrenamiento de los modelos de inteligencia artificial. El modelo fue entrenado en Google Colab, haciendo uso de recursos informáticos en la nube que lograron reducir considerablemente los tiempos de procesamiento.

El componente de inteligencia artificial fue aislado del resto del sistema al implementar

los modelos que entrenamos como servicios independientes a través de contenedores Docker. Esta clasificación hizo más sencillo su mantenimiento, actualización y escalabilidad, mientras garantizaba una operación estable en un entorno controlado.

Para asegurar la coherencia e integridad de los datos, se utilizó la imagen ISO de PostgreSQL para almacenar y gestionar la información generada por el sistema. Asimismo, se empleó Amazon Web Services (AWS) para implementar y operar los servicios en la nube. Esto permitió garantizar que el sistema estuviera accesible, que se pudiera acceder de manera remota y que tuviera la capacidad de escalar conforme a lo requerido.

Visual Studio Code fue el entorno de programación principal a lo largo de todo el proceso de desarrollo, lo cual ayudó a integrar las diferentes herramientas usadas y colaboró para mejorar el flujo laboral del proyecto.

4.8.3 Entorno de desarrollo y SaaS

Para crear el sistema seleccionamos Visual Studio Code como nuestro editor principal, debido a que es un instrumento liviano, muy adaptable y con una amplia gama de extensiones que nos facilitaron el trabajo con todas las tecnologías del proyecto. Fue posible programar, desde un solo lugar, no solo la aplicación móvil en Flutter y el backend en Python con FastAPI, sino también manejar contenedores de Docker y enlazarse con servicios de la nube.

VSCode se transformó en nuestro núcleo de operaciones: no solo programamos, sino que además ajustamos y depuramos los diferentes elementos del sistema. La integración de la API REST, los servicios de inteligencia artificial y la aplicación móvil se volvió más fácil debido a sus herramientas para gestionar versiones con Git y para manejar dependencias, lo que hizo que el desarrollo fuera eficaz y organizado.

Con respecto a la infraestructura de ejecución, se implementó el sistema en una instancia t3.small de Amazon Web Services (AWS), que cuenta con 2 GB de memoria RAM y 2 vCPU. Esta configuración fue apropiada para hospedar el backend creado en FastAPI, administrar los contenedores Docker y mantener activos los servicios requeridos durante las etapas de prueba y despliegue. El uso de esta infraestructura en la nube estuvo en línea con el enfoque SaaS del proyecto, lo que posibilitó acceder de manera remota,

mantener estable el rendimiento y escalar recursos de acuerdo con la demanda sin tener que depender únicamente de un entorno local.

Cabe mencionar que las tareas más pesadas, como el entrenamiento y ejecución de los modelos de inteligencia artificial, las realizamos de forma remota usando servicios en la nube. Esto nos permitió no sobrecargar el equipo local, aprovechar mejor los recursos y asegurar un buen rendimiento durante todo el proyecto.

5. ANÁLISIS DE RESULTADOS

En esta sección, presentamos y examinamos los resultados logrados en el proceso de desarrollo de nuestra aplicación móvil con inteligencia artificial, la cual fue creada para identificar enfermedades en las hojas del maíz amarillo. Para crear la solución, empleamos métodos para recolectar y preparar datos, además de pruebas funcionales que contribuyeron a comprobar cómo funcionaba el sistema correctamente y cómo era la experiencia del usuario mientras interactuaba.

Elaborando la aplicación con la metodología ágil Extreme Programming (XP), logramos que las funciones se implementaran de manera progresiva, que se realizaran pruebas constantes y que todo el procedimiento se ajustara con rapidez a las modificaciones. Asimismo, empleamos el método KDD (Knowledge Discovery in Databases) para la concepción, formación y valoración del modelo de inteligencia artificial. Esto nos permitió obtener resultados confiables en la identificación automatizada de enfermedades mediante imágenes.

5.1 RESULTADOS DE LA ENTREVISTA

De acuerdo con el método cualitativo de este estudio, se realizó una entrevista con cinco especialistas en el área agrícola y el presidente del barrio. Esta entrevista tuvo como propósito examinar el estado actual del cultivo de maíz amarillo, reconocer la existencia de enfermedades en las hojas, entender los procedimientos tradicionales para su detección, control, valorar el grado de aceptación y necesidad de una solución tecnológica que emplee una aplicación móvil con inteligencia artificial.

Los entrevistados están de acuerdo en que no tienen el apoyo tecnológico necesario para manejar adecuadamente el maíz y que les cuesta detectar con precisión las enfermedades que dañan la cosecha. Con base en esta concordancia, a continuación, se ofrece un

resumen de los aspectos más relevantes que mencionaron los participantes

- **Diagnóstico de la situación actual**

El presidente barrial indicó que tiene una vasta experiencia en el cultivo de maíz amarillo y que es común que aparezcan plagas y enfermedades en las hojas del cultivo durante los ciclos de producción. La existencia de insectos, la descomposición de las plantas y el cambio climático fueron algunos de los síntomas principales que se mencionaron. No obstante, indicó que no tiene los conocimientos técnicos necesarios para determinar la clase de enfermedad.

Desde el punto de vista de los expertos en la agricultura, los síntomas que se han descrito son signos típicos de enfermedades foliares frecuentes en el maíz amarillo. Los especialistas subrayaron que es esencial detectar con precisión y prontitud estas condiciones para emplear tratamientos apropiados, porque una evaluación errónea puede llevar a tomar decisiones técnicas ineficaces que impactan directamente en la eficiencia y productividad de los cultivos.

- **Percepción del manejo actual del cultivo**

Desde la perspectiva del presidente del barrio, el control de las enfermedades se realiza mediante acciones básicas, como el corte de plantas afectadas o la eliminación manual de plagas, sin recurrir a un diagnóstico técnico previo. Asimismo, indicó que estas prácticas no siempre garantizan resultados efectivos.

Desde una perspectiva técnica, los expertos afirman que el control de agroquímicos debe fundamentarse en un diagnóstico exacto que posibilite determinar con precisión el agente causante de la enfermedad antes de implementar cualquier intervención. Indican que, si se aplican tratamientos sin una valoración técnica apropiada, puede haber ineficiencia en el control, un aumento de la vulnerabilidad del cultivo y potenciales pérdidas en productividad. En este sentido, destacan la importancia de incluir instrumentos de diagnóstico que posibiliten tomar decisiones basadas en fundamentos y a tiempo.

- **Uso y disponibilidad de tecnología**

El presidente de la zona señaló que tiene un teléfono móvil y lo usa en su mayoría llamadas telefónicas y aplicaciones de mensajería como WhatsApp, aunque no tiene

apps específicas para labores agrícolas. Asimismo, indicó que no había obtenido ninguna clase de instrumento tecnológico para el manejo de enfermedades del maíz.

Los expertos indicaron que para manejar de manera moderna el cultivo, es necesario incluir herramientas tecnológicas enfocadas en la vigilancia y diagnóstico fitosanitario. Señalaron que la falta de aplicaciones especializadas restringe la posibilidad de hacer evaluaciones técnicas y a tiempo para controlar las enfermedades del maíz.

- **Necesidad y aceptación de una solución tecnológica**

El presidente del barrio y los expertos en agricultura coincidieron en que una aplicación móvil que, mediante una fotografía, pueda detectar enfermedades del maíz sería muy beneficiosa. El presidente opinó que esta herramienta posibilitaría decisiones más veloces y confiables, mientras que los expertos destacaron que una solución de este tipo ayudaría a disminuir la cantidad de errores en el diagnóstico y optimizar la gestión del cultivo.

- **Impacto esperado en la implementación**

Los entrevistados confían en que la implementación de la aplicación móvil basada en inteligencia artificial ayude a aumentar la producción de maíz amarillo, disminuir eventuales pérdidas financieras y potenciar el poder de los agricultores para afrontar dificultades fitosanitarias. Además, los expertos indicaron que esta herramienta tiene el potencial de ser un soporte adicional a la asesoría técnica convencional, en particular en áreas donde no se puede acceder fácilmente a especialistas.

- **Análisis e interpretación de la entrevista**

El análisis de las entrevistas permitió identificar una brecha clara entre la experiencia práctica del agricultor y el conocimiento técnico especializado. A pesar de que el productor identifica los inconvenientes en la cosecha, no tiene instrumentos para diagnosticarlos con exactitud. Sin embargo, los especialistas concuerdan en que para posibilitar el diagnóstico temprano de enfermedades es imprescindible incorporar soluciones tecnológicas. En estas condiciones, la aplicación móvil recomendada aparece como una alternativa apropiada y realizable para perfeccionar el proceso de toma de decisiones y aumentar la productividad en el cultivo del maíz amarillo.

Fuente: Autores

5.2 RESULTADO DE LA ENCUESTA

- **¿Con qué frecuencia se presentan enfermedades en las hojas del maíz amarillo en su cultivo?**

Tabla 5.1. ¿Con qué frecuencia se presentan enfermedades en las hojas del maíz amarillo en su cultivo? (Tabulación)

Opción	Frecuencia
Nunca	13
Rara vez	29
Algunas veces	34
Frecuentemente	18
Muy frecuentemente	2

Fuente: Autores

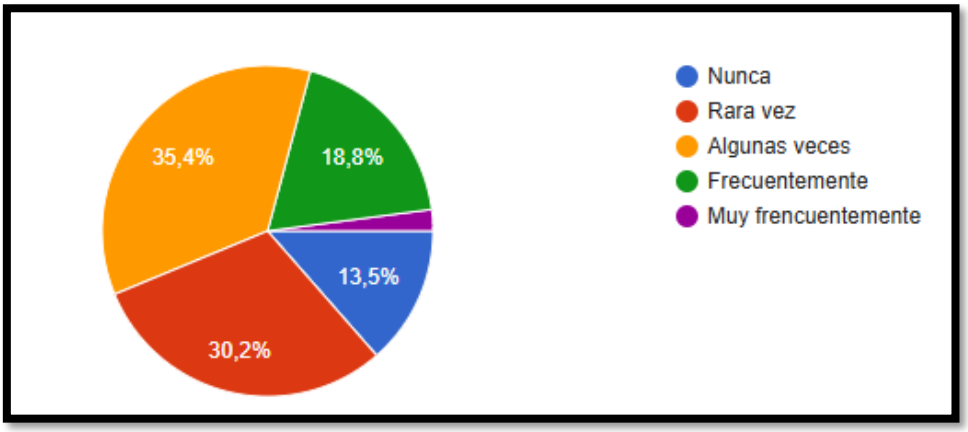


Figura 5.1 ¿Con qué frecuencia se presentan enfermedades en las hojas del maíz amarillo en su cultivo? (Pastel).

Análisis e interpretación

La respuesta relacionada con la frecuencia de aparición de enfermedades foliares muestra que estas se presentan de manera habitual en los cultivos, ya que el 35,4% de los agricultores indica que ocurren frecuentemente y el 18,8% muy frecuentemente, mientras que un 30,2% señala que aparecen algunas veces y un 13,5% manifiesta no haberlas presentado; por esta razón, se evidencia que la presencia constante de estas enfermedades constituye un problema recurrente en la producción agrícola.

- **¿Las enfermedades foliares afectan significativamente el rendimiento de su producción?**

Tabla 5.2. ¿Las enfermedades foliares afectan significativamente el rendimiento de su producción? (Tabulación)

Opción	Frecuencia
Nada	5
Poco	22
Moderadamente	42
Mucho	21
Demasiado	6

Fuente: Autores

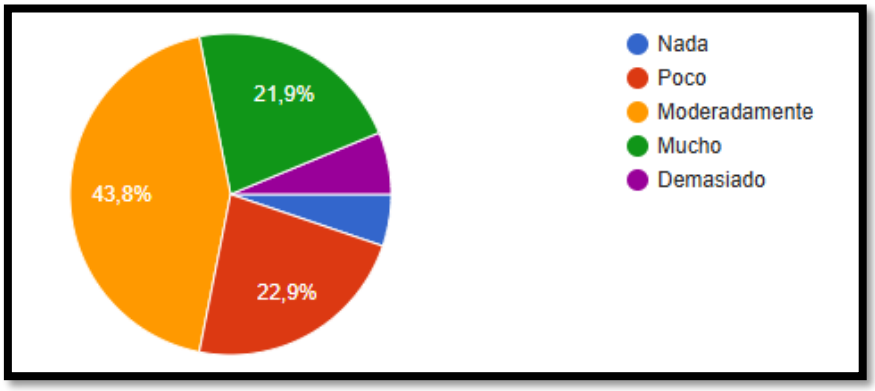


Figura 5.2 ¿Las enfermedades foliares afectan significativamente el rendimiento de su producción? (Pastel).

Análisis e interpretación

La respuesta relacionada con el impacto de las enfermedades foliares en el rendimiento productivo evidencia una afectación relevante, ya que el 43,8% de los productores considera que el impacto es moderado, el 21,9% señala que es mucho y un 6,3% lo califica como demasiado, mientras que una menor proporción percibe un efecto poco (22,9%) o nulo (5,2%); por esta razón, se confirma que las enfermedades foliares influyen de manera significativa en la producción de maíz.

- **¿Tiene dificultades para identificar correctamente las enfermedades de las hojas**

del maíz?

Tabla 5.3 ¿Tiene dificultades para identificar correctamente las enfermedades de las hojas del maíz? (Tabulación)

Opción	Frecuencia
Nunca	5
Rara vez	14
A veces	36
Casi siempre	24
Siempre	17

Fuente: Autores

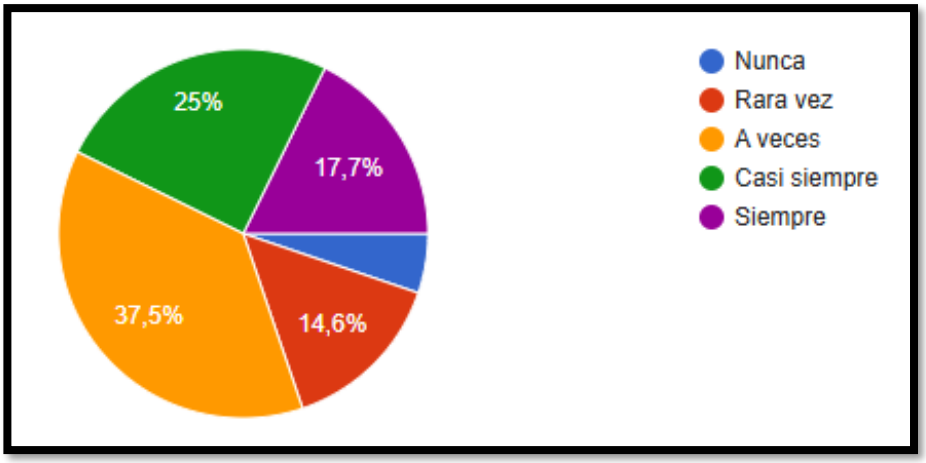


Figura 5.3 ¿Tiene dificultades para identificar correctamente las enfermedades de las hojas del maíz? (Pastel).

Análisis e interpretación

La respuesta relacionada con la identificación de enfermedades foliares evidencia que este proceso no se realiza de forma segura ni constante, ya que el 25% de los productores señala que casi siempre logra identificarlas y un 37,5% indica que solo a veces lo consigue, lo que demuestra la existencia de dificultades recurrentes en el diagnóstico; por esta razón, se hace necesaria la implementación de herramientas que faciliten una detección más precisa y oportuna.

- **Actualmente, ¿cómo identifica las enfermedades del cultivo?**

Tabla 5.4. Actualmente, ¿cómo identifica las enfermedades del cultivo? (Tabulación).

Opción	Frecuencia
Experiencia propia	23
Recomendación de otros agricultores	36
Técnico agrícola	6
Tienda agropecuaria	12
No sabe identificarlas	19

Fuente: Autores

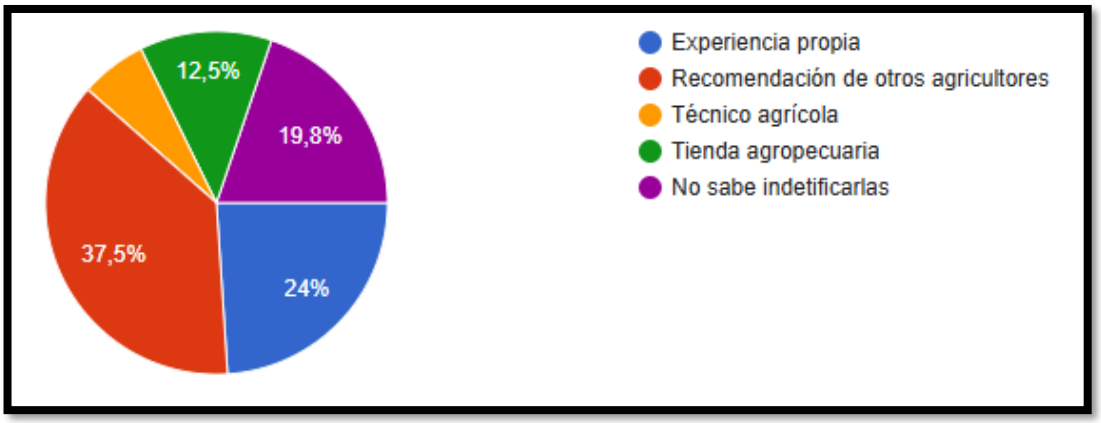


Figura 5.4 Actualmente, ¿cómo identifica las enfermedades del cultivo? (Pastel).

Análisis e interpretación

La respuesta relacionada con los métodos utilizados para diagnosticar enfermedades en el cultivo de maíz evidencia una fuerte dependencia del conocimiento empírico, ya que el 37,5% se basa en la recomendación de otros agricultores y el 24% en la experiencia personal, mientras que una menor proporción recurre a técnicos agrícolas (6%) o a tiendas agropecuarias (12,5%), e incluso un 19,8% manifiesta no saber identificar las enfermedades; por esta razón, se evidencia una limitada asistencia técnica formal en el manejo sanitario del cultivo.

- **¿Dispone de un teléfono inteligente (smartphone) con cámara?**

Tabla 5.5. ¿Dispone de un teléfono inteligente (smartphone) con cámara? (Tabulación).

Opción	Frecuencia
Si	86
No	10

Fuente: Autores

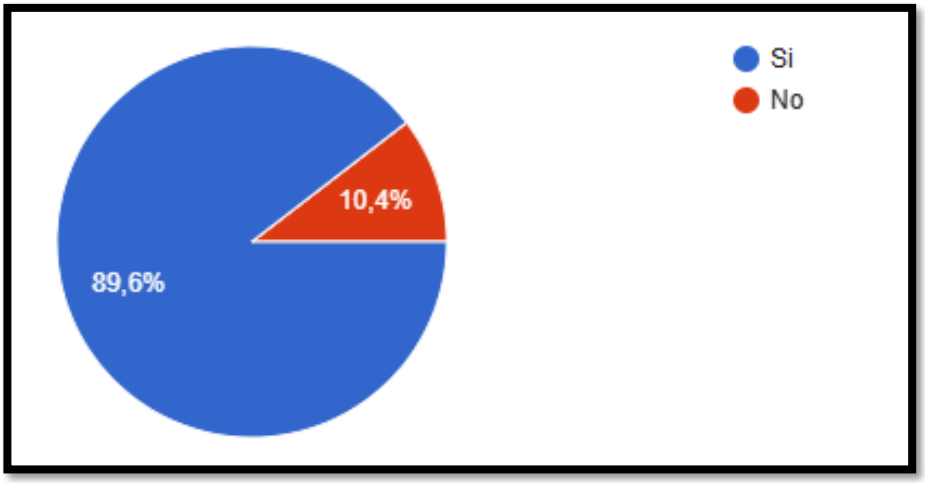


Figura 5.5 ¿Dispone de un teléfono inteligente (smartphone) con cámara? (Pastel).

Análisis e interpretación

La respuesta relacionada con la disponibilidad de teléfonos inteligentes con cámara evidencia que la mayoría de los productores cuenta con este recurso tecnológico (89,6%), mientras que solo un 10,4% no dispone de él; por esta razón, se confirma la existencia de una base tecnológica adecuada para implementar soluciones digitales orientadas al diagnóstico de enfermedades foliares.

- **¿Con qué frecuencia utiliza aplicaciones móviles?**

Tabla 5.6. ¿Con qué frecuencia utiliza aplicaciones móviles? (Tabulación)

Opción	Frecuencia
Nunca	3
Rara vez	14
Algunas veces	28
Frecuentemente	27
Muy frecuentemente	24

Fuente: Autores

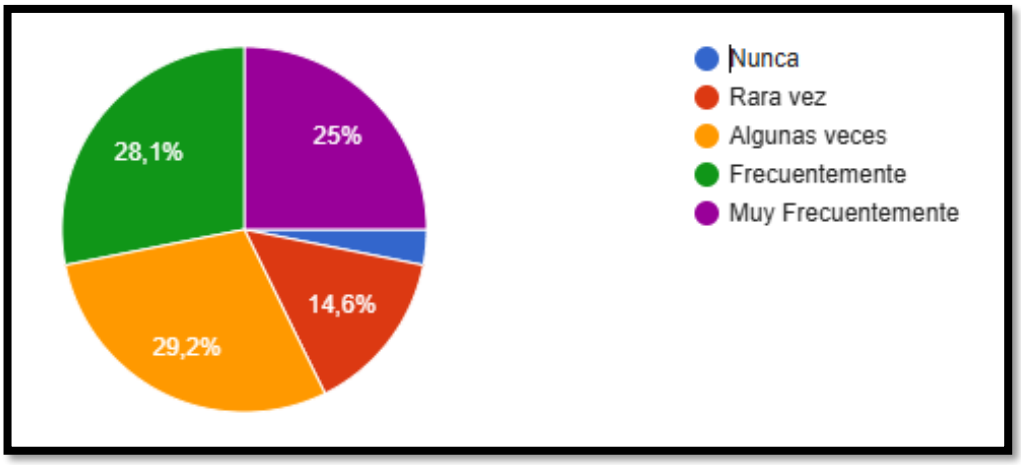


Figura 5.6 ¿Con qué frecuencia utiliza aplicaciones móviles? (Pastel).

Análisis e interpretación

La respuesta relacionada con el uso de aplicaciones móviles muestra que existe una familiaridad considerable con este tipo de herramientas, ya que el 29,2% las utiliza algunas veces, el 28,1% frecuentemente y el 25% con mucha frecuencia, mientras que solo un 14,6% las usa rara vez o nunca; por esta razón, se evidencia un escenario favorable para la adopción de aplicaciones móviles en el ámbito agrícola.

- **¿Considera útil una aplicación móvil que identifique enfermedades del maíz mediante fotografías y uso de inteligencia artificial?**

Tabla 5.7. ¿Considera útil una aplicación móvil que identifique enfermedades del maíz mediante fotografías y uso de inteligencia artificial? (Tabulación)

Opción	Frecuencia
Nada útil	3
Poco útil	5
Útil	36
Muy útil	33
Totalmente útil	19

Fuente: Autores

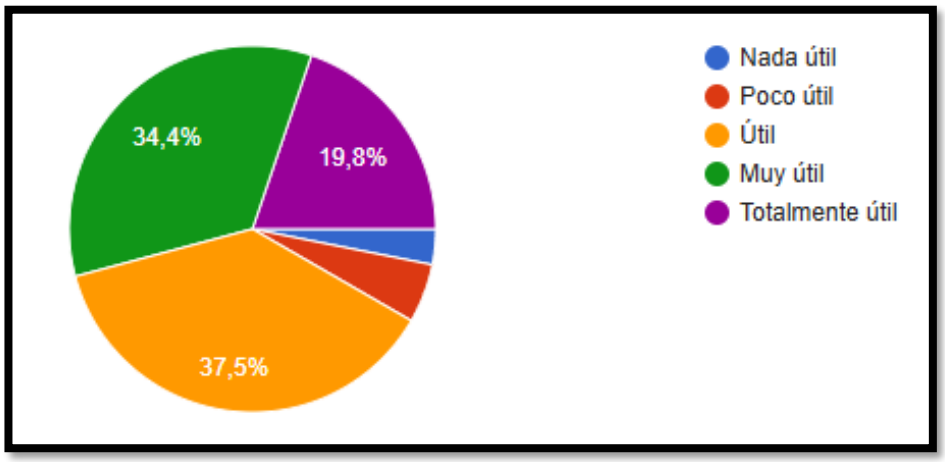


Figura 5.7 ¿Considera útil una aplicación móvil que identifique enfermedades del maíz mediante fotografías y uso de inteligencia artificial? (Pastel).

Análisis e interpretación

La respuesta relacionada con la utilidad de una aplicación móvil basada en inteligencia artificial evidencia una aceptación ampliamente positiva, ya que el 19,8% la considera totalmente útil, el 37,5% útil y el 34,4% muy útil, mientras que solo una proporción mínima la califica como poco o nada útil; por esta razón, se confirma la viabilidad y pertinencia de implementar este tipo de solución tecnológica.

- **¿Cree que una aplicación móvil ayudaría a reducir pérdidas económicas en su producción?**

Tabla 5.8. ¿Cree que una aplicación móvil ayudaría a reducir pérdidas económicas en su producción? (Tabulación)

Opción	Frecuencia
No ayudaría	4
Ayudaría poco	13
Ayudaría moderadamente	35
Ayudaría mucho	34
Ayudaría totalmente	10

Fuente: Autores

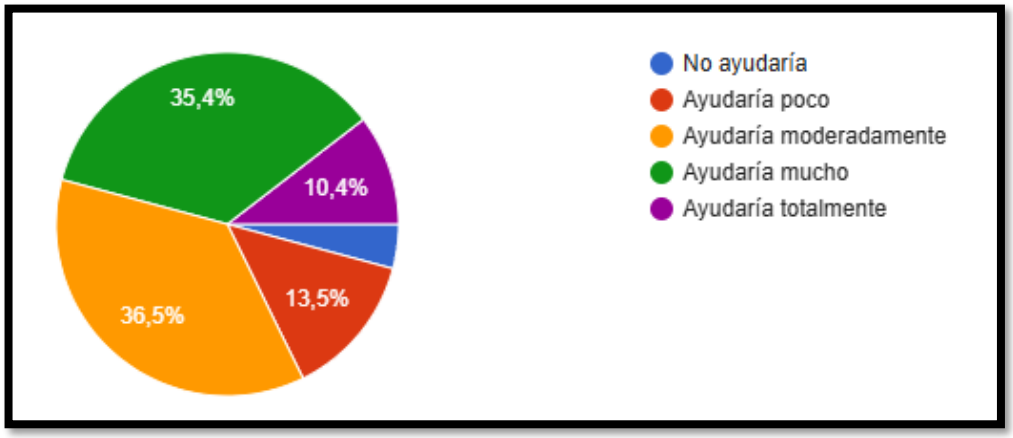


Figura 5.8 ¿Cree que una aplicación móvil ayudaría a reducir pérdidas económicas en su producción? (Pastel).

Análisis e interpretación

La respuesta relacionada con la reducción de pérdidas económicas mediante el uso de una aplicación móvil evidencia una percepción favorable, ya que el 36,5% considera que ayudaría de forma moderada, el 35,4% mucho y el 10,4% totalmente, mientras que solo una minoría percibe un impacto bajo o nulo; por esta razón, se ratifica que la aplicación es vista como una alternativa concreta para mejorar la rentabilidad del cultivo.

- **¿Estaría dispuesto/a a utilizar una aplicación móvil para el monitoreo y control de enfermedades del maíz?**

Tabla 5.9. ¿Estaría dispuesto/a a utilizar una aplicación móvil para el monitoreo y control de enfermedades del maíz? (Tabulación)

Opción	Frecuencia
No	3
Tal vez	42
Si	51

Fuente: Autores

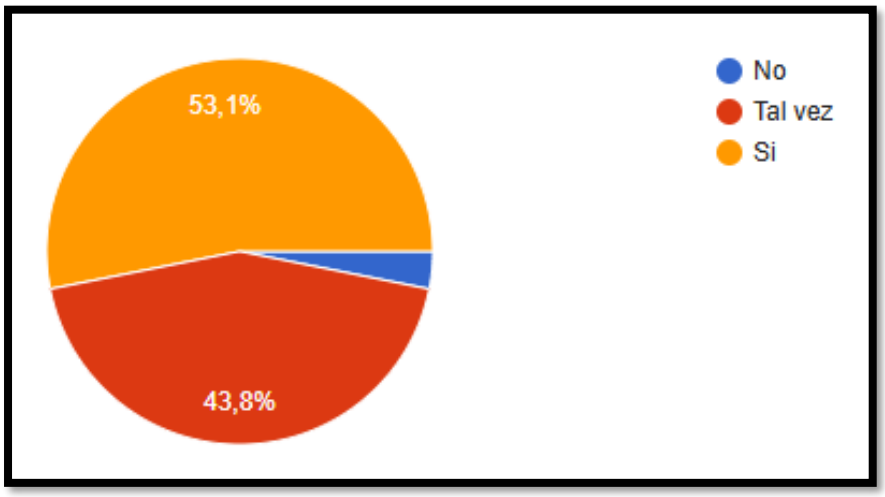


Figura 5.9 ¿Estaría dispuesto/a a utilizar una aplicación móvil para el monitoreo y control de enfermedades del maíz? (Pastel).

Análisis e interpretación

La respuesta relacionada con la disposición de los productores para utilizar una aplicación móvil evidencia una actitud mayoritariamente positiva, ya que el 53,1% manifiesta que sí la usaría y un 43,8% señala que tal vez lo haría, mientras que solo una mínima proporción indica que no; por esta razón, se observa una alta probabilidad de adopción de la herramienta tecnológica.

- **¿Considera importante que la aplicación sea fácil de usar y funcione sin conexión a internet?**

Tabla 5.10. ¿Considera importante que la aplicación sea fácil de usar y funcione sin conexión a internet? (Tabulación)

Opción	Frecuencia
Poco importante	3
Medianamente importante	7
Importante	25
Muy importante	23
Totalmente importante	38

Fuente: Autores

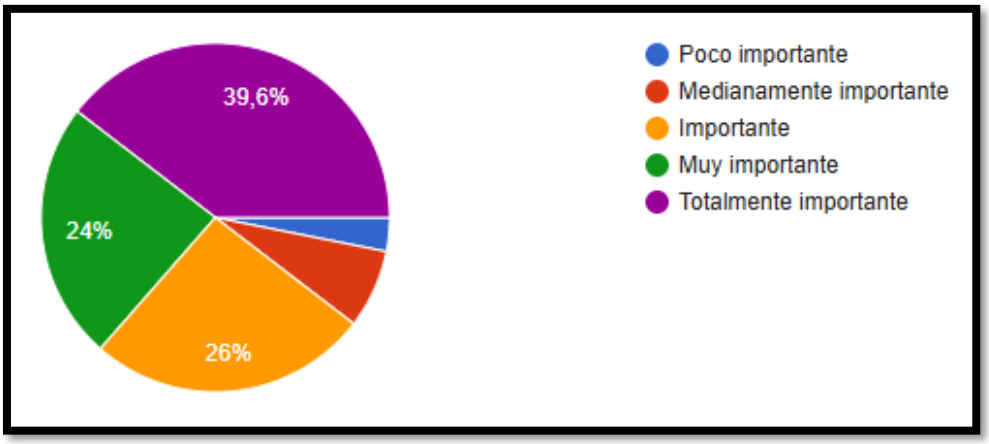


Figura 5.10 ¿Estaría dispuesto/a a utilizar una aplicación móvil para el monitoreo y control de enfermedades del maíz? (Pastel).

Análisis e interpretación

La respuesta relacionada con la facilidad de uso y el funcionamiento sin conexión a internet evidencia que estos aspectos son altamente valorados, ya que cerca del 39,6% los considera totalmente importantes, un 24% muy importantes y un 26% importantes, mientras que solo una minoría les resta relevancia; por esta razón, se concluye que una aplicación sencilla y operativa sin conexión tiene altas probabilidades de ser aceptada y utilizada en el contexto agrícola.

5.3 RESULTADOS DE LA METODOLOGÍA XP

5.3.1 Roles.

Tabla 5.11 Roles de la metodología XP.

Rol	Responsable	Funciones
Programador	Diego Cisneros	Es el responsable del desarrollo e implementación de la aplicación móvil con inteligencia artificial para la detección de enfermedades en la hoja del maíz amarillo.
Cliente	Agricultores del Barrio Santo Samana	Es el responsable de proporcionar los requerimientos del sistema y validar las funcionalidades desarrolladas, asegurando que la aplicación responda a las necesidades reales del contexto agrícola.
Tester	César Zela	Es el responsable de realizar pruebas funcionales del sistema, verificando el correcto funcionamiento de la aplicación y la precisión de los resultados obtenidos.
Tracker	MSc. Manuel Villa	Es el encargado de dar seguimiento al avance del proyecto y al cumplimiento del backlog y las iteraciones planificadas.
Coach	Msc.Manuel Villa	Es el responsable de orientar y supervisar la correcta aplicación de la metodología XP durante el desarrollo del proyecto.

5.3.2 Planificación

Historias de usuario

A partir de la información levantada con los usuarios finales, se identificaron y definieron las historias de usuario que orientaron el desarrollo de la aplicación móvil. Estas historias permitieron establecer de manera clara las necesidades funcionales del sistema, sirviendo como base para la planificación, priorización y ejecución de las iteraciones durante la aplicación de la metodología XP. A continuación, se presentan las historias de usuario definidas para el proyecto.

Tabla 5.12 Iniciar sesión

Acción	Descripción de la acción
Iniciar sesión	
ID	HU-01
Como	Agricultor
Quiero	Iniciar sesión mediante correo electrónico y contraseña
Para	Acceder de forma segura a mis parcelas y diagnósticos registrados.
Criterios de aceptación	• El usuario ingresa credenciales válidas y accede al sistema sin errores. • La aplicación redirige a la pantalla principal de parcelas
Prioridad	Alta

Fuente: Autores

Tabla 5.13 Recuperar contraseña

Acción	Descripción de la acción
Recuperar contraseña	
ID:	HU-02
Como	Agricultor
Quiero	Recuperar mi contraseña mediante correo electrónico
Para	Volver a acceder a la aplicación en caso de olvidar mis credenciales.
Criterios de aceptación	• El sistema envía un enlace de recuperación al correo registrado. • El usuario puede restablecer la contraseña correctamente. • La nueva contraseña cumple con las políticas de seguridad.
Prioridad	Media

Fuente: Autores

Tabla 5.14 Registrar parcelas

Acción	Descripción de la acción
Registrar parcelas	
ID	HU-03
Como	Agricultor
Quiero	Registrar mis parcelas agrícolas con información específica
Para	Organizar y gestionar de mejor manera los diagnósticos realizados.

Criterios de aceptación	• La parcela se guarda con nombre, ubicación (latitud y longitud) y usuario asociado. • La parcela aparece inmediatamente en el listado del usuario. • No se permite duplicar parcelas para el mismo usuario.
Prioridad	Alta

Fuente: Autores

Tabla 5.15 Seleccionar parcela

Acción	Descripción de la acción
Seleccionar parcela	
ID	HU-04
Como	Agricultor
Quiero	Seleccionar una parcela registrada
Para	Realizar un diagnóstico específico de esa área de cultivo.
Criterios de aceptación	• La parcela seleccionada queda marcada como activa. • Los diagnósticos se asocian automáticamente a la parcela seleccionada. • La selección se mantiene durante la sesión del usuario.
Prioridad	Alta

Fuente: Autores

Tabla 5.16. Capturar fotografía para diagnóstico

Acción	Descripción de la acción
Capturar fotografía para diagnóstico	
ID	HU-05
Como	Agricultor
Quiero	Capturar una fotografía clara y enfocada de la hoja de maíz
Para	Permitir que el sistema de inteligencia artificial realice un diagnóstico confiable.
Criterios de aceptación	• La cámara se abre con opciones de enfoque automático. • La imagen capturada se muestra en vista previa. • El usuario puede aceptar o descartar la imagen. • Se muestra un indicador de carga durante el diagnóstico.
Prioridad	Alta

Fuente: Autores

Tabla 5.17. Cargar imagen desde la galería

Acción	Descripción de la acción
Cargar imagen desde la galería	
ID	HU-06

Como	Agricultor
Quiero	Seleccionar una imagen desde la galería del dispositivo
Para	Analizar fotografías previamente capturadas.
Criterios de aceptación	• La aplicación permite acceder a la galería del dispositivo. • La imagen seleccionada se carga correctamente. • La imagen queda lista para su análisis por el sistema.
Prioridad	Media

Fuente: Autores

Tabla 5.18. Visualizar diagnóstico de enfermedad

Acción	Descripción de la acción
Visualizar diagnóstico de enfermedad	
ID	HU-07
Como	Agricultor
Quiero	Visualizar el diagnóstico generado por la CNN
Para	Conocer si la hoja está sana o presenta alguna enfermedad, junto con el nivel de confianza del modelo.
Criterios de aceptación	• Se muestra el nombre de la enfermedad detectada o el estado “Sano”. • Se presenta el porcentaje de confianza de la predicción. • El diagnóstico se genera en un tiempo razonable. • El resultado se guarda en la base de datos.
Prioridad	Alta

Fuente: Autores

Tabla 5.19. Ver detalles y recomendaciones

Acción	Descripción de la acción
Ver detalles y recomendaciones	
ID	HU-08
Como	Agricultor
Quiero	Consultar información detallada y recomendaciones del diagnóstico
Para	Tomar decisiones informadas sobre el tratamiento del cultivo.
Criterios de aceptación	• Se muestra la imagen analizada, la fecha y el diagnóstico. • Se presentan recomendaciones claras y comprensibles. • La información es útil para el agricultor.
Prioridad	Media

Fuente: Autores

Tabla 5.20. Cerrar sesión

Acción	Descripción de la acción
Cerrar sesión	
ID	HU-09
Como	Agricultor
Quiero	Cerrar sesión de forma segura
Para	Proteger mi información cuando utilizo un dispositivo compartido.
Criterios de aceptación	• La opción de cerrar sesión es accesible desde el menú principal. • El sistema elimina la sesión activa. • Se redirige a la pantalla de inicio de sesión.
Prioridad	Baja

Fuente: Autores

Tabla 5.21. Visualizar parcelas de usuarios

Acción	Descripción de la acción
Visualizar parcelas de usuarios	
ID	HU-A01
Como	Administrador
Quiero	Visualizar las parcelas registradas por todos los usuarios
Para	Tener una visión general de la cobertura del sistema.
Criterios de aceptación	• Se muestra un listado completo de parcelas. • Cada registro incluye nombre, usuario y ubicación. • Los datos se cargan en tiempo real desde la base de datos.
Prioridad	Media

Fuente: Autores

Tabla 5.22. Visualizar diagnósticos realizados

Acción	Descripción de la acción
Visualizar diagnósticos realizados	
ID	HU-A02
Como	Administrador
Quiero	Consultar todos los diagnósticos realizados
Para	Monitorear el uso y desempeño del sistema.

Criterios de aceptación	• Se muestran imágenes, resultados y fechas de los diagnósticos. • Los datos se sincronizan correctamente mediante contenedores Docker.
Prioridad	Alta

Fuente: Autores

Tabla 5.23. Visualizar dashboard de KPIs

Acción	**Descripción de la acción**
Visualizar dashboard de KPIs	
ID	HU-A03
Como	Administrador
Quiero	Visualizar indicadores clave del sistema
Para	Apoyar el análisis y la toma de decisiones.
Criterios de aceptación	• El sistema muestra gráficos interactivos con datos reales. • Los indicadores se actualizan automáticamente.
Prioridad	Media

Fuente: Autores

Backlog priorizado

Se creó un backlog priorizado basado en las historias de usuario definidas, lo que facilitó la organización y planificación del desarrollo del sistema, teniendo en cuenta la importancia funcional que tiene cada requerimiento en la aplicación móvil.

Tabla 5.24. Listado de prioridad de historias de usuario

UH	Descripción	Rol	Prioridad
HU-01	Iniciar sesión mediante correo electrónico y contraseña para acceder a la aplicación de forma segura	Agricultor	Alta
HU-03	Registrar parcelas agrícolas con información específica para la gestión de diagnósticos	Agricultor	Alta

UH	Descripción	Rol	Prioridad
HU-04	Seleccionar una parcela registrada para realizar diagnósticos específicos	Agricultor	Alta
HU-05	Capturar una fotografía de la hoja de maíz para el diagnóstico mediante inteligencia artificial	Agricultor	Alta
HU-07	Visualizar el diagnóstico de enfermedades generado por la red neuronal convolucional	Agricultor	Alta
HU-A02	Visualizar los diagnósticos realizados para el monitoreo del uso del sistema	Administrador	Alta
HU-02	Recuperar la contraseña mediante correo electrónico	Agricultor	Media
HU-06	Cargar una imagen desde la galería del dispositivo para su análisis	Agricultor	Media
HU-08	Consultar detalles y recomendaciones del diagnóstico	Agricultor	Media
HU-A01	Visualizar las parcelas registradas por los usuarios del sistema	Administrador	Media
HU-A03	Visualizar un dashboard con indicadores clave (KPIs) del sistema	Administrador	Media
HU-09	Cerrar sesión de forma segura desde la aplicación	Agricultor	Baja

5.3.3 Release Planning

A partir del backlog priorizado, se estableció el release planning, organizando las historias de usuario en iteraciones de desarrollo. Cada iteración agrupa funcionalidades relacionadas, permitiendo una construcción incremental del sistema conforme a los principios de la metodología XP.

Tabla 5.25. Iteración Nº1

Iteración 1 – Acceso y gestión del sistema		
ID	Historia de usuario	Prioridad
HU-01	Iniciar Sesión	Alta
HU-03	Registrar parcelas	Alta
HU-04	Seleccionar parcelas	Alta

Objetivo de la iteración: Permitir el acceso seguro a la aplicación y la gestión inicial de parcelas agrícolas.

Tabla 5.26. Iteración Nº2

Iteración 2 – Captura y diagnóstico con inteligencia artificial		
ID	Historia de usuario	Prioridad
HU-05	Capturar fotografía para diagnóstico	Alta
HU-07	Visualizar diagnóstico de enfermedad	Alta

Objetivo de la iteración: Implementar el proceso de captura de imágenes y el diagnóstico de enfermedades mediante redes neuronales convolucionales.

Tabla 5.27. Iteración Nº3

Iteración 3 – Funcionalidades complementarias para el agricultor		
ID	Historia de usuario	Prioridad
HU-02	Recuperar contraseña	Media
HU-06	Cargar imagen desde la galería	Media
HU-08	Ver detalles y recomendaciones	Media

Objetivo de la iteración: Mejorar la experiencia del usuario mediante funciones adicionales de apoyo al diagnóstico.

Tabla 5.28. Iteración Nº4

Iteración 4 – Gestión administrativa y cierre de sesión		
ID	Historia de usuario	Prioridad
HU-A01	Visualizar parcelas de usuarios	Media
HU-A02	Visualizar diagnósticos realizados	Alta
HU-A03	Visualizar dashboard de KPIs	Media
HU-09	Cerrar sesión	Baja

Objetivo de la iteración: Permitir el monitoreo del sistema por parte del administrador y asegurar el cierre adecuado de sesiones.

5.3.4 Diseño

Diseño Interfaces

La Figura 5.11 muestra el inicio de sesión, donde el agricultor ingresa su correo electrónico y contraseña para acceder de forma segura al sistema. Esta pantalla permite validar las credenciales del usuario y garantizar el acceso a las funcionalidades principales de la aplicación.



Figura 5.11 Inicio de Sesión

La Figura 5.12 presenta el registro de usuarios, mediante la cual el agricultor puede crear una cuenta ingresando sus datos personales y credenciales de acceso. Esta funcionalidad permite la incorporación de nuevos usuarios al sistema, facilitando el uso de la aplicación en el entorno agrícola.



Figura 5.12. Registro de usuarios

En la Figura 5.13 se muestra la gestión de parcelas, donde el agricultor puede visualizar las tierras registradas, seleccionar una parcela específica y acceder a las opciones de diagnóstico e historial.

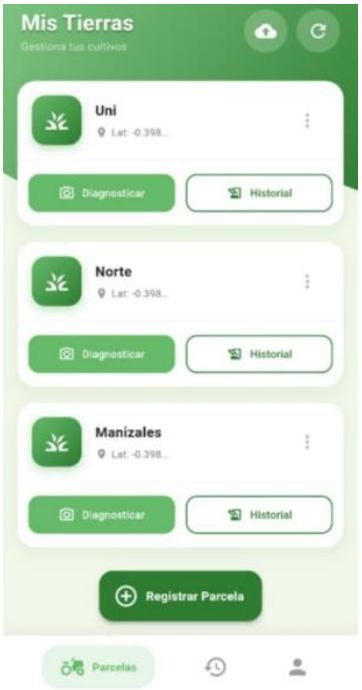


Figura 5.13. Gestión de parcelas

La Figura 5.14 corresponde al historial de diagnósticos, en la cual el agricultor puede consultar los resultados obtenidos en evaluaciones anteriores. Aquí podemos visualizar la enfermedad detectada, el nivel de precisión del modelo de inteligencia artificial y una recomendación general para el manejo del cultivo.



Figura 5.14. Historial de diagnóstico

La Figura 5.15 muestra la gestión de usuarios correspondiente al rol administrador. Desde esta pantalla es posible visualizar los usuarios registrados en el sistema y controlar su estado de acceso, permitiendo una adecuada administración de los permisos y la información almacenada.

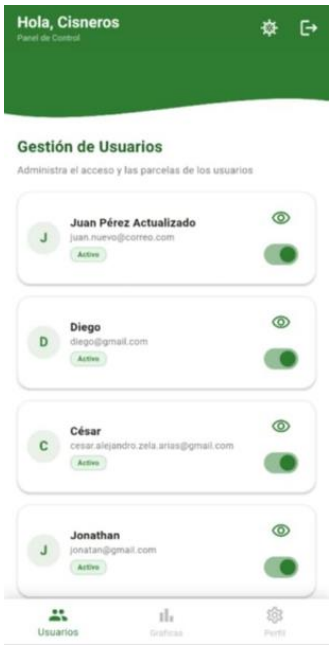


Figura 5.15. Gestión de usuarios (Administrador)

Diagrama caso de uso general

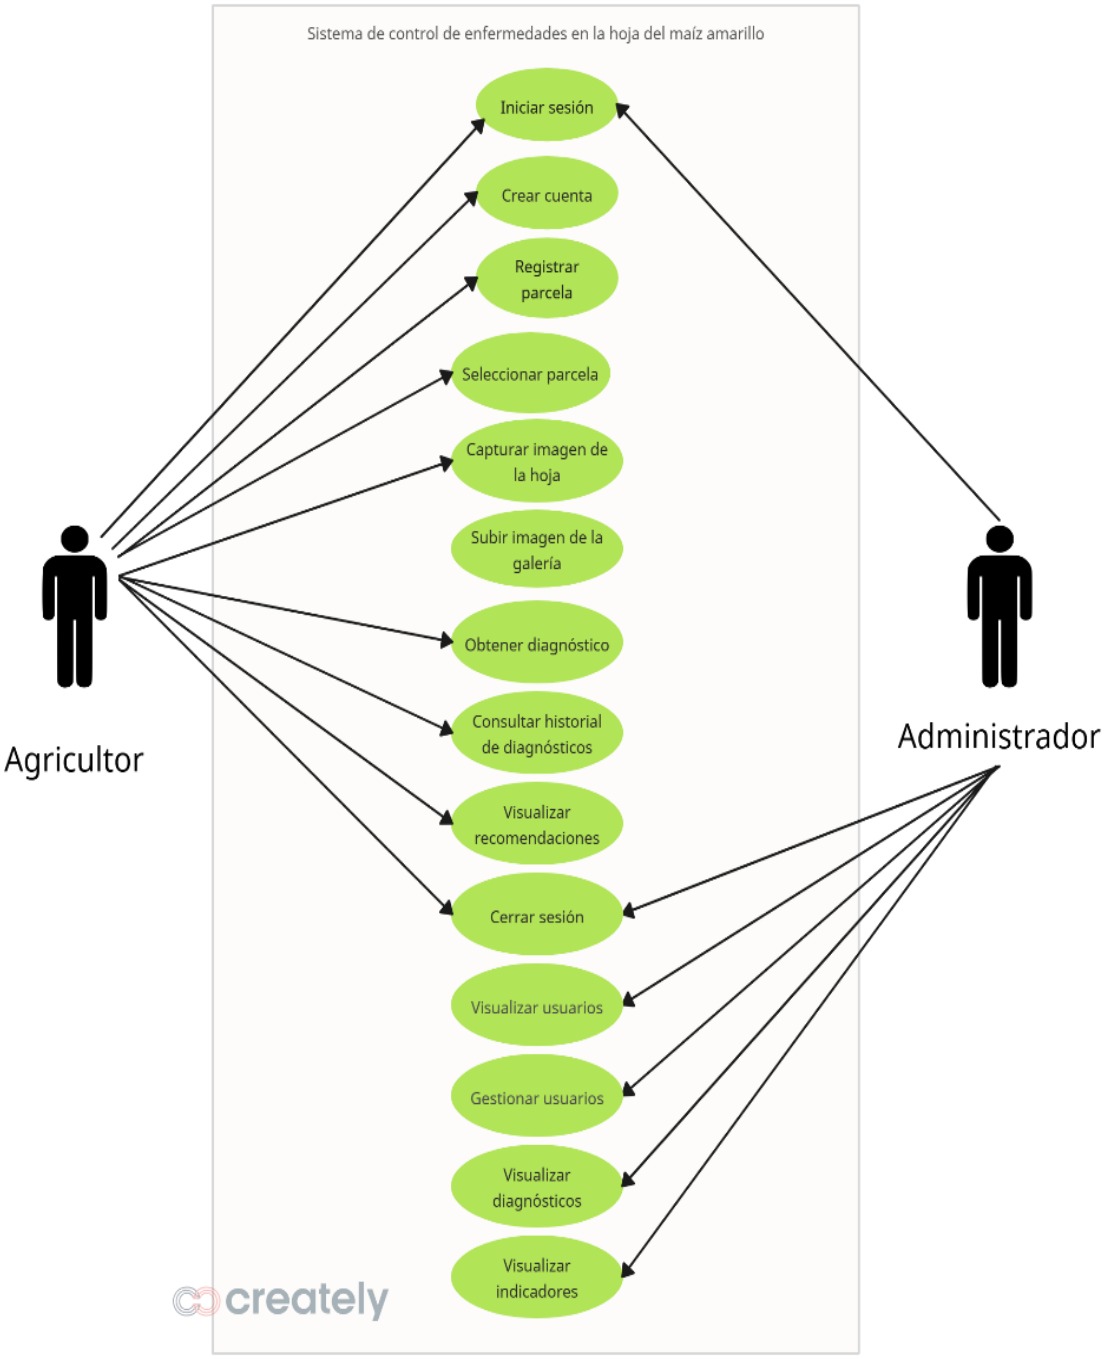


Figura 5.16. Diagrama caso de uso general

Diagrama de base de datos

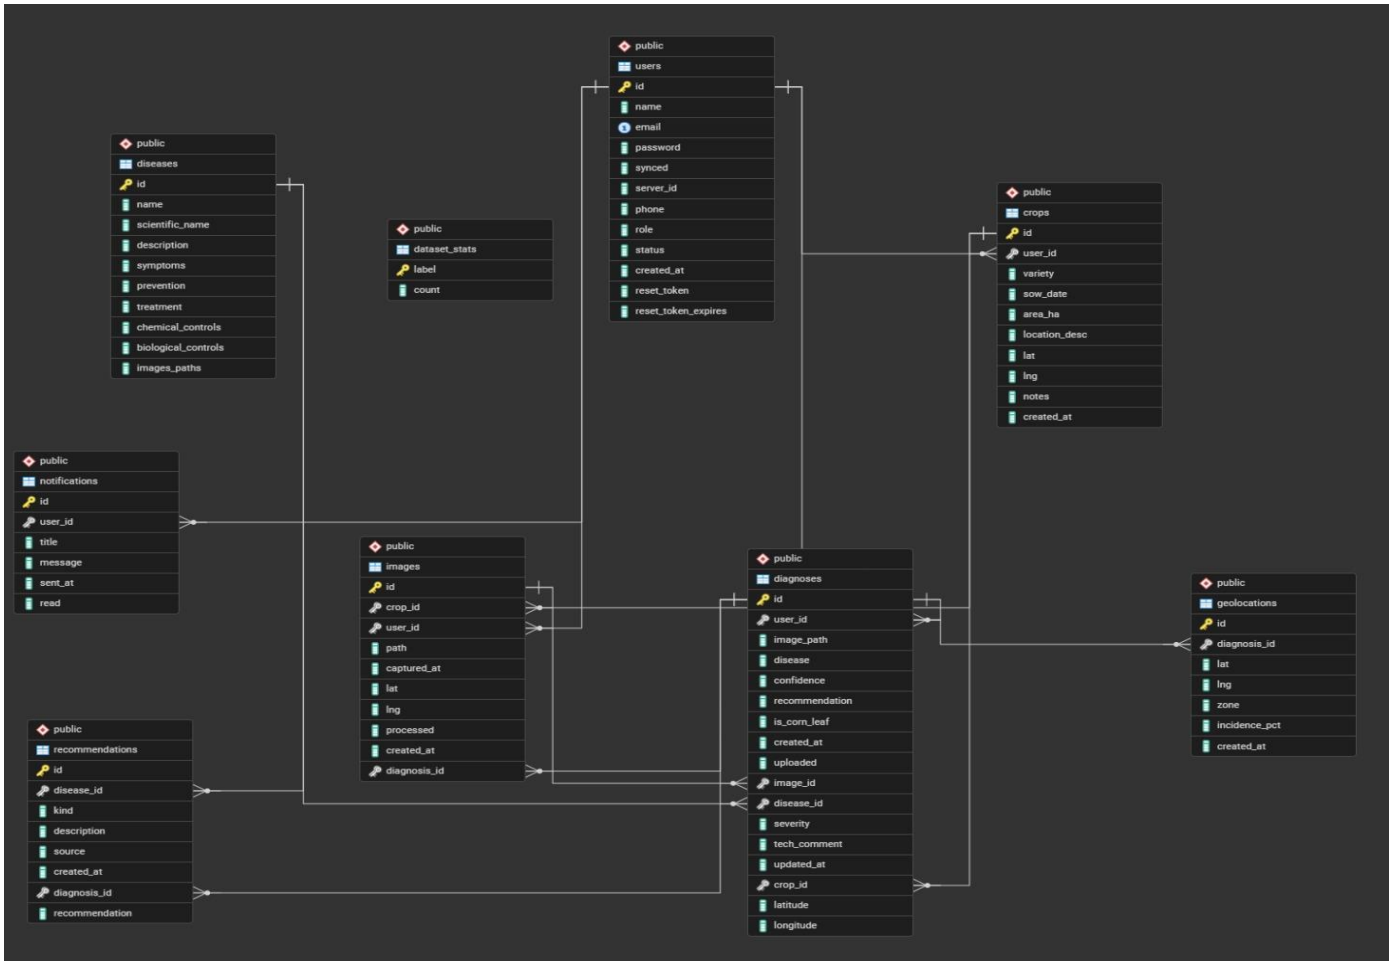


Figura 5.17. Diagrama de la base de datos

5.3.5 Codificación

En esta sección se describe el proceso de codificación del sistema desarrollado para la detección de enfermedades en la hoja del maíz amarillo.

En la Figura 25 se presenta un fragmento de la codificación del módulo de autenticación, encargado de validar las credenciales del usuario y permitir el acceso seguro al sistema.

login_screen.dart 5 ×

maiz_app > lib > screens > login_screen.dart > ...

```dart
import 'package:flutter/material.dart';
import 'package:connectivity_plus/connectivity_plus.dart';

// Importaciones de tus pantallas y servicios
import 'package:maiz_app/screens/register_screen.dart';
import 'package:maiz_app/screens/home_admin.dart';
import 'package:maiz_app/screens/home_agricultor.dart';
import 'package:maiz_app/services/api_service.dart';
import 'package:maiz_app/services/db_service.dart';
import 'package:maiz_app/services/session_service.dart';
import 'package:maiz_app/screens/forgot_password_screen.dart';

class LoginScreen extends StatefulWidget {
  const LoginScreen({super.key});

  @override
  State<LoginScreen> createState() => _LoginScreenState();
}

class _LoginScreenState extends State<LoginScreen> {
  // Controladores de texto
  final emailController = TextEditingController();
  final passwordController = TextEditingController();

  // Variables de estado
  bool _loading = false;
  bool _obscureText = true;

  // ========================================================
  // MÉTODOS DE AYUDA (Validaciones y Alertas)
  // ========================================================

  void _showFriendlyAlert(String title, String message
```

Figura 5.18. Código de inicio de sesión

La Figura 26 muestra parte de la codificación correspondiente a la gestión de parcelas agrícolas, donde el usuario puede registrar, visualizar y seleccionar una parcela para realizar diagnósticos.

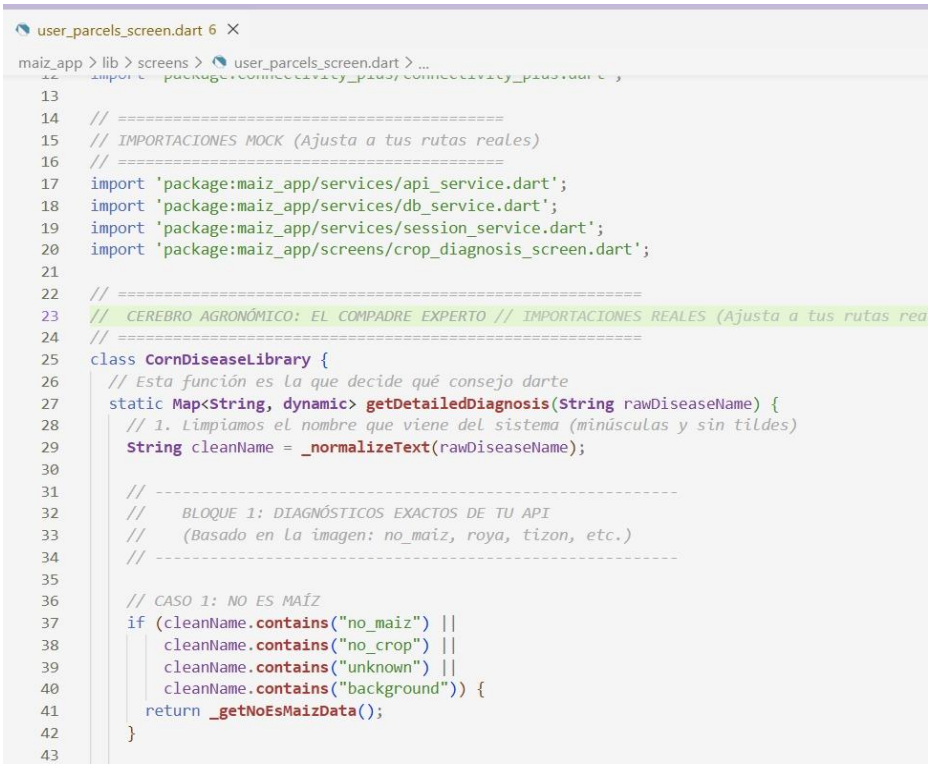


Figura 5.19. Código de gestión de parcelas

En la Figura 27 se observa el fragmento de código encargado de la captura y envío de la imagen de la hoja de maíz hacia el backend para su procesamiento mediante el modelo de inteligencia artificial basado en redes neuronales convolucionales.



Figura 5.20. Código de envío de imágenes

La Figura 28 presenta la codificación utilizada para la visualización del diagnóstico obtenido, donde se muestra la enfermedad detectada, el nivel de precisión del modelo y una recomendación general para el manejo del cultivo.

```dart
import 'dart:ui';
import 'package:flutter/material.dart';
import 'package:maiz_app/services/api_service.dart';

// ========================================================
// 🧠 CEREBRO AGRONÓMICO: EL COMPADRE EXPERTO 🧠
// (Tu librería integrada aquí mismo)
// ========================================================
class CornDiseaseLibrary {

  // Esta función es la que decide qué consejo darte
  static Map<String, dynamic> getDetailedDiagnosis(String rawDiseaseName) {

    // 1. Limpiamos el nombre que viene del sistema (minúsculas y sin tildes)
    String cleanName = _normalizeText(rawDiseaseName);

    // ---------------------------------------------------------
    //    BLOQUE 1: DIAGNÓSTICOS EXACTOS DE TU API
    //    (Basado en la imagen: no_maiz, roya, tizon, etc.)
    // ---------------------------------------------------------

    // CASO 1: NO ES MAÍZ
    if (cleanName.contains("no_maiz") ||
        cleanName.contains("no_crop") ||
        cleanName.contains("unknown") ||
        cleanName.contains("background")) {
```

Figura 5.21 Código de visualización de diagnóstico

En la Figura 29 se muestra el código correspondiente al historial de diagnósticos, permitiendo al usuario consultar evaluaciones realizadas anteriormente. Esta funcionalidad facilita el seguimiento del estado de las plantas a lo largo del tiempo.

```dart
import 'dart:io'; // Necesario para cargar la imagen local si falla la red
import 'package:flutter/material.dart';
import 'package:maiz_app/services/api_service.dart';
import 'package:maiz_app/services/db_service.dart';
import 'package:maiz_app/screens/diagnosis_detail_screen.dart';

class DiagnosisHistoryScreen extends StatefulWidget {
  final int userId;

  const DiagnosisHistoryScreen({super.key, required this.userId});

  @override
  State<DiagnosisHistoryScreen> createState() => _DiagnosisHistoryScreenState();
}

class _DiagnosisHistoryScreenState extends State<DiagnosisHistoryScreen> {
  // --- PALETA DE COLORES (Consistente con Home) ---
  static const Color primaryGreen = Color(0xFF66BB6A);
  static const Color darkGreen = Color(0xFF2E7D32);
  static const Color bgColor = Color(0xFFF1F8E9);
  static const Color cardColor = Colors.white;

  bool loading = true;
  List<Map<String, dynamic>> diagnoses = [];
```

Figura 5.22. Código de historial de diagnóstico

5.3.6 Prueba

Pruebas Funcionales

En esta sección se presentan los casos de prueba funcionales definidos para verificar el correcto funcionamiento de la aplicación móvil, los cuales se encuentran alineados con las historias de usuario planteadas.

Tabla 5.29 Prueba funcional CP001

N° Caso de prueba	N° Historia de usuario	Usuario	Evaluador
CP001	HU-01	Agricultor	Equipo de desarrollo
Objetivo de la prueba:	Verificar el inicio de sesión del usuario agricultor.		
Descripción:	El sistema debe permitir el acceso al usuario mediante correo electrónico y contraseña válidos.		
Condiciones de	Usuario previamente registrado en el sistema.		

<table>
<tr><td>entrada:</td><td colspan="2"></td></tr>
<tr><td>Pasos:</td><td colspan="2">1. Ingresar a la aplicación.

2. Introducir correo electrónico válido.

3. Introducir contraseña válida.

4. Presionar el botón “Ingresar”.</td></tr>
<tr><td colspan="2">Resultado esperado:</td><td>Evaluación de la prueba</td></tr>
<tr><td colspan="2" rowspan="2">El sistema permite el acceso y redirige a la pantalla principal de parcelas.</td><td>Si</td><td>No</td></tr>
<tr><td>X</td><td></td></tr>
</table>

EVIDENCIA:



Figura 5.23. Iniciar sesión

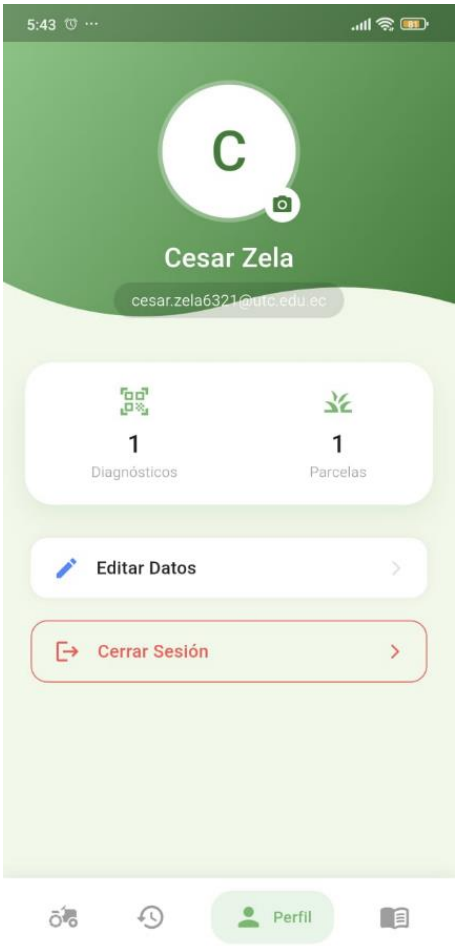


Figura 5.24. Sesión iniciada

Tabla 5.30. Prueba funcional CP002

N° Caso de prueba	N° Historia de usuario	Usuario	Evaluador
CP002	HU-02	Agricultor	Equipo de desarrollo
Objetivo de la prueba:	Verificar la recuperación de la contraseña mediante correo electrónico.		
Descripción:	El sistema debe permitir el usuario restablecer su contraseña en caso de olvidarse.		
Condiciones de entrada:	Correo electrónico registrado en el sistema.		

<table>
<tr><td>Pasos:</td><td colspan="3">1. Presionar “Olvidaste tu contraseña”
2. Ingresar el correo electrónico.
3. Revisar el correo recibido.
4. Restablecer la contraseña.</td></tr>
<tr><td colspan="2">Resultado esperado:</td><td colspan="2">Evaluación de la prueba</td></tr>
<tr><td colspan="2" rowspan="2">El usuario puede restablecer su contraseña correctamente y volver a acceder al sistema.</td><td>Si</td><td>No</td></tr>
<tr><td>X</td><td></td></tr>
</table>

EVIDENCIA:



Figura 5.25. Recuperar Contraseña

Tabla 5.31. Prueba funcional CP003

N° Caso de prueba	N° Historia de usuario	Usuario	Evaluador
CP003	HU-03	Agricultor	Equipo de desarrollo
Objetivo de la prueba:	Verificar el registro de parcelas agrícolas.		
Descripción:	El sistema debe permitir registrar parcelas con información de ubicación y nombre.		
Condiciones de entrada:	Usuario autenticado en el sistema.		
Pasos:	1. Acceder al módulo de parcelas. 2. Seleccionar la opción “Registrar parcela”. 3. Ingresar nombre y coordenadas. 4. Guardar la información.		
Resultado esperado:		Evaluación de la prueba	
La parcela se registra correctamente y aparece en el listado del usuaruio		Si	No
		X	

EVIDENCIA:



Figura 5.26. Registrar Parcelas

Tabla 5.32. Prueba funcional CP004

N° Caso de prueba	N° Historia de usuario	Usuario	Evaluador
CP004	HU-04	Agricultor	Equipo de desarrollo
Objetivo de la prueba:	Verificar la selección de una parcela registrada.		
Descripción:	El sistema debe permitir seleccionar una parcela para asociar los diagnósticos.		
Condiciones de entrada:	Existencia de parcelas registradas.		
Pasos:	1. Ingresar al listado de parcelas. 2. Seleccionar una parcela existente.		
Resultado esperado:		Evaluación de la prueba	
		Si	No
La parcela queda activa y asociada a los diagnósticos realizados.		X	

EVIDENCIA:



Figura 5.27. Selección de parcela para poder diagnosticar

Tabla 5.33. Prueba funcional CP005

N° Caso de prueba	N° Historia de usuario	Usuario	Evaluador
CP005	HU-05	Agricultor	Equipo de desarrollo
Objetivo de la prueba:	Verificar la captura de imágenes para diagnóstico.		
Descripción:	El sistema debe permitir capturar una fotografía clara de la hoja de maíz.		
Condiciones de entrada:	Cámara habilitada en el dispositivo móvil.		
Pasos:	1. Seleccionar la opción “Diagnosticar”. 2. Abrir la cámara del dispositivo. 3. Capturar la imagen. 4. Confirmar la fotografía.		
Resultado esperado:		Evaluación de la prueba	
		Si	No
La imagen se muestra en vista previa y queda lista para el análisis.		X	

EVIDENCIA:



Figura 5.28. Tomar captura

Tabla 5.34. Prueba funcional CP006

N° Caso de prueba	N° Historia de usuario	Usuario	Evaluador
CP006	HU-06	Agricultor	Equipo de desarrollo
Objetivo de la prueba:	Verificar la carga de imágenes desde la galería.		
Descripción:	El sistema debe permitir seleccionar imágenes desde la galería del dispositivo.		
Condiciones de entrada:	Existencia de imágenes almacenadas en el dispositivo.		
Pasos:	1. Seleccionar la opción “Cargar imagen”. 2. Elegir una imagen de la galería. 3. Confirmar la selección.		
Resultado esperado:		Evaluación de la prueba	
		Si	No
La imagen se carga correctamente y queda lista para su análisis.		X	

EVIDENCIA:

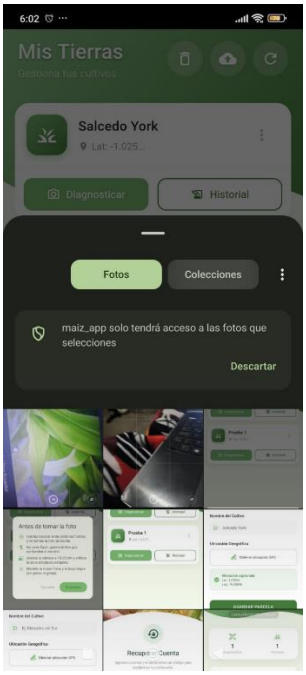


Figura 5.29. Subir fotos desde la galería

Tabla 5.35. Prueba funcional CP007

N° Caso de prueba	N° Historia de usuario	Usuario	Evaluador
CP007	HU-07	Agricultor	Equipo de desarrollo
Objetivo de la prueba:	Verificar la visualización del diagnóstico generado por la CNN.		
Descripción:	El sistema debe mostrar el resultado del diagnóstico con su nivel de confianza.		
Condiciones de entrada:	Imagen procesada por el modelo de inteligencia artificial.		
Pasos:	1. Ejecutar el diagnóstico. 2. Visualizar el resultado.		
Resultado esperado:		Evaluación de la prueba	
		Si	No
Se muestra el diagnóstico, el porcentaje de precisión y se guarda en la base de datos.		X	

EVIDENCIA:



Figura 5.30. Ver diagnóstico de la IA

Tabla 5.36 Prueba funcional CP008

N° Caso de prueba	N° Historia de usuario	Usuario	Evaluador
CP008	HU-08	Agricultor	Equipo de desarrollo
Objetivo de la prueba:	Verificar la visualización de recomendaciones del diagnóstico.		
Descripción:	El sistema debe mostrar información detallada y recomendaciones agrícolas.		
Condiciones de entrada:	Diagnóstico generado previamente.		
Pasos:	1. Acceder al historial de diagnósticos. 2. Seleccionar un diagnóstico.		
Resultado esperado:		Evaluación de la prueba	
		Si	No
Se muestran recomendaciones claras y comprensibles para el agricultor.		X	

EVIDENCIA:



Figura 5.31. Recomendaciones del diagnóstico

Tabla 5.37. Prueba funcional CP009

N° Caso de prueba	N° Historia de usuario	Usuario	Evaluador
CP009	HU-09	Agricultor	Equipo de desarrollo
Objetivo de la prueba:	Verificar el cierre de sesión del usuario.		
Descripción:	El sistema debe cerrar la sesión activa de forma segura.		
Condiciones de entrada:	Sesión iniciada.		
Pasos:	1. Seleccionar la opción “Cerrar sesión”. 2. Se redirigirá a la pantalla del Login		
Resultado esperado:		Evaluación de la prueba	
		Si	No
El sistema finaliza la sesión y redirige a la pantalla de inicio.		X	

EVIDENCIA:

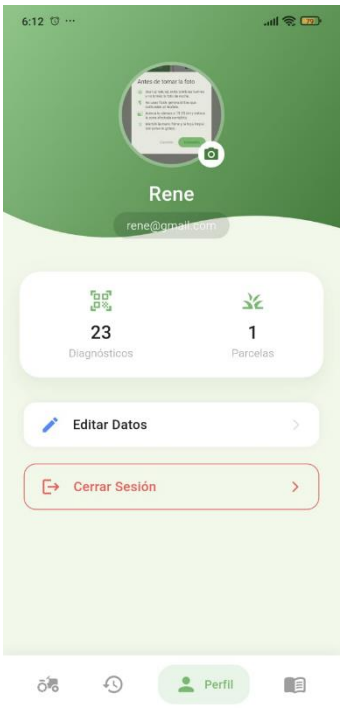


Figura 5.32. Cerrar sesión

Tabla 5.38. Prueba funcional CP010

N° Caso de prueba	N° Historia de usuario	Usuario	Evaluador
CP010	HU-A01	Administrador	Equipo de desarrollo
Objetivo de la prueba:	Verificar la visualización de las parcelas registradas por los usuarios.		
Descripción:	El sistema debe permitir al administrador visualizar todas las parcelas registradas por los usuarios del sistema.		
Condiciones de entrada:	Administrador autenticado y existencia de parcelas registradas en la base de datos.		
Pasos:	1. Iniciar sesión como administrador. 2. Acceder al módulo de gestión de usuarios o parcelas. 3. Visualizar el listado de parcelas registradas.		
Resultado esperado:		Evaluación de la prueba	
		Si	No
El sistema muestra correctamente el listado de parcelas con información de usuario y ubicación.		X	

EVIDENCIA:



Figura 5.33 Ver parcelas registradas de los usuarios

Tabla 5.39. Prueba funcional CP011

N° Caso de prueba	N° Historia de usuario	Usuario	Evaluador
CP011	HU-A02	Administrador	Equipo de desarrollo
Objetivo de la prueba:	Verificar la visualización del dashboard de indicadores.		
Descripción:	El sistema debe mostrar gráficos estadísticos del funcionamiento del sistema.		
Condiciones de entrada:	Existencia de diagnósticos registrados en el sistema.		
Pasos:	1. Ingresar al panel administrativo. 2. Acceder al dashboard.		
Resultado esperado:		Evaluación de la prueba	
		Si	No
Los gráficos se muestran correctamente, sin errores, y reflejan datos reales.		X	

EVIDENCIA:



Figura 5.34 Ver dashboard de administrador

Tabla 5.40. Prueba funcional CP012

N° Caso de prueba	N° Historia de usuario	Usuario	Evaluador
CP012	HU-A03	Administrador	Equipo de desarrollo
Objetivo de la prueba:	Verificar la visualización de indicadores clave del sistema (KPIs).		
Descripción:	El sistema debe permitir al administrador visualizar indicadores y gráficos estadísticos del funcionamiento de la aplicación.		
Condiciones de entrada:	Existencia de diagnósticos y usuarios registrados en el sistema.		
Pasos:	1. Iniciar sesión como administrador. 2. Acceder al panel de control administrativo. 3. Visualizar los gráficos e indicadores del sistema.		
Resultado esperado:		Evaluación de la prueba	
		Si	No
Los indicadores y gráficos se muestran correctamente, actualizados y sin errores de visualización.		X	

EVIDENCIA:



Figura 5.35 Ver KPIs

5.3.7 Implementación

El despliegue de los elementos elaborados durante el proyecto, que incluyen la aplicación para dispositivos móviles, la parte posterior del sistema y el modelo de inteligencia artificial en un ambiente de ejecución que posibilite su operación conjunta, fue lo que constituyó la implementación del sistema. Para este fin, se emplearon tecnologías como AWS para la infraestructura en la nube; contenedores Docker para el despliegue de servicios; Flutter para la app móvil y FastAPI para el backend del sistema.

Esta arquitectura posibilita que la aplicación para móviles tome fotografías de las hojas de maíz y las transmita al servidor para su análisis a través del modelo de redes neuronales convolucionales. Después, el diagnóstico pertinente es presentado al usuario.

Infraestructura en la nube

Para la implementación del sistema se utilizó un servidor en la nube mediante el servicio Amazon EC2, el cual permitió alojar los servicios del backend y el modelo de inteligencia artificial. Esta infraestructura facilita el acceso remoto al sistema y garantiza la disponibilidad del servicio para el procesamiento de imágenes enviadas desde la aplicación móvil.

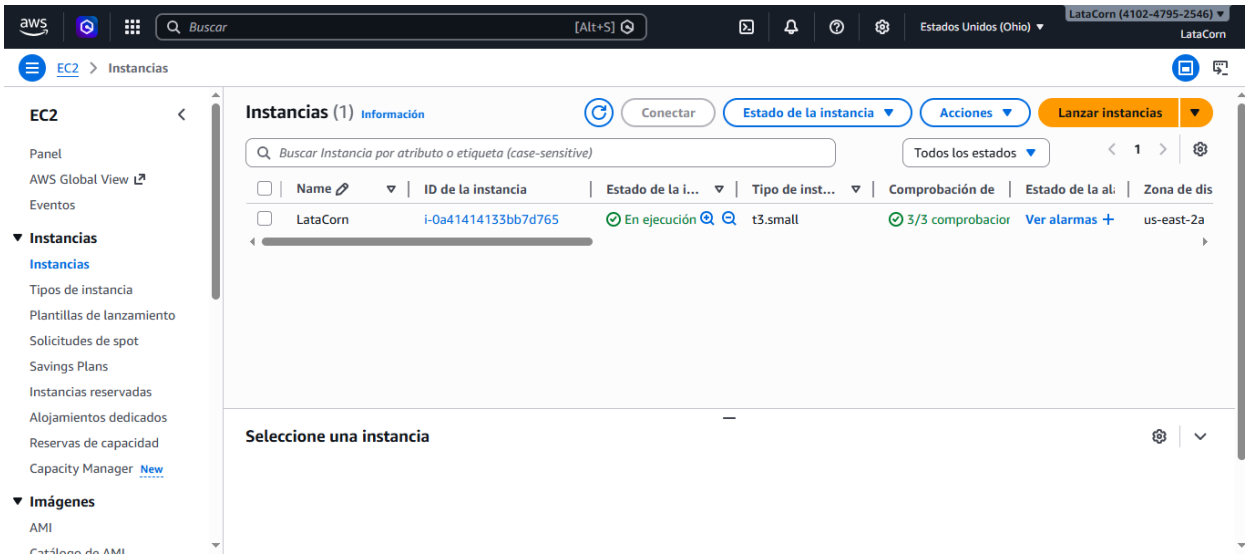


Figura 5.36 Instancia EC2

Implementación del enmascaramiento del backend

- **Configuración del dominio**

Se adquirió el dominio maizapp-ec.com mediante el registrador Namecheap. Posteriormente, se configuraron registros A en la sección Advanced DNS, apuntando tanto el dominio principal (@) como el subdominio www hacia la dirección IP pública de la instancia EC2 (3.143.11.67). Con esta configuración, cualquier solicitud realizada al dominio se redirige automáticamente hacia el servidor donde se encuentra desplegada la aplicación.

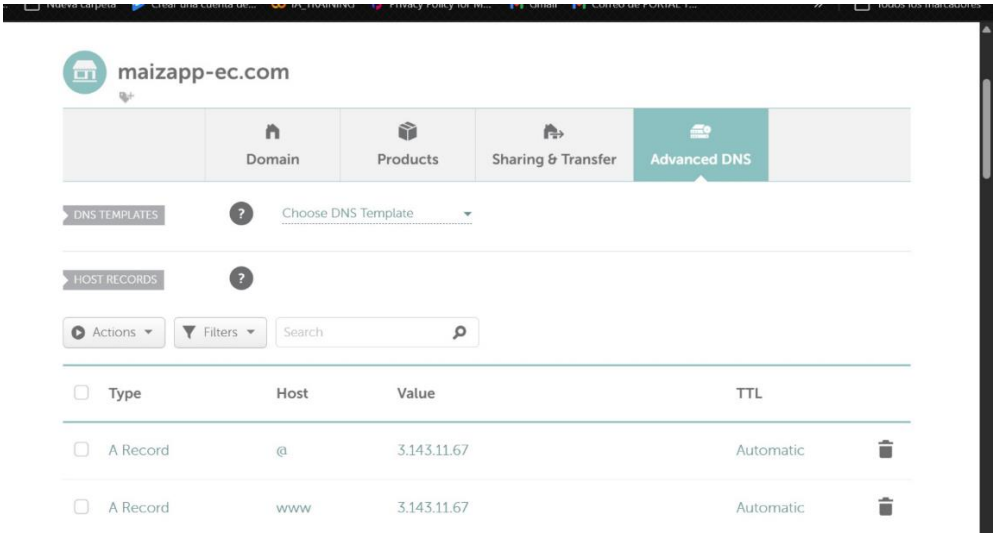


Figura 5.37 Configuración de registros DNS del dominio en Namecheap.

- **Instalación de Nginx**

En la instancia Ubuntu Server de AWS se instaló Nginx, el cual funciona como proxy inverso, es decir, como intermediario entre las solicitudes provenientes de internet y el backend de la aplicación. Esto permite que Nginx reciba las peticiones HTTP desde el dominio y las redirija internamente hacia el servicio que se ejecuta dentro del contenedor Docker.

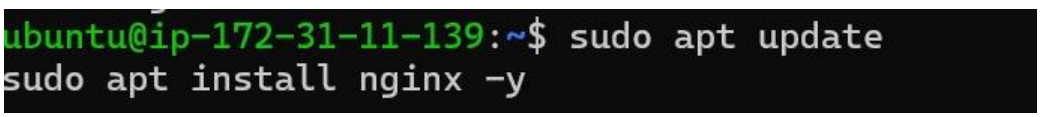


Figura 5.38 Instalación del servidor Nginx en la instancia Ubuntu de AWS EC2.

- **Instalación de Nginx**

Posteriormente, se creó un archivo de configuración específico para el dominio dentro del directorio de Nginx. Este archivo permite definir cómo se gestionarán las solicitudes dirigidas al sistema.

```
ubuntu@ip-172-31-11-139:~$ sudo nano /etc/nginx/sites-available/maizapp
ubuntu@ip-172-31-11-139:~$
```

Figura 5.39 Creación del archivo de configuración del sitio en Nginx.

En este archivo se estableció la estructura del servidor virtual encargado de manejar el tráfico dirigido al dominio de la aplicación.

- **Configuración del proxy inverso**

Dentro del archivo de configuración se definió un bloque server que escucha en el puerto 80, correspondiente al tráfico HTTP. Además, se configuró la directiva server_name para reconocer las solicitudes dirigidas al dominio maizapp-ec.com. Mediante la directiva proxy_pass, Nginx redirige las solicitudes hacia http://localhost:8000, que corresponde al puerto interno donde se ejecuta el backend dentro de Docker. De esta manera, Nginx actúa como intermediario, ocultando el puerto real del servicio.

```
ubuntu@ip-172-31-11-139: ~
 GNU nano 7.2                                /etc/nginx/sites-available/maizapp
server {
    listen 80;
    server_name maizapp-ec.com [www.maizapp-ec.com](https://www.maizapp-ec.com);

    location / {
        # Nginx recibe en el 80 y le pasa la bola a Docker en el 8000
        proxy_pass http://localhost:8000;
        proxy_set_header Host $host;
        proxy_set_header X-Real-IP $remote_addr;
        proxy_set_header X-Forwarded-For $proxy_add_x_forwarded_for;
        proxy_set_header X-Forwarded-Proto $scheme;
    }
}
```

Figura 5.40 Configuración del proxy inverso en Nginx.

- **Configuración de seguridad en AWS**

Finalmente, se configuraron las reglas del Security Group de la instancia EC2 permitiendo únicamente el acceso a los puertos 80 (HTTP) y 22 (SSH). El puerto 8000, donde se ejecuta el backend de la aplicación, se mantuvo cerrado al acceso público para evitar accesos directos desde internet, permitiendo que solo Nginx dentro del servidor pueda comunicarse con este servicio.



Figura 5.41 Configuración de reglas de seguridad en AWS EC2.

RESULTADOS OBTENIDOS

Gracias a esta configuración, la aplicación cliente consume los servicios mediante la dirección http://maizapp-ec.com, sin exponer directamente la IP del servidor ni el puerto interno donde se ejecuta el backend, logrando así un enmascaramiento del servicio y mayor seguridad en la arquitectura del sistema.

Contenedores Docker

Para que la portabilidad y administración de los servicios del sistema sean más fáciles, se empleó Docker para ejecutar los diversos componentes de la aplicación a través de contenedores. Se empleó Docker Compose para establecer los servicios indispensables para el funcionamiento del sistema, como la base de datos, la parte trasera (backend) y los servicios asociados al procesamiento de imágenes.

Encapsular las dependencias del sistema y ejecutar los servicios de forma independiente es posible gracias al uso de contenedores, lo que favorece su implementación y mantenimiento.

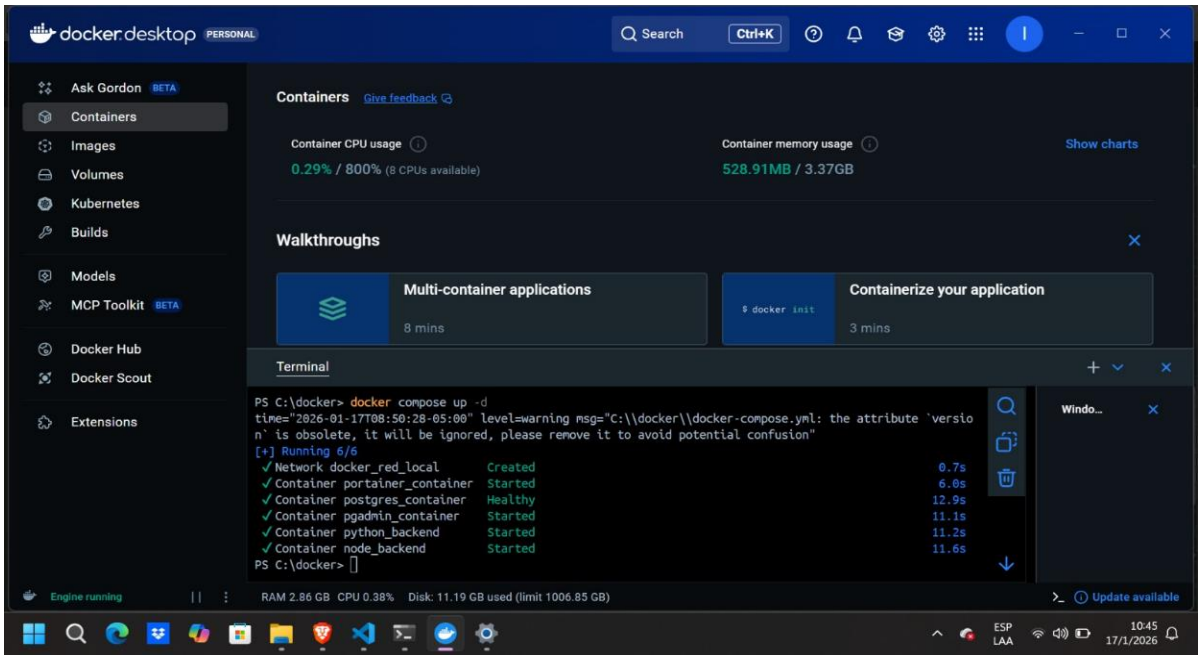


Figura 5.42 Ejecución de los contenedores Docker

docker-compose.yml

```yaml
version: "3.8"

services:
  # --- BASE DE DATOS (POSTGRES) ---
  postgres:
    image: postgres:15-alpine
    container_name: postgres_container
    restart: unless-stopped
    environment:
      POSTGRES_USER: "user"
      POSTGRES_PASSWORD: "password"
      POSTGRES_DB: "maizdb"
    ports:
      - "5432:5432"
    volumes:
      - postgres_data:/var/lib/postgresql/data
      # Si tienes un script de restauración, descomenta la siguiente línea:
      # - ./restore.sh:/docker-entrypoint-initdb.d/restore.sh
    networks:
      - red_local
    healthcheck:
      test: ["CMD-SHELL", "pg_isready -U user -d maizdb"]
      interval: 5s
      timeout: 5s
      retries: 5
```

Figura 5.43 Código docker.yml

5.4 RESULTADOS DE LA METODOLOGÍA KDD

5.4.1 Selección de datos

En esta fase, se recopilaron imágenes de hojas de maíz provenientes de fuentes públicas y también de un archivo interno con el fin de tener información diversa y representativa para la capacitación del modelo de clasificación. Se empleó el repositorio PlantVillage como fuente pública, que proporcionó 3147 fotografías de hojas de maíz, clasificadas en función de la enfermedad que las afectaba: hojas saludables, con tizón, con roya y con mancha gris. Así, se consideraron las condiciones de cultivo más frecuentes.

Para que el modelo pueda aprender a detectar y eliminar este tipo de imágenes, evitando así diagnósticos erróneos, se añadió además un conjunto de datos propio compuesto por 1011 fotografías que no son hojas de maíz. Gracias a esta mezcla de fuentes, se formó un conjunto diverso y balanceado, que incluye cinco tipos de clasificación: hoja sana, hoja con tizón, hoja con mancha gris, hoja con roya y hoja no maíz.

En la Tabla 5.41 se detallan los conjuntos de datos utilizados, indicando el origen de la información, la cantidad total de imágenes y cómo se distribuyen entre las clases consideradas durante el entrenamiento.

Tabla 5.41. Conjunto de datos

Conjunto de datos para el entrenamiento del modelo			
Fuente de Datos	Total de imágenes	Clases	Total
PlantVillage	3147	Hoja sana	885
		Hoja con tizón	879
		Hoja con mancha gris	513
		Hoja con roya	870
Dataset Propio	1011	No maíz	1011

5.4.2 Preprocesamiento de datos

La fase de preprocesamiento, dentro de la metodología KDD, tuvo como objetivo principal homogeneizar el conjunto de imágenes y prepararlo para la arquitectura de red neuronal seleccionada. Para ello, se aplicaron dos transformaciones esenciales.

En primer lugar, todas las imágenes se unificaron al formato de color RGB. Estandarizar el espacio de color fue un paso necesario para asegurar que la red convolucional interpretara de manera coherente la información visual de cada muestra, evitando sesgos por diferencias en la codificación del color.

En segundo lugar, con el fin de adecuarse a la resolución de entrada que espera MobileNetV2 como modelo base, las imágenes fueron escaladas a 224 x 224 píxeles. Esta normalización de las dimensiones no solo es una exigencia técnica en arquitectura, sino que además disminuye la variabilidad en los datos, lo que hace más fácil un entrenamiento posterior más eficaz y estable.

Estas medidas de preprocesamiento fueron fundamentales para asegurar la calidad y la coherencia de los datos, reducir al mínimo probables errores y garantizar que se mantenga la compatibilidad con el modelo planteado desde el comienzo del procedimiento.



Figura 5.44. Preprocesamiento de imágenes

5.4.3 Transformación de datos

Durante la fase de transformación de datos del proceso KDD, el conjunto de datos expuesto en la Tabla 5.41 indica que el entrenamiento del modelo consumió la mayor parte de las imágenes, con un total de 3326 (80%), y que 832 (20%) fueron empleadas para validar. Gracias a esta proporción, el modelo puede aprender de una cantidad adecuada de datos y, al mismo tiempo, es posible examinar su rendimiento utilizando información que no se empleó en la capacitación. Así, se logra un análisis más imparcial del desempeño del modelo en el trabajo de detección de enfermedades en hojas de maíz.

Tabla 5.41. Distribución del dataset

Conjunto de datos	Porcentaje	Número de imágenes
Entrenamiento	80%	3326
Validación	20%	832
Total	100%	4158

5.4.4 Minería de datos

En esta etapa, se empleó una red neuronal convolucional con la arquitectura MobileNetV2 para entrenar el modelo de clasificación de imágenes mediante el conjunto de datos previamente elaborado. El análisis de hojas de maíz se beneficia de esta arquitectura, que fue elegida por su habilidad para detectar patrones visuales al clasificar imágenes y por su eficiencia computacional.

Varios hiperparámetros fueron configurados a lo largo del proceso de entrenamiento; estos posibilitan que el aprendizaje del modelo sea regulado y su rendimiento, optimizado. El conteo de épocas usadas en el entrenamiento, la función de pérdida que se utiliza para medir el error del modelo y el optimizador que se encarga de modificar los pesos de la red neuronal son algunos de los parámetros fundamentales.

Tabla 5.42. Configuración de hiperparámetros del modelo MobileNetV2

Parámetro	Valor
Arquitectura de red	MobileNetV2
Número de épocas	8
Tamaño de lote	32
Optimizador	Adam
Función de pérdida	Categorical Crossentropy
Métrica de evaluación	Accuracy

Interpretación:

La configuración de hiperparámetros utilizada permitió establecer las condiciones necesarias para el entrenamiento del modelo MobileNetV2. El uso de la arquitectura MobileNetV2 junto con el optimizador Adam y la función de pérdida Categorical Crossentropy permitió ajustar adecuadamente los pesos de la red neuronal durante el proceso de aprendizaje. Asimismo, el entrenamiento realizado durante 8 épocas con un tamaño de lote de 32 imágenes facilitó un aprendizaje progresivo y estable del modelo. En conjunto, esta configuración contribuyó a que el modelo lograra un buen desempeño en la clasificación de las diferentes categorías de hojas de maíz.

5.4.5 Interpretación y evaluación

Comportamiento del modelo

Para examinar el rendimiento del modelo a lo largo de su proceso de aprendizaje, se realizó una evaluación de su desempeño durante los diferentes períodos de entrenamiento. Para tal fin, se examinó el avance de la precisión y la función de pérdida en los conjuntos de entrenamiento y validación. Esto posibilita determinar si el modelo es estable y tiene la habilidad de aprender patrones significativos sin caer en sobreajuste.

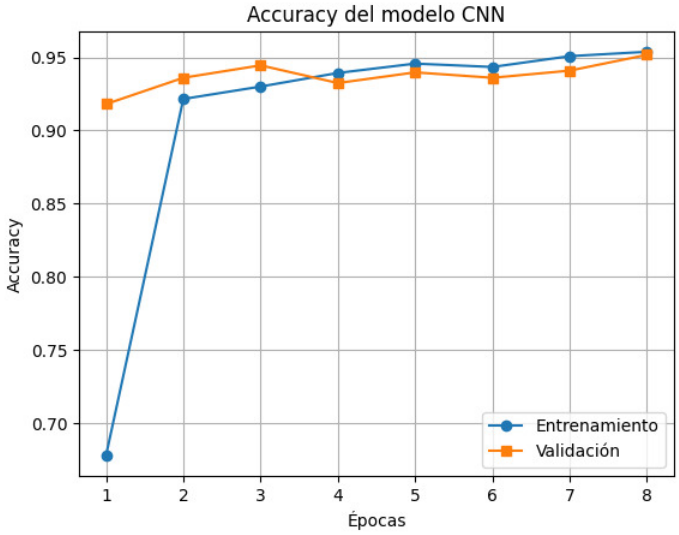


Figura 5.45. Evolución de la precisión del modelo durante el entrenamiento y la validación

Adicionalmente, se analizó el desarrollo de la función de pérdida como un indicador del proceso de optimización del modelo.

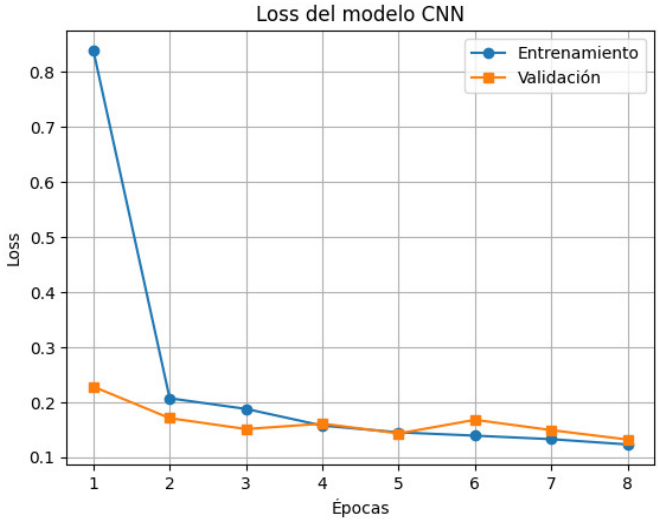


Figura 5.46. Evolución de la función de pérdida del modelo durante el entrenamiento y validación.

Evaluación del desempeño del modelo

Para hacer una evaluación objetiva del rendimiento general del modelo de clasificación, se calcularon métricas globales que permiten medir qué tan acertado es a la hora de identificar las diferentes categorías de hojas de maíz amarillo. Estas estadísticas brindan una perspectiva general de la efectividad del modelo en el trabajo planteado.

Tabla 5.43. Métrica de evaluación del modelo MobileNetV2

Métrica	Valor
Accuracy(Precisión Global)	93.37%

Interpretación:

El valor de accuracy obtenido, correspondiente al 93.37%, indica que el modelo de redes neuronales convolucionales logró clasificar correctamente la mayoría de las imágenes del conjunto de prueba. Este resultado refleja un alto nivel de desempeño en la identificación de las diferentes categorías de hojas de maíz amarillo. Por lo tanto, el modelo puede considerarse efectivo para apoyar el proceso de diagnóstico automatizado de enfermedades en hojas de maíz.

Análisis de la matriz de confusión

Se empleó una matriz de confusión para examinar el desempeño del modelo en cada clase seleccionada. Esta herramienta posibilita la identificación de los errores y los aciertos de clasificación, lo que hace más sencillo el análisis del modelo en cuanto a su competencia para diferenciar entre categorías que son visualmente semejantes.

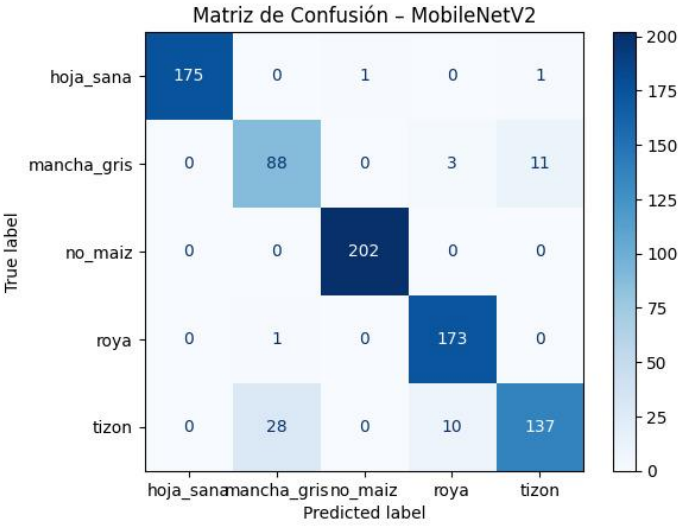


Figura 5.47. Matriz de confusión del modelo MobileNetV2

Interpretación:

La matriz de confusión muestra que el modelo MobileNetV2 logró clasificar correctamente

la mayoría de las imágenes evaluadas, lo cual se evidencia en los valores predominantes en la diagonal principal. Esto indica que el modelo tiene una buena capacidad para diferenciar entre las distintas categorías de hojas de maíz, incluyendo hojas sanas y aquellas afectadas por enfermedades como roya, tizón y mancha gris. Aunque se presentan algunos errores de clasificación entre clases con características visuales similares, el desempeño general del modelo es adecuado. En conjunto, estos resultados confirman que el modelo es efectivo para apoyar el proceso de identificación automática de enfermedades foliares en hojas de maíz amarillo.

Métricas de evaluación

Además, para llevar a cabo un análisis más detallado del rendimiento del modelo, se calcularon métricas de evaluación por clase, como la sensibilidad, la precisión y la medida F1. Estas métricas posibilitan la valoración del balance entre la precisión de las predicciones y el potencial de detección para cada categoría.

Tabla *50*. Métrica de evaluación del modelo MobileNetV2

Métricas de evaluación por clase del modelo MobileNetV2				
	Precisión	Recall	F1-Score	Support
Hoja_sana	1.0000	0.9887	0.9943	177
Mancha_gris	0.7521	0.8627	0.8037	102
No_maíz	0.9951	1.0000	0.9975	202
Roya	0.9301	0.9943	0.9611	174
Tizon	0.9195	0.7829	0.8457	175
Accuracy			0.9337	830
Macro avg	0.9194	0.9257	0.9205	830
Weighted avg	0.9367	0.9337	0.9334	830

Interpretación:

Las métricas de evaluación muestran que el modelo MobileNetV2 presenta un buen

desempeño en la clasificación de las distintas categorías de hojas de maíz. Se observan valores altos de precisión, recall y F1-score en la mayoría de las clases, especialmente en hoja_sana y no_maíz, lo que indica una correcta identificación de estas categorías. Aunque algunas clases como mancha_gris presentan valores ligeramente menores, el rendimiento general del modelo es adecuado. Estos resultados confirman que el modelo es capaz de identificar enfermedades foliares en hojas de maíz con un nivel de precisión satisfactorio.

Curva ROC

Por último, para valorar la habilidad de distinción del modelo entre las diferentes clases, se utilizaron curvas ROC con un enfoque multiclase. El examen del área bajo la curva posibilita evaluar el rendimiento del modelo de manera individual para cada clase, teniendo en cuenta su capacidad para diferenciar adecuadamente entre resultados positivos y negativos.

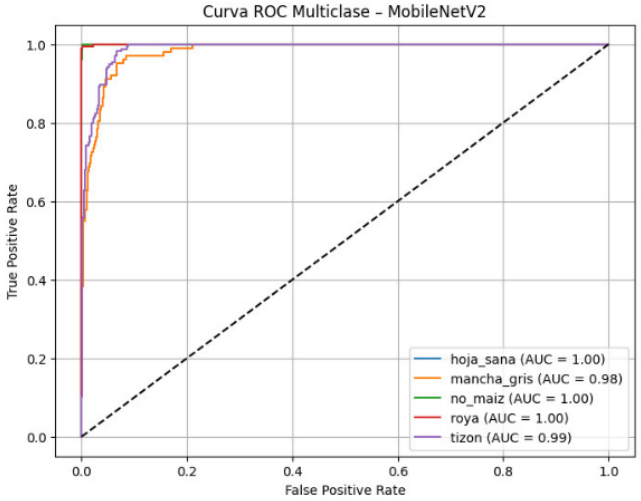


Figura 5.48. Curvas ROC basado en MobileNetV2.

Interpretación:

La curva ROC multiclase muestra que el modelo MobileNetV2 presenta una alta capacidad para diferenciar entre las distintas categorías de hojas de maíz. Los valores del área bajo la curva (AUC) se aproximan a 1.00 en la mayoría de las clases, lo que indica un excelente desempeño en la clasificación. Esto significa que el modelo logra distinguir correctamente entre imágenes positivas y negativas para cada categoría. En general, estos resultados confirman que el modelo posee una alta capacidad discriminativa para identificar enfermedades foliares en hojas de maíz amarillo.

5.5 COSTO DEL SOFTWARE

Se estimó el costo de desarrollo del sistema propuesto tomando en cuenta un equipo pequeño compuesto por dos desarrolladores, quienes se encargarán de implementar la aplicación, integrar el modelo de inteligencia artificial y realizar las pruebas funcionales del sistema. Se aplicó la técnica de T-Shirt Sizes, que se usa frecuentemente en metodologías ágiles, para estimar el esfuerzo de desarrollo. Esta metodología posibilita la asignación de un tamaño relativo a cada historia de usuario según su complejidad y el tiempo previsto para su realización.

Los tamaños de referencia que se emplean para la estimación, expresados en días de desarrollo, son mostrados en la Tabla 5.44.

Tabla 5.44. Tamaños referentes para estimar

Tamaño	Tiempo estimado
XS	2 días
S	3-4 días
M	5-6 días
L	7-8 días
XL	+9 días

Tabla 5.45. Asignación de tamaños a las historias de usuario

UH	DESCRIPCIÓN	PRIORIDAD	TAMAÑO
HU-01	Iniciar sesión	Alta	M
HU-02	Recuperar contraseña	Media	S
HU-03	Registrar parcelas	Alta	L

UH	DESCRIPCIÓN	PRIORIDAD	TAMAÑO
HU-04	Seleccionar parcela	Alta	S
HU-05	Capturar fotografía para diagnóstico	Alta	XL
HU-06	Cargar imagen desde la galería	Media	M
HU-07	Visualizar diagnóstico de enfermedad	Alta	XL
HU-08	Ver detalles y recomendaciones	Media	M
HU-09	Cerrar sesión	Baja	XS
HU-A01	Visualizar parcelas de usuarios	Media	M
HU-A02	Visualizar diagnósticos realizados	Alta	L
HU-A03	Visualizar dashboard de KPIs	Media	L

Para el cálculo del costo del software se consideraron los siguientes supuestos:

- Salario mensual promedio de un desarrollador junior/intermedio en Ecuador: **USD 800**
- Estimación de salario diario: **USD 26.66**
- Número de desarrolladores: **2**
- No se consideran costos de infraestructura física ni hardware personal

La Tabla 53 presenta el cálculo detallado del costo de desarrollo por historia de usuario.

Tabla 5.46. Estimación del costo del software

UH	Tamaño	Días	Costo / día	Total
HU-01	M	6	26.66 USD	159.96 USD
HU-02	S	4	26.66 USD	106.64 USD
HU-03	L	8	26.66 USD	213.28 USD
HU-04	S	4	26.66 USD	106.64 USD
HU-05	XL	12	26.66 USD	319.92 USD
HU-06	M	6	26.66 USD	159.96 USD
HU-07	XL	13	26.66 USD	346.58 USD
HU-08	M	6	26.66 USD	159.96 USD
HU-09	XS	2	26.66 USD	53.32 USD
HU-A01	M	6	26.66 USD	159.96 USD
HU-A02	L	8	26.66 USD	213.28 USD
HU-A03	L	8	26.66 USD	213.28 USD
			Subtotal:	2,212.78 USD
			Total:	4,425.56 USD

Se estima que el precio total del software es de USD 4,425.56, una suma que constituye una inversión efectiva para la creación de un sistema eficaz de diagnóstico de

enfermedades en hojas de maíz por medio de inteligencia artificial, desarrollado en un lapso aproximado de tres meses. Este monto abarca únicamente las tareas de análisis, diseño, desarrollo y validación del sistema, lo que incluye la ejecución del modelo de clasificación y la aplicación correspondiente. El software resultante es una solución evaluada y operativa, con la capacidad de ser ampliada y adaptada para su aplicación en situaciones agrícolas reales.

5.6 COSTO DEL DOCKER E INFRAESTRUCTURA

El sistema se implementó a través de contenedores Docker, lo cual posibilita la ejecución del modelo de inteligencia artificial y del backend de manera escalable, portátil y controlada. Para calcular el costo de la infraestructura, se tomó en cuenta una instancia Amazon EC2 t3.small, que proporciona recursos apropiados para que el sistema funcione de manera ininterrumpida en un ambiente productivo a pequeña y mediana escala.

La instancia elegida posee 2 GB de memoria RAM y 2 vCPU, recursos que son adecuados para llevar a cabo el servicio backend y hacer inferencias con el modelo de clasificación. La Tabla 52 muestra el cálculo de los costos anuales vinculados al empleo de esta infraestructura, suponiendo un funcionamiento ininterrumpido durante un año.

Tabla 5.47. Estimación anual de costos de infraestructura con Docker en AWS

RECURSO	DESCRIPCIÓN	COSTO MENSUAL ESTIMADO	COSTO ANUAL ESTIMADO
Instancia EC2	t3.small(2 vCPU, 2 GB RAM)	USD 18	USD 216
Almacenamiento	Volumen EBS (30 GB)	USD 3	USD 36
Transferencia de datos	Tráfico básico estimado	USD 4	USD 48
Total estimado		USD 25/mes	USD 300/año

5.7 RESULTADO A LA PREGUNTA DE INVESTIGACIÓN

Se creó una aplicación móvil con inteligencia artificial, a través de redes neuronales convolucionales y enfocada en la detección de enfermedades foliares en hojas de maíz amarillo. Esto se hizo con el objetivo de responder la pregunta investigativa planteada. Se eligió un conjunto de cinco ingenieros agrónomos con experiencia en la gestión de cultivos de maíz como parte del proceso de validación del sistema. Estos interactuaron con el funcionamiento de la aplicación y analizaron su eficacia como instrumento complementario para diagnosticar enfermedades en los cultivos.

A lo largo de la evaluación se mostró la manera en que funciona la aplicación, que consiste en tomar fotografías de hojas de maíz, procesar dichas imágenes a través del modelo de redes neuronales convolucionales y mostrar el diagnóstico creado por la inteligencia artificial. Después, se hicieron preguntas para analizar aspectos vinculados con la claridad del diagnóstico, la utilidad de la aplicación como instrumento de soporte para el monitoreo del cultivo y la usabilidad.

- **Usabilidad del sistema**

Los ingenieros agrónomos indicaron que la aplicación presenta una interfaz clara y fácil de utilizar. Señalaron que el proceso de captura de imágenes y visualización del diagnóstico resulta comprensible, lo que facilitaría su uso por parte de los agricultores durante el monitoreo de sus cultivos.

- **Claridad del diagnóstico generado por el sistema**

Los ingenieros agrónomos señalaron que los resultados proporcionados por la aplicación son claros y permiten identificar de forma comprensible la posible enfermedad presente en las hojas del maíz, lo cual puede servir como apoyo en el proceso de diagnóstico.

- **Utilidad de la aplicación en el monitoreo del cultivo**

Los ingenieros agrónomos manifestaron que la aplicación podría ser una herramienta útil para apoyar la identificación de enfermedades foliares en el cultivo de maíz, especialmente en contextos donde los agricultores no cuentan con acceso inmediato a

asesoría técnica especializada.

- **Apoyo al diagnóstico temprano de enfermedades**

Los ingenieros agrónomos indicaron que una herramienta basada en inteligencia artificial como la desarrollada en este estudio puede contribuir a la detección temprana de enfermedades en las hojas del maíz, permitiendo que los agricultores tomen decisiones oportunas en el manejo del cultivo.

- **Aceptación de la tecnología en el sector agrícola**

Los ingenieros agrónomos coincidieron en que el uso de aplicaciones móviles en el ámbito agrícola representa una alternativa innovadora que puede facilitar el monitoreo del estado fitosanitario del cultivo y mejorar el acceso a herramientas tecnológicas para los agricultores.

Análisis e Interpretación

Se encontró que la aplicación móvil desarrollada era útil y funcionaba bien, según las opiniones recogidas en las entrevistas a ingenieros agrónomos. Los expertos coincidieron en que la interfaz del sistema es comprensible, el diagnóstico es claro y tiene un alto potencial como herramienta para monitorear enfermedades en el cultivo de maíz. En este contexto, los resultados obtenidos permiten afirmar que la utilización de una aplicación móvil basada en redes neuronales convolucionales ayuda a identificar enfermedades foliares en las hojas del maíz, lo cual responde a la pregunta de investigación formulada en esta investigación.

6. CONCLUSIONES Y RECOMENDACIONES

6.1 CONCLUSIONES

- La revisión del marco teórico posibilitó la detección de las dolencias foliares más relevantes que impactan al maíz amarillo, así como el entendimiento de sus síntomas y rasgos visuales más representativos. Esta base teórica permitió establecer las categorías empleadas en el conjunto de datos y en la clasificación del modelo. Así, la solución tecnológica sugerida se desarrolló sobre la base del conocimiento agronómico recopilado.

- La metodología KDD sirvió para procesar y organizar los datos de imágenes de manera correcta, lo cual fue útil para evaluar y entrenar el modelo de redes neuronales convolucionales. Como consecuencia de esto, se logró un modelo que tiene la capacidad de detectar enfermedades foliares en hojas de maíz amarillo mediante el estudio de imágenes.

- Es posible implementar una solución para la detección temprana de enfermedades foliares en maíz amarillo, utilizando una aplicación móvil que esté integrada con un modelo de redes neuronales convolucionales y que se despliegue mediante contenedores Docker. Esta arquitectura permite dividir el procesamiento del modelo de la interfaz de usuario, lo que ayuda a que el sistema sea fácil de mantener, escalable y portátil.

6.2 RECOMENDACIONES

- La revisión de documentos y bibliografía sobre las enfermedades foliares del maíz amarillo se amplíe y actualice cada cierto tiempo, añadiendo nuevas investigaciones, guías agronómicas y estudios de campo. Esto hará posible que el sistema permanezca en línea con el conocimiento científico contemporáneo y que sea más fácil incorporar nuevas enfermedades o cambios sintomáticos en las versiones futuras del modelo.

- Reforzar el conjunto de datos al agregar más imágenes tomadas en diversas condiciones geográficas, ambientales y fenológicas. De igual manera, se recomienda investigar técnicas de ajuste fino y comparar el rendimiento del modelo con otras estructuras de aprendizaje profundo para optimizar la exactitud y la habilidad de generalización del sistema.

- Seguir actualizando la aplicación móvil, incorporando mejoras tanto en la interacción con el usuario como en la eficacia de comunicación con el modelo de redes neuronales convolucionales que se está utilizando en contenedores Docker. Realizar ensayos de funcionamiento en áreas agrícolas de la región andina del Ecuador para analizar la estabilidad, el rendimiento y la facilidad de uso del sistema, lo que permitiría hacer modificaciones para promover su utilización por los agricultores.

7. REFERENCIAS

[1] A. Calderon y H. Hurtado, «Machine Learning in plant disease detection,» *Tecnología, investigacion y academia,* 2019.

[2] M. E. Estrada y Martinez, «Principales enfermedades del maiz en Ecuador,» *Avances, oportunidades y desafios para la agricultura,* vol. 9, nº 2, 2021.

[3] MapCarta, «MapCarta,» 2020. [En línea]. Available: https://mapcarta.com/es/N3210144466. [Último acceso: 20 11 2025].

[4] E. U. Botero, «El cambio climático y sus efectos en la biodiversidad en América Latina.,» *CEPAL,* 2015.

[5] Lamari, «Poder estadístico en la investigación en patología vegetal,» *Google Academico,* 2002.

[6] A. Schroeder, E. Dobson, C. Rueden, T. Pavel, F. Jug y K. Eliceiri, «TheImageJecosystem:Open-sourcesoftwareforimage visualization,processing,andanalysis,» *The Proteint Society,* 2020.

[7] L. Cáceres, R. Mejía y O. Gonzalo, «Evidencias del cambio climatico en Ecuador,» *Scientific Information System,* vol. 27, nº 3, 1998.

[8] J. Hatfield y J. Prueger, «Temperature extremes: Effect on plant growth and development.,» *Weather and Climate Extrems,* nº 10, pp. 4-10, 2019.

[9] J. Delgado, «Efecto del cambio climático en la producción de hortalizas en Costa Rica,» *Escuela de Ingeniería Agrícola, Instituto Tecnológico de Costa Rica.,* 2022.

[10] L. F. Guanoluisa Pilatasig y D. A. Haro Caizabanda, «Desarrollo de una aplicación móvil basada en visión artificial para la detección de enfermedades foliares en cultivos agrícolas,» Latacunga, 2023.

[11] K. d. R. Méndez León y K. Y. Montaño Luzcando, «Implementación de una aplicación web y móvil basado en visión por computador para el control de la enfermedad Sigatoka negra en el cultivo del banano en la Hacienda Los Ángeles,» Milagro, 2022.

[12] J. M. Medina Cercado y J. A. Urteaga Montoya, «Impacto de la aplicación móvil "Healthy Plant" para detectar enfermedades foliares en cultivos de aguaymanto haciendo uso de inteligencia artificial con Custom Vision en la ciudad de Cajamarca,» Cajamarca, 2021.

[13] J. G. Enriquez y S. I. Casas, «USABILIDAD EN APLICACIONES MÓVILES,» *Dialnet,* vol. 5, nº 2, pp. 25-47, 2013.

[14] C. Bircher, «Arquitectura Cliente-Servidor/Cliente-Servidor en Aplicaciones de Misión Crítica,» *Repositorio del Instituto Universitario Aeronáutico,* 2020.

[15] J. C. P. G. T. Soto y F. S. Q. Aguilera, Inteligencia Artificial, Proyecto Latin, 2014.

[16] L. Rouhiainen, Inteligencia Atificial: 101 cosas que debes saber sobre nuestro futuro, Barcelona: Editorial Planeta, S.A., 2018.

[17] E. M. M. L. A. S. S. M.-T. Adriana Cifuentes, «Desarrollo de una red neuronal convolucional para reconocer patrones en imágenes,» *Revista I+D en TIC,* vol. 10, nº 2, pp. 7-17, 2019.

[18] B.-C. A. S. O. A. M. G. H. K. E. S. S, «Convolutional neural networks for radiologic images: A Radiologist's Guide Shelly. Radiology.,» *Revista Colomb,* p. 5591, 2021.

[19] S. J. Pan y Q. Yang, «A Survey on Transfer Learning,» *IEEE Transactions on Knowledge and Data Engineering,* vol. 22, nº 10, p. 1345–1359, 2010.

[20] L. Ali, F. Alnajjar, H. A. Jassmi, M. Gocho, W. Khan y M. A. Serhani, «Performance Evaluation of Deep CNN-Based Crack Detection and Localization Techniques for Concrete Structures,» *Sensors,* vol. 21, nº 5, p. 1688, 2021.

[21] I. Romón Jacob, «Aplicación de técnicas de Deep Learning para la detección de enfermedades

en hojas mediante análisis de imágenes,» 2022.

[22] L. Yong, L. Ma, D. Sun y L. Du, «Application of MobileNetV2 to waste classification,» *PLOS ONE,* vol. 18, nº 3, 2023.

[23] F. L. Badillo, C. A. R. Hernández, B. M. Narváez y Y. E. A. Trillo, «Redes neuronales convolucionales: un modelo de Deep Learning en imágenes diagnósticas. Revisión de tema,» *Revista Colomb,* vol. 32, nº 3, pp. 5591-9, 2021.

[24] S. Susnjara y I. Smalley, «IBM,» 2020. [En línea]. Available: https://www.ibm.com/es-es/think/topics/containerization. [Último acceso: 08 01 2026].

[25] Á. Iradier y I. Martínez, Docker para DevOps de noob a experto, 2021.

[26] C. Anderson, Docker "IEEE Software", vol. 32, 2015, pp. 102-105.

[27] Y. F. Noreña, «Revisión Sistemática de la Literatura Sobre Tecnologías Docker,» *Repositorio Universidad Nacional de Colombia,* 2022.

[28] M. D. agostino, Docker for Data Scientists, Medellín, 2022.

[29] «DESARROLLO DE UNA APLICACIÓN MÓVIL QUE PERMITA LA RECOPILACIÓN AUTOMÁTICA DE DATOS RELACIONADOS CON IMPERFECCIONES EN LA CALZADA PARA EL DISTRITO METROPOLITANO DE QUITO,» *Repositorio de la Universidad Politécnica Salesiana Sede Quito,* 08 2021.

[30] D. J. R. B. K. L. F. C. Luis Manuel Palmera Quintero, «DESARROLLO DE UN APLICATIVO MÓVIL CON NODE.JS PARA LA VENTA DE PRODUCTOS AGRÍCOLAS EN MIPYMES,» *Alianza de Investigadores Internacionales S.A.S,* 2024.

[31] T. C. Cordero, «Mercado de datos para el apoyo a la toma de decisiones sobre servidores PostgreSQL,» *Repositorio de la Universidad de las Ciencias Informáticas sobre servidores PostgreSQL,* 2013.

[32] «APLICACIÓN DE TENSORFLOW EN DEEP LEARNING,» *Repositorio de la Universidad Politécnica de Madrid,* 2018.

[33] L. M. Bedia, «Implementación de modelos de Deep Learning en dispositivos de bajo coste (Implementation of Deep Learning Models on Low-Cost Devices),» *Repositorio de la Universidad de Cantabria,* 07 2023.

[34] I. Á. Fidalgo, «Introducción al Machine Learning con TensorFlow,» *Repossitorio de la Universidad de Santiago de Compostela,* 2022.

[35] D. S. M. Pizarro, «Solución de Ecuaciones Diferenciales mediante Google Colab,» *Universidad Nacional Abierta y a Distancia,* 2025.

[36] A. O. Ramírez, «Python como primer lenguaje de programación,» *Departamento de Tecnolog´ıas de Información y Computación,* 30 06 2010.

[37] V. F. Palacio, «DESARROLLO DE GATEWAY DE SEGURIDAD EN PYTHON CON FASTAPI,» *Repositorio de la Universidad de Cantabria,* 2022.

[38] J. Joskowicz, «Reglas y Prácticas en eXtreme Programming,» *Nuevas Técnicas de Desarrollo de Software en Ingeniería Telemática,* 10 02 2008.

[39] L. M. E. Tobón y L. E. D. Carmona, «CASO PRÁCTICO DE LA METODOLOGÍA ÁGIL XP AL DESAROLLO DE SOFTWARE,» *Repositorio de la Universidad Tecnológica de Pereira,* 2007.

[40] J. M. Moine, «Metodologías para el descubrimiento de conocimiento en bases de datos: un estudio comparativo,» *Repositorio de la Universidad Nacional de la Plata,* 2013.

[41] INIAP, «Comercialización de maíz amarillo seco en la zona de Mocache,» *REPOSITORIO DE LA UNIVERSIDAD TÉCNICA DE BABAHOYO,* 2018.

[42] MAG, «Guía para la producción sustentable de maíz en la Sierra ecuatoriana,» *Instituto*

Nacional de Investigación Agropecuarias, p. 149, 2021.

[43] Agritotal, «Manual Fitosanitario,» 2014. [En línea]. Available: https://www.manualfitosanitario.com/noticias/738. [Último acceso: 14 12 2025].

[44] L. F. A. Cavallini, «Fitopatología : Un Enfoque Agroecológico,» *Google Academico,* 1998.

[45] MATABI, «El aliado para tu huerto y jardín.,» *Google academico.*

[46] M. Sautua, «Sanidad de los cultivos. Recuperado el 10 de 06 de 2019, de Cómo y cuándo aplicar fungicidas para evitar roya y tizón en el maíz,» *Repositorio Universidad Técnica de Babahoyo.*

[47] M. E. E. Martínez, «PRINCIPALES ENFERMEDADES DEL MAÍZ (ZEA MAYS, L.) EN ECUADOR,» *Google Academico,* 2021.

[48] Instituto Nacional de Estadística y Censos (INEC), «Censo de Población y Vivienda 2023: Resultados,» Quito, 2023.

8. ANEXOS

A. INFORME ANTIPLAGIO

UNIVERSIDAD TÉCNICA DE COTOPAXI

FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS

Latacunga, marzo del 2026

CERTIFICACIÓN DE INFORME DE SIMILITUD

En mi calidad de Tutor de la Propuesta Tecnológica con el tema: **"DESARROLLO DE UNA APLICACIÓN MÓVIL PARA EL CONTROL DE ENFERMEDADES DE LAS HOJAS DE MAÍZ AMARILLO UTILIZANDO INTELIGENCIA ARTIFICIAL (CNN), DOCKER, EN EL BARRIO SANTO SAMANA DEL CANTÓN LATACUNGA"**, de los estudiantes **Zela Arias César Alejandro** y **Cisneros Valencia Diego Isaac,** de la Carrera de Sistemas de Información, remito la captura de pantalla del reporte del sistema de reconocimiento de texto Turnitin, con un porcentaje de coincidencias del 7%; y expreso una vez más, mi conformidad en cuanto a la dirección del trabajo de titulación.

Particular me comunico a usted para los fines pertinentes.

Ing. Manuel William Villa Quishpe
C.C. 1803386950
TUTOR

turnitin Página 2 de 85 - Descripción general de integridad Identificador de la entrega trn:oid:::1:3495483306

7% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- Bibliografía
- Texto citado
- Texto mencionado
- Coincidencias menores (menos de 12 palabras)

Exclusiones

- N.º de fuentes excluidas

Fuentes principales

5% Fuentes de Internet
0% Publicaciones
4% Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

No se han detectado manipulaciones de texto sospechosas.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

Ing. Manuel V. Ll. C.I. 1803386950

turnitin Página 2 de 85 - Descripción general de integridad Identificador de la entrega trn:oid:::1:3495483306

B. ANEXO FORMULARIO DE LA ENCUESTA

1. ¿Con qué frecuencia se presentan enfermedades en las hojas del maíz amarillo en su cultivo?

- Nunca ( )
- Rara vez ( )
- Algunas veces ( )
- Frecuentemente ( )
- Muy frecuentemente ( )

2. ¿Las enfermedades foliares afectan significativamente el rendimiento de su producción?

- Nada ( )
- Poco ( )
- Moderadamente ( )
- Mucho ( )
- Demasiado ( )

3. ¿Tiene dificultades para identificar correctamente las enfermedades de las hojas del maíz?

- Nunca ( )
- Rara vez ( )
- A veces ( )
- Casi siempre ( )
- Siempre ( )

4. Actualmente, ¿cómo identifica las enfermedades del cultivo?

- Experiencia propia ( )
- Recomendación de otros agricultores ( )

- Técnico agrícola ( )
- Tienda agropecuaria ( )
- No sabe identificarlas ( )

5. ¿Dispone de un teléfono inteligente (smartphone) con cámara?

- Si ( )
- No ( )

6. ¿Con qué frecuencia utiliza aplicaciones móviles?

- Nunca ( )
- Rara vez ( )
- Algunas veces ( )
- Frecuentemente ( )
- Muy frecuentemente ( )

7. ¿Considera útil una aplicación móvil que identifique enfermedades del maíz mediante fotografías y uso de inteligencia artificial?

- Nada útil ( )
- Poco útil ( )
- Útil ( )
- Muy útil ( )
- Totalmente útil ( )

8. ¿Cree que una aplicación móvil ayudaría a reducir pérdidas económicas en su producción?

- No ayudaría ( )
- Ayudaría poco ( )
- Ayudaría moderadamente ( )

- Ayudaría mucho ( )
- Ayudaría totalmente ( )

9. ¿Estaría dispuesto/a a utilizar una aplicación móvil para el monitoreo y control de enfermedades del maíz?

- No ( )
- Tal vez ( )
- Si ( )

10. ¿Considera importante que la aplicación sea fácil de usar y funcione sin conexión a internet?

- Poco importante ( )
- Medianamente importante ( )
- Importante ( )
- Muy importante ( )
- Totalmente importante ( )

C. ANEXO FORMULARIO DE ENTREVISTA

N.º	Propósito	Título de la Pregunta
1	Identificar la experiencia del agricultor en el cultivo de maíz amarillo.	¿Cuántos años lleva dedicándose al cultivo de maíz amarillo?
2	Conocer la frecuencia y condiciones del ciclo productivo del cultivo.	¿Cuántas veces al año realiza la siembra del maíz amarillo?
3	Determinar la escala de producción agrícola del entrevistado	¿Qué extensión aproximada de terreno cultiva actualmente?
4	Identificar la presencia de enfermedades foliares en el cultivo.	¿Ha presentado enfermedades en las hojas del maíz durante sus cultivos?
5	Reconocer los síntomas más frecuentes de enfermedades foliares	¿Qué síntomas observa con mayor frecuencia en las hojas del maíz?
6	Determinar el momento del ciclo productivo en que aparecen las enfermedades	¿En qué etapa del cultivo aparecen normalmente estas enfermedades?
7	Conocer los métodos actuales de identificación de enfermedades en el cultivo	¿Cómo identifica actualmente una planta enferma en su cultivo?
8	Analizar el impacto económico de las enfermedades foliares	¿Las enfermedades del maíz le han generado pérdidas económicas?
9	Identificar las prácticas actuales de control de enfermedades	¿Qué acciones realiza cuando detecta una enfermedad en el cultivo?
10	Evaluar la percepción de efectividad de los métodos de control actuales	¿Considera que el control actual de enfermedades es efectivo?
11	Determinar el acceso del agricultor a dispositivos tecnológicos	¿Dispone de un teléfono celular inteligente?

D. ANEXO FORMULARIO DE ENTREVISTA EXPERTOS

N.º	Propósito	Título de la Pregunta
1	Identificar la experiencia del agricultor en el cultivo de maíz amarillo.	¿Considera que la aplicación móvil es fácil de utilizar para identificar enfermedades en hojas de maíz?
2	Conocer la frecuencia y condiciones del ciclo productivo del cultivo.	¿El diagnóstico generado por la aplicación le parece claro y comprensible?
3	Determinar la escala de producción agrícola del entrevistado	¿Considera que la aplicación podría ayudar a los agricultores a identificar enfermedades en sus cultivos de maíz?
4	Identificar la presencia de enfermedades foliares en el cultivo.	¿Cree que una herramienta de este tipo podría facilitar la detección temprana de enfermedades en las hojas del maíz?
5	Reconocer los síntomas más frecuentes de enfermedades foliares	Desde su experiencia, ¿considera que los agricultores estarían dispuestos a utilizar una aplicación móvil para el monitoreo de sus cultivos?

E. VALIDACIÓN TÉCNICA

UNIVERSIDAD TÉCNICA DE COTOPAXI

FACULTAD DE CIENCIAS AGROPECUARIAS Y RECURSOS NATURALES

Latacunga, Marzo de 2026

CERTIFICADO DE VALIDACIÓN TÉCNICA

Yo, CASTILLO DE LA GUERRA CLEVER GILBERTO, en calidad de Director de la Carrera de Agropecuaria, certifico que he revisado y evaluado la aplicación móvil desarrollada por los estudiantes CISNEROS VALENCIA DIEGO ISAAC, con cédula de ciudadanía N.° 1727653600, y ZELA ARIAS CESAR ALEJANDRO, con cédula de ciudadanía N.° 0503766321, de la Carrera de Sistemas de Información de la Facultad de Ciencias de la Ingeniería y Aplicadas, correspondiente al trabajo de titulación denominado **"Desarrollo de una aplicación móvil para el control de enfermedades de las hojas de maíz amarillo utilizando inteligencia artificial (CNN) y Docker, en el barrio Santo Samana del cantón Latacunga"**, verificando que el sistema cumple con las funcionalidades planteadas y presenta un correcto funcionamiento en la identificación de enfermedades foliares del maíz amarillo mediante técnicas de inteligencia artificial, por lo que se certifica su validación técnica para fines académicos dentro del proceso de titulación de los mencionados estudiantes.

UNIVERSIDAD TÉCNICA DE COTOPAXI
FACULTAD CARRERA

Ing. Clever Gilberto Castillo De La Guerra, MS.c.
C.I: 0501715494