RESUMEN – TRABAJO DE GRADO

AUTORES	Yeison Danuil Ascanio Ascanio Josue Campo Silva
FACULTAD	Ingenierías
PLAN DE ESTUDIOS	Ingeniería de Sistemas
DIRECTOR	Dewar Wilmer Rico Bautista
CODIRECTOR	Toni Granollers I Saltiveri
ASESOR(A)	Yesenia Areniz Arévalo
TÍTULO DE LA TESIS	Implementación de un aplicativo móvil para la detección de enfermedades enfocado a cultivos de tomate en ambientes controlados; por medio de técnicas de redes neuronales, con el fin de generar un diagnóstico que ayude a los agricultores a controlar la expansión de enfermedades en el cultivo.
TITULO EN INGLES	Implementation of a mobile application for disease detection focused on tomato crops in controlled environments, using neural network techniques to generate a diagnosis that helps farmers control the spread of diseases in the crop.

RESUMEN

El proyecto consiste en el desarrollo de un aplicativo móvil que permite detectar enfermedades en cultivos de tomate en ambientes controlados. Se utilizaron técnicas de redes neuronales para analizar imágenes de las plantas y generar diagnósticos precisos. Esta herramienta busca apoyar a los agricultores en la identificación temprana de enfermedades, contribuyendo así al control de su propagación y a una mejor gestión de los cultivos.

RESUMEN EN INGLES

The project consists of the development of a mobile application that enables the detection of diseases in tomato crops grown in controlled environments. Neural network techniques were used to analyze plant images and generate accurate diagnoses. This tool aims to support farmers in the early identification of diseases, thus helping to control their spread and improve crop management.

PALABRAS CLAVES	Aplicativo móvil, redes neuronales, cultivos de tomate, detección de enfermedades.
PALABRAS CLAVES EN INGLES	Mobile application, neural networks, tomato crops, disease detection.

CARACTERÍSTICAS

PÁGINAS: 216	PLANOS:	ILUSTRACIONES: 94	CD-ROM:

Implementación de un aplicativo móvil para la detección de enfermedades enfocado a cultivos de tomate en ambientes controlados; por medio de técnicas de redes neuronales, con el fin de generar un diagnóstico que ayude a los agricultores a controlar la expansión de enfermedades en el cultivo.

Yeison Danuil Ascanio Ascanio

Josue Campo Silva

Facultad de Ingenierías, Universidad Francisco de Paula Santander Ocaña

Ingeniería de Sistemas

Ph.D. Dewar Wilmer Rico Bautista

Ph.D Toni Granollers I Saltiveri

Msc. Yesenia Areniz Arévalo

31 de marzo de 2025

Agradecimiento

Con profunda gratitud, reconozco a quienes hicieron posible este logro académico:

A la Fundación Semillas de Paz y Amor, mi segundo hogar, donde encontré no sólo alojamiento sino una familia que me brindó apoyo incondicional y amistades genuinas que alegraron mi camino estudiantil.

A mis compañeros de universidad, cómplices de esta travesía, por los debates enriquecedores, los materiales compartidos y el ánimo constante en los momentos más desafiantes.

Al Ph.D Dewar Rico Bautista y Ph.D Toni Granollers i Saltiveri, cuya valiosa orientación y consejos expertos iluminaron mi proceso de investigación, aportando perspectivas fundamentales para mi trabajo.

A la Mag. Yesenia Areniz Arévalo, por su dedicación ejemplar y fe inquebrantable en mi potencial, ofreciéndome no sólo conocimientos académicos sino importantes lecciones de vida.

A cada docente que contribuyó a mi formación, desafiándome a superar mis límites y cultivando en mí la pasión por el aprendizaje continuo.

Este logro, aunque personal en su consecución, fue colectivo en su construcción. A todos ustedes, mi más sincero agradecimiento por ser parte esencial de esta etapa trascendental en mi vida profesional y personal.

Yeison Danuil Ascanio Ascanio

Agradecimiento

Primeramente, gracias a Dios, por brindarme la fortaleza, la sabiduría y la constancia necesaria para alcanzar esta meta.

A mis compañeros de universidad, por ser parte de este proceso formativo y personal; su compañía, apoyo y experiencias compartidas han dejado una huella significativa en mi vida.

A mis docentes, por su compromiso con la enseñanza y por impartir sus conocimientos con dedicación, paciencia y vocación.

Al PhD. Dewar Rico Bautista, director de este trabajo, por su guía, exigencia y acompañamiento constante; al PhD. Toni Granollers, codirector, por sus valiosos aportes; y a la MSc. Yesenia Areniz Arévalo, asesora, por su orientación y apoyo durante todo el desarrollo del proyecto.

Finalmente, a mi universidad, por abrirme sus puertas, brindarme las herramientas para crecer como profesional y permitirme ser parte de su historia.

Hoy, con felicidad y gratitud, puedo decir: ¡sí se pudo! "Todo lo puedo en Cristo que me fortalece." Filipenses 4:13

Josue Campo Silva

Dedicatoria

A **Dios**, mi guía y fortaleza, por darme sabiduría y perseverancia en este camino.

A mis padres, **Mirella Ascanio Álvarez** y **Juvenal Ascanio Arévalo**, por su amor incondicional y ejemplo de vida. Este logro es fruto de su apoyo.

A mis hermanos, **Fabián Eduardo Ascanio Ascanio** y **Yomaida Ascanio Ascanio**, por estar siempre a mi lado con su cariño y comprensión.

Con todo mi amor, dedico estas páginas a quienes han sido mi fundamento y motivación. Esta victoria es tan vuestra como mía.

Yeison Danuil Ascanio Ascanio

Dedicatoria

A mi familia, por su amor y apoyo incondicional.

A mis padres, **Digna Luz Silva** y **Pablo Campo**, por enseñarme el valor del esfuerzo y estar siempre presentes, dándome su cariño, ánimo y sobre todo el impulso necesario para lograr mis metas.

A mis hermanos **Yorgen Bonilla** y **Miguel David**, por ser una fuente constante de motivación y aliento.

A mi novia **Leidy Peña**, por su paciencia, comprensión y compañía en cada etapa de este proceso.

Les dedico este trabajo, fruto del respaldo, la fe y la convicción que cada uno depositó en mí. Gracias por recordarme que sí era posible.

Josue Campo Silva

Índice

1. Implementación de un aplicativo móvil para la detección de enfermedades enfocado a cultivos de tomate en ambientes controlados, por medio de técnicas de redes neuronales, con el fin de generar un diagnóstico que ayude a los agricultores controlar la expansión de enfermedades en el cultivo…… 19

1.1 Planteamiento del problema 19

1.2 Formulación del problema 25

1.3 Objetivos 25

1.3.1 Objetivo General 25

1.3.2 Objetivos específicos 25

1.4 Justificación 26

1.5 Delimitaciones 28

1.5.1 Delimitación Geográfica 28

1.5.2 Delimitación Temporal 30

1.5.3 Delimitación Conceptual 30

1.5.4 Delimitación Operativa 30

2. Marco Referencial 31

2.1 Marco histórico 31

2.1.1 Antecedentes a nivel Internacional 31

2.1.2 Antecedentes a nivel Nacional 32

2.1.3 Antecedentes a Nivel Regional 32

2.2 Marco Contextual 33

2.3 Marco Conceptual 34

2.3.1 Redes neuronales Convolucionales 34

2.3.2 Detección de enfermedades 35

2.3.3 Procesamiento de imágenes 35

2.3.4 Aplicativo móvil 38

2.3.5 Cultivo de tomates en ambientes controlados 38

2.4 Marco Teórico 39

2.5 Marco Legal 44

3. Diseño metodológico 46

3.1 Tipo de Investigación 46

3.2 Población y muestra 47

3.2.1 Población 47

3.2.2 Muestra 47

3.2.3 Diseño de instrumentos de recolección de la información y técnicas de análisis de datos 49

3.2.4 Análisis de información 49

4. Resultados. 50

4.1 Analizar toda la información relacionada con el sistema basado en conocimiento y los diferentes factores que contribuyen a la adquisición de enfermedades en los cultivos de tomates para la correcta detección e identificación de enfermedades que afectan al

cultivo…….50

4.1.1 Técnicas de inteligencia artificial empleadas con mayor frecuencia para la detección de enfermedades en cultivos agrícolas 50

4.1.2 Estudios que validan la implementación de CNN y ANN para la detección temprana de enfermedades en cultivos de tomate 53

4.1.3 Impacto que ha obtenido la implementación de CNN y ANN en el sector agrícola ……...55

4.1.4 Factores que contribuyen a la adquisición de enfermedades en los cultivos de tomates 57

4.1.5 Enfermedades que están afectando actualmente a los cultivos de tomate 60

4.2 Diseñar un sistema basado en conocimiento para la correcta detección e identificación de enfermedades que afectan al cultivo de tomate 71

4.2.1 Modelo y arquitectura de red neuronal utilizado para el procesamiento de imágenes..... 71

4.2.2 Arquitectura de red neuronal utilizada en TAIGRO..... 78

4.2.3 Inicio del Proyecto según la Guía SBOK™..... 79

4.2.4 Arquitectura utilizada para el desarrollo del aplicativo móvil..... 88

4.2.5 Especificación de requerimientos..... 91

4.2.6 Diseño de la base de datos 112

4.3 Desarrollar un sistema basado en conocimiento para la correcta detección e identificación de enfermedades que afectan al cultivo de tomate por medio de toma de imágenes de este..... 116

4.3.1 Entrenamiento de la red neuronal 116

4.3.2 Desarrollo del Aplicativo 126

4.4 Evaluar el nivel de satisfacción de los agricultores con respecto a los resultados que brinda el aplicativo móvil a la hora de diagnosticar la enfermedad y formular el tratamiento adecuado que debe seguir en su cultivo de tomate 149

4.4.1 Facilidad de uso y navegación 150

5. Generación de conocimiento 166

5.1 Participación en eventos como ponente 166

5.1.1 Participación como ponente en la feria de proyectos de aula año 2020

En la feria de proyectos de proyectos de aula del año 2020, se logró obtener el tercer puesto en la categoría Junior. 166

5.1.2 Participación como ponente en la feria de proyectos de aula año 2023-1 167

5.1.3 Participación como ponente en la feria de proyectos de aula año 2023-2 169

5.1.4 Encuentro de Semilleros de Investigación ENSI 2021 169

5.1.5 Encuentro Regional de Semilleros de Investigación REDCOLSI 2022 170

5.1.6 Congreso de Ciencia de la Computación, Electrónica e Ingeniería Industrial 171

5.2 Certificados en maratones de programación 172

5.2.1 Maratón de programación 2020 172

5.2.2 Maratón de programación 2021 173

5.2.3 Maratón de programación 2022 175

5.2.4 Maratón de programación Expotecnología 176

6. Conclusiones 178

7. Recomendaciones y trabajos futuros 180

Referencias 181

Lista de Tablas

Tabla 1 Técnicas de inteligencia artificial más utilizadas 51

Tabla 2 Arquitecturas de inteligencia artificial más frecuentemente utilizadas. 52

Tabla 3 Estudios que validan la implementación de CNN y ANN para la identificación temprana de enfermedades en cultivos de tomate 54

Tabla 4 Significado de las siglas correspondientes a cada enfermedad detectada en el estudio realizado en las zonas rurales del municipio de Abrego, Norte de Santander 70

Tabla 5 Visión del Proyecto 80

Tabla 6 Requerimientos funcionales 82

Tabla 7 Requerimientos no funcionales 84

Tabla 8 Historia de usuario de registro de información personal. 85

Tabla 9 Historia de usuario de consultar información personal registrada 85

Tabla 10 Historia de usuario de Actualizar información personal. 86

Tabla 11 Historia de usuario de captura de imágenes de hojas de tomate 80

Tabla 12 Historia de usuario de visualización de enfermedades 87

Tabla 13 Historia de usuario de acciones recomendadas 87

Tabla 14 Historia de usuario de consultar información climática 88

Tabla 15 Caso de uso de registro de información personal 91

Tabla 16 Caso de uso de inicio de sesión en el aplicativo móvil 93

Tabla 17 Caso de uso de consultar información personal registrada 94

Tabla 18 Caso de uso de Actualizar información personal 94

Tabla 19 Caso de uso de toma de imágenes de las hojas de tomate 95

Tabla 20 Caso de uso de visualización de la enfermedad detectada en la hoja de tomate 96

Tabla 21 Caso de uso de consultar información climática.....97

Tabla 22 Proceso de entrenamiento de la CNN por épocas.....121

Tabla 23 Alfa de Cronbach.....164

Tabla 24 Apéndice C. Product Backlog Refinado.....206

Tabla 25 Apéndice D. Sprint Backlog.....209

Lista de Figuras

Figura 1 Distribución geográfica de la zona de estudio.....29

Figura 2 Frecuencia de Alternari en cultivos de tomate 61

Figura 3 Frecuencia de Mancha Bacteriana en cultivos de tomate.....62

Figura 4 Frecuencia de Botritis en cultivos de tomate.....63

Figura 5 Frecuencia de La Mancha foliar causada por Septoria en cultivos de tomate.....63

Figura 6 Frecuencia de Marchitez del tomate en cultivos de tomate.....64

Figura 7 Frecuencia de Tizón Tardío en cultivos de tomate.....65

Figura 8 Frecuencia de Tizón Temprano en cultivos de tomate.....65

Figura 9 Frecuencia de Mildiu en cultivos de tomate.....66

Figura 10 Frecuencia de Virus del enrollamiento amarillo de las hojas en cultivos de tomate.....67

Figura 11 Frecuencia de Podredumbre apical en cultivos de tomate.....67

Figura 12 Frecuencia de Virus del Mosaico en cultivos de tomate 68

Figura 13 Frecuencia del Virus rugoso del tomate 69

Figura 14 Enfermedades que más afectan al cultivo de tomate en las zonas rurales del municipio de Abrego (Llano del Pozo, San Javier y El Campanario).....70

Figura 15 Arquitectura Tradicional de una CNN.....72

Figura 16 Tamaño y rendimiento de EfficientNet en el conjunto de datos de ImageNet.....74

Figura 17 Con base para el diseño de una arquitectura de ImageNet 75

Figura 18 Arquitectura de EfficientNetb.....76

Figura 19 Red neuronal utilizada en TAIGRO 78

Figura 20 Épicas 81

Figura 21 Diagrama de casos de uso 89

Figura 22 Registro de información personal 98

Figura 23 Inicio de sesión 98

Figura 24 Visualización de información personal 98

Figura 25 Actualización de información personal 99

Figura 26 Toma y diagnóstico de enfermedades presentes en la hoja del tomate 99

Figura 27 Consulta de información climática 99

Figura 28 Vista de bienvenida 101

Figura 29 Vista de Inicio de sesión 102

Figura 30 Vista de Registro de usuarios 103

Figura 31Vista de Home 104

Figura 32 Vista de actualización de datos 105

Figura 33 Vista de detección 106

Figura 34 Vista de visualización de la enfermedad detectada 107

Figura 35 Vista de clima 108

Figura 36 Arquitectura general de TAIGRO 112

Figura 37 Base de datos en postgresSQL 113

Figura 38 Base de datos en MongoDB 114

Figura 39 Imágenes en el Dataset 115

Figura 40 Redimensionamiento 118

Figura 41 Pérdida y precisión por épocas 122

Figura 42 Curva de precisión-Recall Multiclase 123

Figura 43 Mapa de difusión (t-SNE) de las características 124

Figura 44 Matriz de confusión 125

Figura 45 Interfaz gráfica de registro de información personal 128

Figura 46 Interfaz gráfica de bienvenida 129

Figura 47 Interfaz gráfica de inicio de sesión 130

Figura 48 Interfaz gráfica de consultar información personal 131

Figura 49 Interfaz gráfica de actualizar información personal 132

Figura 50 Burndown Chart sprint 1 133

Figura 51 Interfaz gráfica de la vista del home 140

Figura 52 Interfaz gráfica de la sección de captura de imágenes 141

Figura 53 Interfaz gráfica de la sección de captura de imágenes 142

Figura 54 Interfaz gráfica de visualización de la enfermedad detectada 143

Figura 55 Interfaz gráfica sobre información de la enfermedad y como tratarla 144

Figura 56 Interfaz gráfica sobre información de la enfermedad y como tratarla 145

Figura 57 Interfaz gráfica de la sección de información climática 146

Figura 58 Análisis del Desempeño del Sprint 2 147

Figura 59 Facilidad de uso y navegación 151

Figura 60 Interfaz clara y organizada 151

Figura 61 Registro y acceso a la aplicación 152

Figura 62 Uso de la cámara para capturar imágenes 153

Figura 63 Precisión del diagnóstico 154

Figura 64 Identificación correcta de enfermedades 155

Figura 65 Utilidad de la imagen de referencia 155

Figura 66 Claridad en las recomendaciones de tratamiento 156

Figura 67 Utilidad de la información proporcionada 157

Figura 68 Aplicabilidad de los pasos recomendados 158

Figura 69 Información climática como herramienta de planificación 158

Figura 70 Precisión de la predicción del clima 159

Figura 71 Estabilidad del sistema 160

Figura 72 Tiempo de respuesta del diagnóstico 160

Figura 73 Consistencia de los datos almacenados 161

Figura 74 Satisfacción general con la aplicación 162

Figura 75 Recomendaría esta aplicación a otros agricultores 162

Figura 76 Certificado de participación de Yeison Danuil Ascanio en la feria de proyectos de aula 2020 166

Figura 77 Certificado de participación de Josue Campo en la feria de proyectos de aula 2020 167

Figura 78 Certificado de participación de Yeison Ascanio en la feria de proyectos de aula 2023-1 168

Figura 79 Certificado de participación de Josue Campo en la feria de proyectos de aula 2023-1 168

Figura 80 Certificado de participación de Yeison Ascanio y Josue Campo en la feria de proyectos de aula 2023-2 169

Figura 81 Certificado de participación de Yeison Ascanio en el ENSI 2021 170

Figura 82 Certificado de participación de Yeison Ascanio en el REDCOLSI 2022 171

Figura 83 Certificado de participación en el CSEI 23 172

Figura 84 Certificado de participación en The 2020 ICPC South America-North Finals..... 173

Figura 85 Certificado de participación de Yeison Ascanio en la Maratón de programación 2021 174

Figura 86 Certificado de participación de Josue Campo en la Maratón de programación 2021 174

Figura 87 Certificado de participación de Yeison Ascanio en la Maratón de programación 2022 175

Figura 88 Certificado de participación de Josue Campo en la Maratón de programación 2022 175

Figura 89 Certificado de participación de Yeison Ascanio en la Expotecnología 2021..... 176

Figura 90 Certificado de participación de Josue 177

Figura 91 Encuesta realizada a agricultores 190

Figura 92 Uso de la herramienta de Notion para la gestión del proyecto- Sprint 1 202

Figura 93 Uso de la herramienta de Notion para la gestión del proyecto- Sprint 2..... 204

Figura 94 Apéndice E. Evidencia de reuniones con los Agricultores de las zonas rurales y usabilidad del aplicativo 212

Apéndices

Apéndice A. Encuesta realizada a agricultores 190

Apéndice B. Uso de la herramienta de Notion para la gestión del proyecto.....202

Apéndice C. Product Backlog Refinado 206

Apéndice D. Sprint Backlog 209

Apéndice E. Evidencia de reuniones con los Agricultores de las zonas rurales y usabilidad del aplicativo 212

1. Implementación de un aplicativo móvil para la detección de enfermedades enfocado a cultivos de tomate en ambientes controlados, por medio de técnicas de redes neuronales, con el fin de generar un diagnóstico que ayude a los agricultores controlar la expansión de enfermedades en el cultivo.

1.1 Planteamiento del problema

Para satisfacer la demanda de cantidad y calidad de productos, los agricultores necesitan evolucionar utilizando tecnología para hacer más eficientes todos sus procesos y mostrar competitividad para estar más involucrados en el mercado. Lastimosamente, solo alrededor del 15% del sector agrícola del país, utiliza actualmente las últimas tecnologías en sus procesos de producción (Minagricultura, 2021), lo cual, deja en completa evidencia el bajo índice de utilización de las tecnologías por parte de los campesinos colombianos, teniendo en cuenta el nivel de importancia que posee este sector en la economía del país.

En este sentido, actualmente es muy poco el porcentaje de utilización de la tecnología en este sector, debido a que existe cierta resistencia a la adopción de estas tecnologías por parte de muchos agricultores, además, en algunos departamentos puede haber otros limitantes que no permiten que se logre un avance óptimo en este aspecto. Tal es el caso de Norte de Santander, en donde, debido a la existencia de conflictos armados, producción de cultivos ilícitos, entre otros, no se ha logrado el avance anhelado, y es que, el grupo agropecuario de Norte de Santander representó en promedio una participación del 0,8% del total de las exportaciones locales entre 2013 y 2022 (Ministerio de comercio industria y turismo, 2023). Sin embargo, Norte de

Santander se encuentra como uno de los departamentos que más producen cultivos de tomate en el país, junto con Boyacá y Antioquía (MADR, 2020).

Por otra parte, el sector agrícola presenta diversos inconvenientes que dificultan el avance económico del mismo, siendo considerados como principales causantes de las cosechas perdidas. Entre los factores que dificultan el proceso de realización de cultivos o cosechas para los agricultores de nuestro país, se encuentran: plagas, enfermedades, malezas, deficiencias nutricionales de la planta o el suelo, condiciones climáticas, etc. Estos factores mencionados anteriormente son independientes de cada cultivo y, por ende, se deben aplicar técnicas y procesos para mitigar las pérdidas de cada cultivo en específico.

Este contexto será enfocado en la prevención y control de enfermedades del cultivo de tomate en ambientes controlados, debido a que parte fundamental del crecimiento del mismo, se debe entre otros factores, al entorno o ambiente en el cual se desarrolla, siendo un cultivo demasiado frágil en comparación con otros a la hora de ser plantado al aire libre, además, son más propensos a adquirir enfermedades en este entorno. El cultivo de tomate normalmente es afectado por múltiples enfermedades, siendo esto un reto para la producción de alimentos y uno de los principales causantes de pérdidas económicas (Altalak et al., 2022), es por eso, que los agricultores se ven obligados a replantear las formas tradicionales de sembrar este cultivo, por la cantidad de enfermedades que este adquiere al ser cosechado a campo abierto.

De esta forma, se opta por realizar el proceso de siembra en entornos controlados, el cual, reduce sustancialmente la adquisición de enfermedades en el cultivo, sin embargo, existen otros

tipos de enfermedades que, a pesar del traslado realizado del aire libre a un entorno controlado, sigue estando presente en el cultivo, siendo perjudiciales para el correcto desarrollo y el proceso de obtención de calidad del producto.

Actualmente muchos agricultores utilizan técnicas tradicionales en el proceso de identificación o detección de las enfermedades en cada uno de sus cultivos, pero este proceso no siempre se realiza de la mejor manera, ya que, los agricultores pueden confundir la enfermedad con otra, llevando al agricultor a suministrar un tratamiento que al contrario de ayudar a la planta, termina empeorando el estado de la misma, generando sobrecostos y la probabilidad de que la planta sufra daños irreversibles que afecten la calidad del fruto, además, a la hora de hacer frente a este inconveniente que representa la adquisición de enfermedades en el cultivo, se hace uso de diversos pesticidas que permiten la erradicación de tales enfermedades, pero en este proceso, muchos de estos productos utilizados se aplican bajo el desconocimiento de lo que realmente se encuentra afectando el cultivo, ocasionando desperdicio de dicho producto e intoxicación de la planta, dado a que el químico utilizado, muchas veces no es el que en realidad se requiere.

Por otro lado, las enfermedades que atacan a las plantas de tomate no pueden ser superadas inmediatamente, porque primero hay que examinar y analizar el tipo de enfermedad, y en este proceso pueden producirse errores en el tratamiento; como detectar el tipo de enfermedad equivocada, lo que hace que el método de tratamiento sea incorrecto, así mismo, algunos agricultores manifiestan que, a la hora de enfrentar una enfermedad, confían en sus propios conocimientos para hacer un diagnóstico, y si carecen de los conocimientos adecuados, es

posible que no utilicen los insumos agrícolas apropiados para el control de la enfermedad (Chen et al., 2021). Además, las generaciones más jóvenes carecen del conocimiento adecuado, siendo un gran desafío para ellos la prevención temprana de enfermedades. En estos últimos años, surge la tendencia hacia un manejo racional de las enfermedades, dentro de un marco de sustentabilidad del sistema. El concepto de "Control de enfermedades" involucra la aplicación de medidas dirigidas a eliminar al organismo causal de la enfermedad, con el paso del tiempo este concepto se ha ido reemplazando por el de "Manejo de enfermedades", que implica un proceso continuo de eventos consistentes en la selección y uso de técnicas orientadas a reducir las enfermedades a un nivel tolerable.

Respecto a una enfermedad mal identificada, se puede concluir que esta empeora la condición de la planta y se extiende más en el cultivo, llevando al agricultor al uso irracional de los insumos, ocasionando pérdidas monetarias a los agricultores y alza en los precios de los productos pertenecientes a la canasta familiar (Kusrini, et al., 2021)

Debido a la gran variación en la condición ambiental, el diagnóstico y la clasificación de enfermedades se convierten en una tarea desafiante. Aparte de la enfermedad, las hojas se ven afectadas por los cambios climáticos, complicando aún más, dar un diagnóstico preciso (Nirmala V & Gomathy B, 2003).

Las pérdidas producidas en los cultivos en general, es una situación que preocupa actualmente a los agricultores, debido a diversos factores que afectan a la producción de sus cultivos. Uno de estos factores que representa una amenaza latente, son los altos índices de

lluvias producidos en el país, de hecho, entre 2021 y 2023, se registraron alrededor de 2.201.423 hectáreas afectadas por el fenómeno de la niña, concentrándose el 85.7% en 10 departamentos, de entre los cuales se encuentra Norte de Santander (Fondo Adaptación et al., 2023). Así mismo, el exceso de humedad producido por las fuertes lluvias, conlleva la aparición de diversas enfermedades que afectan la calidad de los cultivos de tomate.

El cultivo de tomate ha sido uno de los grandes perjudicados, ya que, las siembras realizadas a campo abierto tienden a adquirir una mayor cantidad de patógenos que afectan en gran medida el cultivo, en este sentido, se le dio uso a los invernaderos para tratar de reducir estos índices, sin embargo, según un estudio realizado en Norte de Santander, donde se recalca que los productores de invernadero muestran un parámetro de evaluación medio, lo que indica que presentan mediana incidencia de enfermedades, de igual manera, estos productores incurren en alto uso de agroquímicos para el tomate, lo cual contiene efectos directos que perjudican el ambiente, la salud humana y la economía de los agricultores, debido a que incurren en altos costos en el desarrollo de la cosecha. Con base en lo anterior, se pudo evidenciar el bajo nivel de utilización de las tecnologías que permitan la identificación y correcto diagnóstico de las plagas, para evitar incurrir en tratamiento erróneo de las mismas. (Vinet & Zhedanov, 2016).

La identificación incorrecta de las enfermedades es un problema que presentan los agricultores de nuestro país, pero si nos enfocamos en el ámbito del departamento de Norte de Santander, tampoco están exentos de los bajos índices a la hora de identificar correctamente una plaga o enfermedad. Lo que produce, que los agricultores no usen o apliquen los tratamientos adecuados al cultivo. Esta situación, se encuentra afectando actualmente los invernaderos de las

zonas rurales de Llano del Pozo, San Javier y El Campanario, en donde están en el proceso de aplicar buenas prácticas en la realización del cultivo, pero aún falta integrar un buen sistema de control y monitoreo, para la correcta identificación y diagnóstico de las enfermedades que están afectando las plantas de tomate.

En este sentido, se aplicó un instrumento de medición que ayudó a determinar las enfermedades que se encuentran afectando los cultivos y la economía de los agricultores en diferentes zonas rurales, tales como, la vereda Llano del Pozo, San Javier y El Campanario, ubicadas en el municipio de Ábrego, Norte de Santander, Colombia.

Para este proyecto, se tuvieron en cuenta los grados de frecuencia con que los agricultores han observado los tipos de enfermedades propuestos en cada uno de sus cultivos, tomando como referencia aquellas donde las sumas de los resultados de Muy Frecuentemente y Frecuentemente superan el 50%.

Teniendo en cuenta los resultados obtenidos, se puede observar un alto grado de afectación en los cultivos de tomate de los campesinos de las tres zonas mencionadas anteriormente las cuales fueron modelo de investigación, debido a que es muy frecuente encontrar estas enfermedades que generan consecuencias no favorables para los agricultores, disminuyendo la calidad de los productos.

1.2 Formulación del problema

A lo largo de este proyecto, se desea dar respuesta a la siguiente pregunta: ¿De qué manera se puede realizar una detección e identificación precisa de las diferentes enfermedades que atacan los cultivos de tomate en ambientes controlados?

1.3 Objetivos

1.3.1 Objetivo General

Implementar un aplicativo móvil para la detección de enfermedades enfocado a cultivos de tomate en ambientes controlados, por medio de técnicas de redes neuronales, con el fin de generar un diagnóstico que ayude a los agricultores a controlar la expansión de enfermedades en el cultivo.

1.3.2 Objetivos específicos

Analizar toda la información relacionada con el sistema basado en conocimiento y los diferentes factores que contribuyen a la adquisición de enfermedades en los cultivos de tomates para la correcta detección e identificación de enfermedades que afectan al cultivo.

Diseñar un sistema basado en conocimiento para la correcta detección e identificación de enfermedades que afectan al cultivo de tomate.

Desarrollar un sistema basado en conocimiento para la correcta detección e identificación de enfermedades que afectan al cultivo de tomate por medio de toma de imágenes del mismo.

Evaluar el nivel de satisfacción de los agricultores con respecto a los resultados que brinda el aplicativo móvil a la hora de diagnosticar la enfermedad y formular el tratamiento adecuado que debe seguir en su cultivo de tomate.

1.4 Justificación

La agricultura es un sector de gran relevancia en Colombia, según Portafolio (2020) “ La agricultura en Colombia representa aproximadamente el 17% de la fuerza laboral del país, además, se posiciona como uno de los países con mayor disponibilidad de áreas cultivables en Latinoamérica”. Por otra parte, Procolombia (2021) afirma que “Alrededor de 40 millones de hectáreas han sido declaradas como frontera agrícola nacional, lo que equivale al 35% del territorio nacional, aunque solo 8 millones de hectáreas están actualmente cultivadas, esto evidencia el potencial de crecimiento de la agricultura en nuestro país.

En este contexto, el cultivo de tomate tiene un papel importante como producto de alimentación, dado que posee una alta demanda por parte de los consumidores, el tomate es una de las hortalizas más consumidas a nivel mundial, en la región de Norte de Santander, este cultivo destaca como uno de los principales productos agrícolas junto a la cebolla de bulbo, abarcando un área de 7.479 hectáreas, lo que representa casi el 6% de la extensión territorial del departamento (MARD, 2020).

Sin embargo, a la hora de producir esta hortaliza se presentan muchos desafíos, siendo la afección de plagas en el cultivo una de ellas, debido a que estas atacan directamente a la planta o al fruto y si estas no se identifican y tratan de manera adecuada, se puede evidenciar una drástica reducción en la calidad del producto, es por eso que, este proyecto posee gran relevancia, debido a que surge como respuesta a la necesidad de identificar y tratar de manera correcta cada una de las enfermedades que atacan el cultivo de tomate y con ello poder garantizar una fuente estable de alimentos saludables para la población en general, lo cual, puede contribuir a la seguridad alimentaria en la región y mejorar la calidad de vida de las personas, siendo los agricultores y las comunidades locales que dependen de la producción de tomate para su sustento los principales beneficiarios.

Así mismo, este proyecto se encuentra alineado con el objetivo de desarrollo sostenible número doce, que busca garantizar modalidades de consumo y producción sostenibles, dado que, la detección temprana de las enfermedades que afectan al cultivo de tomate, puede ayudar a tratar de manera adecuada dicha enfermedad y contribuir a la reducción de pesticidas innecesarios, además de asegurar una producción sostenible y segura (Producción Y Consumo Responsables - La Agenda 2030 En Colombia - Objetivos De Desarrollo Sostenible, n.d.).

La metodología propuesta para poder realizar la identificación y clasificación de las enfermedades, hace uso de redes neuronales, las cuales, representan una solución innovadora en el sector agrícola, ya que permite una detección temprana y precisa, lo que a su vez contribuirá a mejorar la productividad y la rentabilidad de los agricultores en la región. Además, se propone desarrollar un aplicativo móvil, con el fin de integrar las redes neuronales y lograr la

identificación de las enfermedades a través del procesamiento de imágenes tomadas por medio de la misma. El diseño de la aplicación se realizará teniendo en cuenta siempre generar una interacción positiva del usuario mediante la amabilidad visual de las interfaces de usuario (UI) para los agricultores.

1.5 Delimitaciones

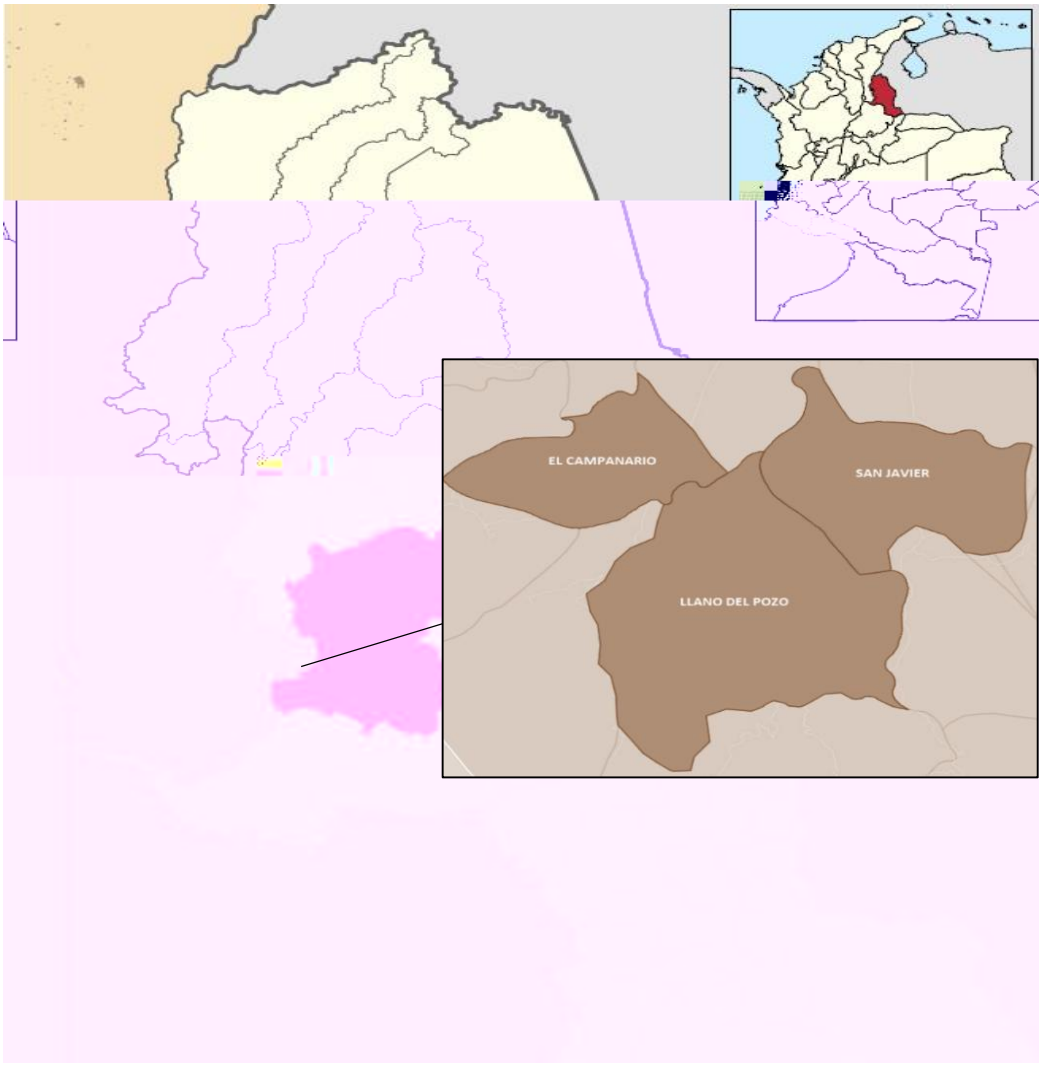
1.5.1 Delimitación Geográfica

El proyecto está dirigido a los agricultores de las zonas rurales de Llano del Pozo, San Javier y el Campanario, ubicadas en el municipio de Ábrego, Norte de Santander, Colombia.

A continuación, se presenta la distribución geográfica de la zona de estudio. En primer lugar, se muestra el mapa de Colombia con el departamento de Norte de Santander resaltado en color rojo. Luego, se visualiza el municipio de Ábrego dentro del territorio departamental y, finalmente, se identifican las tres veredas contempladas en este proyecto.

Figura 1

Distribución geográfica de la zona de estudio



Nota. Veredas de Colombia según (Esri Colombia, 2021)

1.5.2 Delimitación Temporal

La duración de este proyecto fue de (4) meses calendarios, contados a partir de la fecha de aprobación del anteproyecto.

1.5.3 Delimitación Conceptual

Para la realización de este proyecto, se consideraron los siguientes conceptos fundamentales: Agricultura de precisión, Redes neuronales artificiales, Redes neuronales convolucionales, Lenguaje de programación Python y Procesamiento de imágenes, los cuales, son de suma importancia para poder llevar a cabo el desarrollo del proyecto.

1.5.4 Delimitación Operativa

El proyecto a realizar se centrará en el uso de redes neuronales y procesamiento de imágenes, con orientación inicial para sistemas operativos Android, de esa manera, se realizará la identificación de la enfermedad que se encuentra deteriorando el cultivo de tomate, para posteriormente recomendar un tratamiento específico de acuerdo a la enfermedad detectada.

2. Marco Referencial

2.1 Marco histórico

2.1.1 Antecedentes a nivel Internacional

India es uno de los países que más produce tomates en todo el mundo, de hecho, ocupa el segundo lugar en este ámbito, pero también enfrenta un problema significativo y es la detección de enfermedades en las hojas del cultivo de tomate, debido a que este se ve afectado por diversas enfermedades que provocan una reducción en la calidad y cantidad del producto. La universidad Nacional de Ciencias Forenses de la India realizaron en su estudio la clasificación entre 10 categorías diferentes de hojas de plantas de tomate utilizando el novedoso modelo TomConv propuesto que implementa una red neuronal convolucional (CNN) mejorada, para ello, utilizaron con fines de experimentación el conjunto de datos disponible públicamente llamado PlantVillage, que comprende más de 16.000 imágenes de hojas de tomate, tanto enfermas como sanas. El modelo propuesto es el más simple entre todos los modelos de última generación disponibles. (Baser, et al., 2023)

Al finalizar el entrenamiento y las pruebas de validación obtuvieron una precisión del 98,19%. Los resultados que se obtuvieron en el estudio son prometedores ya que superaron a muchos de los modelos existentes actualmente.

2.1.2 Antecedentes a nivel Nacional

El proceso de identificar las enfermedades que afectan a un determinado cultivo es fundamental para prevenir posibles pérdidas. En una zona rural de Bogotá; Colombia, se implementó una aplicación que ayuda en la identificación de plagas en el cultivo de café, para esto, se delimitaron cuatro enfermedades hacia las que se enfocaron, con el fin de predecir qué enfermedad estaba afectando al cultivo en ese momento. Este avance fue posible gracias al uso de redes neuronales, específicamente a través de la librería de código abierto TensorFlow. (Ávila Pérez, & Gustavo Adolfo, 2022)

Las redes neuronales fueron entrenadas con un amplio conjunto de imágenes que mostraban las características de las enfermedades mencionadas, así como también imágenes del cultivo sano. Durante el proceso de entrenamiento, la red aprendió a identificar las enfermedades basadas en las características específicas de cada una, así como también a identificar si la planta estaba sana. La precisión del modelo entrenado fue determinante para su eficacia en la identificación temprana de enfermedades en los cultivos de café.

2.1.3 Antecedentes a Nivel Regional

En nuestra región de Norte de Santander se han implementado estudios para verificar la efectividad de modelos de redes neuronales convolucionales pre entrenados, uno de ellos lo realizaron LaraRodríguez, et al. (2023) en el que muestran los resultados obtenidos por dos diferentes arquitecturas de redes neuronales convolucionales, con ayuda del aumento de datos.

En su estudio, logran obtener una precisión del 87% con el que logran clasificar de manera correcta casi todas las imágenes que no se han mostrado nunca al modelo. Inicialmente, con el primer modelo, el cual tiene una estructura de red no tan compleja y con un número de capas un poco baja logran alcanzar una precisión del 78%, luego aumentan la complejidad del modelo agregando más capas y por ende más neuronas, lo que les resulta en una mejora del 9% con respecto al modelo anterior, logrando alcanzar el nivel de precisión que se mencionó anteriormente del 87%.

Los antecedentes mencionados anteriormente, son de vital importancia para validar la implementación de las redes neuronales convolucionales en la detección de características de enfermedades en el cultivo de tomate, esto ayuda y reafirma el enfoque de la presente investigación en la que se busca realizar un diagnóstico lo más preciso posible, con el fin de ayudar a los agricultores a detectar a tiempo posibles afecciones y pérdidas en su cultivo.

2.2 Marco Contextual

La implementación de este proyecto tiene lugar en las zonas rurales de Llano del Pozo, San Javier y Campanario, ubicadas en el municipio de Abrego, Norte de Santander, Colombia. En estos lugares, se planea realizar un instrumento de medición que ayude a identificar cuáles enfermedades se encuentran afectando el cultivo de tomate en las zonas anteriormente mencionadas

Teniendo plenamente identificadas las enfermedades que más afectan el cultivo de tomate, se procederá a realizar una búsqueda en bancos de datos de imágenes, con el fin de poder obtener un conjunto de imágenes robusto de cada una de las enfermedades más frecuentes en las zonas de estudio, esto con el fin de enseñarle a la red cuales son las características de las imágenes pertenecientes a cada enfermedad. Una vez que el proyecto se encuentre realizado en cuanto a los tres primeros objetivos específicos que se tienen planteados en este documento, se procederá a capacitar a los agricultores de las zonas rurales indicadas inicialmente sobre el uso del aplicativo móvil, para que así cada uno de ellos les de uso a la aplicación durante un lapso de tiempo prudencial, con el fin de determinar el nivel de satisfacción de los agricultores con respecto a los resultados que brinda el aplicativo móvil a la hora de diagnosticar la enfermedad y formular el tratamiento adecuado que debe seguir en su cultivo de tomate.

2.3 Marco Conceptual

En el desarrollo del presente proyecto es fundamental hacer uso de diferentes conceptos asociados al objeto de estudio, de los cuales es importante definir y mostrar el soporte teórico de cada elemento. A continuación, se pueden observar cada uno de los conceptos comprendidos en este estudio.

2.3.1 Redes neuronales Convolucionales

La CNN es una red neuronal artificial profunda ampliamente utilizada para la clasificación de imágenes, de hecho, en los últimos años ha venido ganando fuerza en cuanto a la

utilización en diferentes sectores por su alto rendimiento y nivel de identificación, clasificación, agrupación de similitudes y la presentación de reconocimiento de objetos basados en la visualización de imágenes. (Chen, et alt., 2021)

2.3.2 Detección de enfermedades

La detección de enfermedades en el sector agrícola es un proceso vital para los agricultores, debido a que puede evitar las pérdidas económicas asociadas con dichas enfermedades, además, al aplicar en el proceso de identificación, se pueden lograr excelentes resultados que beneficien directamente los cultivos y a los agricultores (Bensaadi & Louchene, 2023).

2.3.3 Procesamiento de imágenes

La etapa del procesamiento de imágenes o el reconocimiento de imágenes es una parte esencial para la clasificación de enfermedades en cultivos de tomate. Existen varios estudios que proponen marcos de procedimientos con el fin de obtener clasificaciones más precisas. En ese sentido, es muy importante tener en cuenta que existen muchos modelos para realizar el procesamiento de las imágenes, pero actualmente el mejor rendimiento y nivel de precisión lo poseen las Redes Neuronales Convolucionales, es por eso que están siendo muy utilizadas en los diferentes campos, uno de ellos es en la agricultura en donde posee gran relevancia para poder realizar el proceso de identificación y clasificación de las enfermedades, basándose en un

conjunto de características propias de las imágenes, tales como los pixeles, conversión a RGB (red, green, blue), saturación e intensidad, etc.(Nirmala & Gomathy, 2023)

2.3.3.1 Conjunto de datos de imágenes. El conjunto de datos de imágenes es de suma importancia a la hora de entrenar una CNN ya que nos permite definir qué imágenes pertenecen a ciertos grupos, en nuestro caso qué imágenes contienen características relacionadas a las enfermedades que tratamos. Luego, el conjunto de datos general de imágenes se divide en dos subconjuntos, el subconjunto de entrenamiento y el de verificación, estos subconjuntos se obtienen aleatoriamente, normalmente se obtiene el 80% para entrenamiento y el 20% para verificación (Hong, et al., 2023). También es importante recalcar que, dependiendo del número de datos establecidos en el subconjunto de entrenamiento, se pueden obtener o no excelentes resultados, además, a partir del aumento de los datos se puede reducir el sobreajuste durante el proceso de entrenamiento. La etapa del procesamiento o reconocimiento de imágenes es una parte esencial para la clasificación de enfermedades en cultivos de tomate, existen varios estudios que proponen marcos de procedimientos con el fin de obtener clasificaciones más precisas (Bensaadi & Louchene, 2023). En ese sentido, según Wang, et al. (2019) “es muy importante tener en cuenta que existen muchos modelos para realizar el procesamiento de las imágenes, pero actualmente el mejor rendimiento y nivel de precisión lo poseen las Redes Neuronales Convolucionales”, es por eso que están siendo muy utilizadas en los diferentes campos, uno de ellos es en la agricultura en donde posee gran relevancia para poder realizar el proceso de identificación y clasificación de las enfermedades, basándose en un conjunto de características propias de las imágenes, tales como los pixeles, conversión a RGB (red, green, blue), saturación e intensidad, etc. (Nirmala & Gomathy, 2023)

2.3.3.2 Preprocesamiento de datos. Las CNN profundas necesitan una gran cantidad de datos de entrenamiento para obtener mejores resultados, el aumento de imágenes produce artificialmente imágenes de entrenamiento utilizando varios métodos de combinación, como el giro de la imagen, la iluminación, el recorte aleatorio, y la rotación. (Hong H. L., 2020, pp. 25-29)

Normalmente estas Redes Neuronales Convolucionales corren capa por capa un paso hacia adelante, en donde en cada capa hay una función de activación en la cual se procesa lo necesario y establecido en dicha capa, además, estas capas tienen parámetros optimizados para minimizar las pérdidas. (Bensaadi & Louchene, 2023)

2.3.3.3 Entrenamiento de la CNN. Para entrenar una CNN es necesario de una arquitectura como ShuffleNet que utiliza la convolución de grupos puntuales y combina canales para reducir el costo de cálculo mientras se mantiene la precisión. (Hong, H. et al, 2020)

2.3.3.4 Modelos de CNN profundos. Los modelos de CNN profundos son algoritmos de aprendizaje que aprende y analiza grandes cantidades de datos. En el anexo 1, podemos visualizar 5 modelos de aprendizaje profundo más utilizados para la detección de enfermedades en las hojas de tomate, con su respectivo porcentaje de precisión. (Hong, H. et al, 2020)

2.3.4 Aplicativo móvil

Es un tipo de software que permite la interacción entre usuario y máquina (móvil), dando opción al usuario ejecutar acciones de las que ofrece el aplicativo. Los aplicativos móviles pueden ser desarrollados a medida para satisfacer las necesidades de un usuario en específico o ser parte de un paquete integrado. (Jesús David García Caro & Luis Gerardo Martín Martín, 2020).

2.3.5 Cultivo de tomates en ambientes controlados

Un invernadero es un lugar donde se simula y controla el ambiente, con el fin de evitar daños ocasionados por estar el cultivo expuesto al aire libre, como por ejemplo enfermedades, daños por los cambios climáticos, etc. Aunque con la implementación de estos espacios cerrados se busca aislar los cultivos de patógenos, de igual forma no se encuentran exentos de sufrir de alguna de ellas, ya que en estos espacios controlados los síntomas generalmente consisten en lesiones en el tallo que resultan de la infección de las heridas de poda dejadas por la eliminación de hojas y yemas axilares a lo largo de la temporada de crecimiento (Decognet, et al. 2009, pp. 185-193), además, otros factores también pueden influir, como por ejemplo, humedad, calor, etc.

Cada uno de los conceptos anteriormente mencionados son de vital importancia para el desarrollo de este proyecto, debido a que con cada uno de ellos se desea dar solución a la problemática planteada anteriormente. Pero también es relevante mencionar cada una de las

enfermedades que más se encuentran afectando las zonas rurales de Llano del Pozo, San Javier y el Campanario, ubicadas en el municipio de Abrego, Norte de Santander, Colombia.

2.4 Marco Teórico

El empleo de las últimas tecnologías de visión por computadora ha desempeñado un papel fundamental en la detección de enfermedades en diversos cultivos, mediante el análisis de las imágenes. A continuación, se presentan varios enfoques de investigación vinculados al proyecto:

Según Bensaadi & Louchene, (2023), en el artículo de investigación "Low-cost convolutional neural network for tomato plant diseases classification" donde proponen una clasificación automática de enfermedades de las plantas de tomate basada en una arquitectura de red neuronal convolucional (CNN) de baja complejidad en Argelia, la cual, conduce a una clasificación en línea más rápida". El estudio tiene como objetivo diseñar una estructura de red óptima, que ayude a obtener un modelo menos complejo en términos de profundidad de red, con el fin de mejorar la generalización en el proceso de clasificación de las enfermedades del cultivo de tomate. Para poder llevar a cabo lo anteriormente mencionado, se hace uso de una arquitectura de CNN de baja complejidad. Dicho modelo consta de tres capas convolution-maxpooling, las tres últimas capas son: capa totalmente conectada seguida de capas softmax y clasificación. El modelo fué entrenado, en ambiente Matlab, utilizando el método SGD con una tasa de aprendizaje constante igual a 0.0007.

Los parámetros de la red fueron modificados por ensayo y error. La base de datos se dividió en: 80% para entrenamiento y 20% para validación. En este sentido, para los datos de entrenamiento es muy importante tener en cuenta el conjunto de datos, es decir, si se hace uso de un conjunto pequeño de datos, es muy probable que las curvas de error que se obtengan sean casi cercanas al 100%, a esto se le conoce como sobreajuste y según los resultados obtenidos en la investigación, los autores proponen el aumento de los datos de entrenamiento para poder evitar dicho sobreajuste. Al finalizar su estudio, lograron obtener una precisión del 97,04% y un error de menos de 0,2. (p.164)

De la investigación se puede resaltar la importancia que posee el conjunto de datos de entrenamiento, considerando que, si se desean obtener excelentes resultados de precisión, se debe contar con un alto número de datos en el conjunto seleccionado o propuesto. Además, se puede observar que el modelo de CNN propuesto sólo usó tres capas convolucionales, lo que les permitió obtener una complejidad computacional reducida (Bensaadi & Louchene, 2023). Esto es muy importante en el presente proyecto llevado a cabo, debido a que ayuda a la rápida toma de decisiones en la aplicación diseñada; llamada Taigro.

Por otra parte, según Mim, et al. (2019), en su artículo de investigación titulado “Leaves Diseases Detection of Tomato using Image Processing”, identificaron los 5 tipos de enfermedades que más afectan el cultivo de tomate en Bangladesh, para posteriormente realizar una correcta clasificación del tipo de enfermedad haciendo uso de CNN. En el estudio se eligieron alrededor de 6000 imágenes, de las cuales, 4000 fueron tomadas por ellos directamente

y la cantidad faltante fueron tomadas de GitHub, además, para el proceso de entrenamiento y prueba decidieron utilizar 80% y 20% respectivamente. (pp.244-247)

Para poder alcanzar un alto nivel de precisión en la identificación del tipo de enfermedad, han requerido 30 épocas de entrenamiento, de donde obtuvieron una precisión final de entrenamiento de 92,61 % y la precisión de validación fué del 96,55 %. Al finalizar el estudio, han podido determinar que el uso de procesamiento de imágenes por medio de Redes Neuronales Convolucionales es muy efectivo, dado que ofrece altos niveles de confiabilidad en cuanto a la identificación de las enfermedades en cualquier tipo de cultivo y en este caso enfocado al cultivo de tomate. Este proyecto posee gran relevancia al ser usado como base, ya que, deja más claro el camino a seguir con respecto al procesamiento de las imágenes, debido a que, aunque existen otros métodos, estos no brindan tanta precisión como si lo hacen las CNN. (pp.248-249)

Ahora, teniendo en cuenta que en el presente trabajo se desea desarrollar sobre un aplicativo móvil, se han investigado algunos referentes que hacen uso de esta tecnología para dar solución a la problemática de la identificación de las enfermedades del tomate, tal es el caso de los autores Azeddine Elhassouny & Florentin Smarandache, quienes en su artículo “Smart mobile application to recognize tomato leaf diseases using Convolutional Neural Networks”, quienes en su artículo de investigación proponen una aplicación inteligente integrada para reconocer enfermedades de las hojas de tomate. En el desarrollo de su proyecto se enfrentaron con un gran inconveniente y es que normalmente la mayoría de los métodos de identificación de enfermedades de las hojas de las plantas se basa en el uso de computadoras con poder de cálculo,

pero encontraron que, con el desarrollo de los modelos de CNN cuantificados, la integración de aplicaciones inteligentes en teléfonos móviles con recursos limitados se vuelve posible.

En su estudio hicieron uso del modelo de clasificación MobileNet, el cual consiste en convoluciones separables en profundidad, lo que reduce entre 8 y 9 veces menos cómputo, en comparación de las convoluciones estándar. La aplicación construida por los autores puede identificar y reconocer alrededor de 10 tipos de enfermedades de la hoja del tomate, para poder realizar este reconocimiento, el modelo adaptado acepta una imagen de color de entrada de tamaño 224X224, para luego realizar una serie de circunvoluciones separables en profundidad con capas en profundidad y puntuales seguidas de batchnorm (BN) y ReLU. Por último, el modelo finaliza con la agrupación de promedio de capas de agrupación totalmente conectadas y la función Softmax con 10 clases. Al finalizar, los investigadores alcanzan un nivel de exactitud en su modelo del 90.3%, el cual puede mejorar aún más si se aumenta el número de datos pertenecientes al conjunto de datos de entrenamiento.

Es importante destacar el uso del modelo propuesto en la anterior investigación, debido al bajo poder de cálculo que se requiere, esto es muy relevante porque permite acceder al potente mundo de la identificación de las enfermedades con tan solo un teléfono móvil, el cual resulta ser más accesible para los agricultores.

Por último, a nivel nacional se resalta el siguiente artículo “Supervised Learning-Based Image Classification for the Detection of Late Blight in Potato Crops”, de los autores Suarez Baron, et al. (2022), donde desarrollan un modelo de clasificación para identificar las plantas de

patata como sanas o infectadas en el departamento de Boyacá, Colombia. La metodología usada en el estudio consta de tres pasos: Adquisición de datos, Núcleo lineal y la validación del rendimiento del modelo.

Para el proceso de adquisición de los datos, es importante recalcar lo que se ha podido observar en los estudios anteriores, en los cuales, hacen énfasis en que, para obtener resultados confiables en cuanto al nivel de precisión a la hora de identificar las enfermedades, se debe establecer un conjunto de datos numeroso y a partir de ahí empezar a realizar el proceso de entrenamiento correspondiente. Para la fase de núcleo lineal, se introduce la imagen y a continuación, se extraen todas las características de contraste, de semejanza y homogeneidad, luego se detecta si la hoja de papa sufre de la enfermedad que en este caso es el tizón tardío y finalmente se obtienen los resultados. Los investigadores lograron determinar que en las pruebas realizadas el modelo de CNN obtuvo mejor resultado que los modelos de máquina de vectores de soporte (SVM), en cuyo caso, el modelo de CNN obtuvo un nivel de precisión del 93%, mientras que el SVM obtuvo un nivel del 87,5%. (Suarez Baron, et al., 2022)

Todos estos resultados observados en cada uno de los anteriores estudios nos muestran la tendencia en cuanto al procesamiento de imágenes, y más que la tendencia el excelente rendimiento de las redes neuronales convolucionales a la hora de realizar identificaciones en las imágenes que, aplicada en este contexto, permiten la identificación de las enfermedades en las hojas de las plantas. Además, se puede observar la reciente inclinación por realizar o integrar estos modelos con los dispositivos móviles, por su facilidad a la hora de conseguir, portar y utilizar estos dispositivos por parte de los agricultores. En resumen, para el desarrollo de este

proyecto, se opta por seguir la reciente tendencia en cuanto a procesamiento de imágenes, desarrollo e integración de modelos de red con los dispositivos móviles.

Como parte innovadora, se ha optado por utilizar una red neuronal artificial (ANN), para procesar los datos que provienen de la CNN, para determinar con más exactitud de qué enfermedad se trata realmente, brindando el tratamiento adecuado para dicha enfermedad, y así reducir el gasto económico en insumos o pesticidas innecesarios, y finalmente evitar que se realice una intoxicación y deterioro en el estado actual del cultivo.

2.5 Marco Legal

El creciente uso y desarrollo de inteligencia artificial es algo por lo que muchas personas y países en general se encuentran preocupados, debido a que existen dilemas éticos, legales y técnicos que se deben tener presente en el proceso de creación de una IA (Inteligencia Artificial). (UNESCO, 2024)

En este sentido, se han definido debates para tratar estos temas relevantes que están relacionados con las bases y principios que deben regir estas tecnologías. A nivel nacional, se han establecido algunas leyes que regulan o controlan el accionar de las IA.

El gobierno nacional en su proyecto de ley 059 2023 del senado, presenta los lineamientos que se deben tener en cuenta al momento de usar o desarrollar cualquier tecnología que involucre IA. Ahora, con respecto a este proyecto el artículo 21, ordena que se deben

establecer los responsables en cuanto al uso, desarrollo e implementación de la IA y, además, los desarrolladores estarán en la obligación de realizar pruebas y controles que ayuden a determinar la veracidad de los datos que analice el sistema, con el fin de que aprenda con datos verídicos y los valores que genere o que brinde como resultado sean verdaderos y confiables. (Congreso de Colombia, 2024)

Por otra parte, también existen leyes que impulsan el uso y desarrollo de IA para diferentes sectores o campos de aplicación. Un ejemplo de ello es la ley 876 DE 2017, donde se crearon las herramientas que promueven el desarrollo tecnológico, gestión del conocimiento y formación del capital humano en el sector agropecuario colombiano. (MinAgricultura, 2018)

En países en desarrollo es importante promover el uso de las últimas tecnologías, es por eso, que el Consejo Nacional de Política Económica y Social (CONPES), aprobó la Política Nacional para la Transformación Digital e Inteligencia Artificial “CONPES 3975”, con el fin de aumentar el uso e implementación de tecnologías digitales y desarrollo de IA tanto en el sector público como en el privado, (MINTIC Colombia, 2019). Esto esExperts muy importante, porque permite que las entidades se apropien de las nuevas tecnologías y puedan estar en constante innovación, contribuyendo al continuo avance del proceso de la Cuarta Revolución Industrial en Colombia. No obstante, también se deben tener muy en cuenta las regulaciones que rigen esta revolución, como por ejemplo la ley 1955 de 2019, la cual se encarga de establecer el marco legal y regulatorio para la cuarta Revolución industrial. (Dbaexperts.tech, 2023)

3. Diseño metodológico

3.1 Tipo de Investigación

La metodología propuesta se encuentra enfocada en una metodología investigativa cuantitativa, ya que el enfoque cuantitativo emplea la recolección y análisis de datos para responder preguntas de investigación y validar hipótesis previamente establecidas. Se apoya en la medición numérica, el conteo y frecuentemente en el uso de la estadística para precisar patrones de comportamiento en una población o en el objeto de estudio. (Roberto Sampieri, 2014)

Para el caso de la presente investigación se utilizó un Dataset con las imágenes de las enfermedades que actualmente afectan a los pequeños agricultores de tomate, de acuerdo con los resultados arrojados en un instrumento de medición que se aplicará a dichos agricultores, para conocer las enfermedades del cultivo de tomate que más se encuentran afectando en las zonas que se tuvieron en cuenta en este estudio. Este enfoque hace hincapié en el análisis de datos cuantificables, como la precisión del modelo de red neuronal convolucional utilizado para el proceso de la identificación de las enfermedades, así como el grado de satisfacción de los agricultores con respecto al uso del aplicativo móvil y a los resultados que arroja el mismo.

3.2 Población y muestra

3.2.1 Población

La población de interés está constituida por agricultores del cultivo de tomate del municipio de Abrego, Norte de Santander, Colombia, específicamente en las zonas rurales de Llano del Pozo, San Javier y El Campanario. Para calcular el tamaño de esta población, se realizó un levantamiento preliminar de información con tres agricultores que tienen una amplia experiencia en la región. Según la información recolectada por los agricultores mencionados anteriormente se determinó que alrededor de 100 fincas están dedicadas al cultivo de tomate en estas zonas rurales. Con esta información, se puede establecer que la población total de agricultores para este estudio es de 100.

.

3.2.2 Muestra

Para calcular el tamaño de la muestra, se utilizó una fórmula estadística diseñada para poblaciones finitas:

$$n = \frac{z^2(p \times q)}{e^2 + \frac{(z^2(p \times q))}{N}}$$

En esta fórmula, n representa el tamaño de la muestra, Z es el valor que corresponde al nivel de confianza, que en este caso es 1.645 para un 90% de confianza. El parámetro p se refiere

a la proporción de la población que tiene la característica que estamos estudiando, mientras que q es su complemento. Para este caso se ha establecido en p = 0.5 y q = 0.5, debido a que no se tienen datos previos. El término e indica el margen de error permitido en el estudio, que se ha establecido en un 15%, y N es el tamaño total de la población, que hemos estimado en 100 agricultores.

$$n = \frac{1.645^2(0.5 \times 0.5)}{0.15^2 + \frac{(1.645^{2^2}\,(0.5 \times 0.5))}{100}}$$

$$n = \frac{(2.706 * 0.25)}{0.0225 + \frac{(2.706 * 0.25)}{100}}$$

$$n = \frac{0.6765}{0.0225 + \frac{0.6765}{100}}$$

$$n = \frac{0.6765}{0.0225 + 0.006765}$$

$$n = \frac{0.6765}{0.029265}$$

$$n \approx 23.116 \approx 23$$

Al sustituir todos los valores en la fórmula, se calculó un tamaño de muestra del 23% de los agricultores. Esto asegura que tengamos una representación adecuada de la población, manteniendo un margen de error del 15% y un nivel de confianza del 90%.

3.2.3 Diseño de instrumentos de recolección de la información y técnicas de análisis de datos

Para la recopilación de información, se utilizaron encuestas dirigidas a un grupo específico de agricultores que se dedican al cultivo de tomate en las zonas rurales de Llano del Pozo, San Javier y El Campanario, en el municipio de Ábrego, Norte de Santander. Para esto, se usará un cuestionario con preguntas cerradas, las cuales ya cuentan con respuestas predefinidas. Este cuestionario permitirá obtener datos precisos y comparables sobre las enfermedades que más afectan las zonas rurales anteriormente mencionadas y el nivel de satisfacción con respecto al uso del aplicativo móvil.

3.2.4 Análisis de información

Para el análisis de la información recolectada se llevaron a cabo varios procesos, en el que inicialmente se hizo una revisión de los datos para comprobar su integridad y detectar cualquier inconsistencia o valores atípicos. Luego, se validó la confiabilidad del instrumento de recolección, asegurando que las preguntas formuladas fueran claras y relevantes para el objeto de estudio y por último, se presentaron los resultados de manera estructurada, lo que facilitó su análisis y discusión en función de los objetivos del proyecto.

.

4. Resultados.

4.1 Analizar toda la información relacionada con el sistema basado en conocimiento y los diferentes factores que contribuyen a la adquisición de enfermedades en los cultivos de tomates para la correcta detección e identificación de enfermedades que afectan al cultivo

4.1.1 Técnicas de inteligencia artificial empleadas con mayor frecuencia para la detección de enfermedades en cultivos agrícolas

La detección de enfermedades es un factor crítico en cualquier cultivo, ya que, si una enfermedad se identifica y clasifica correctamente, se pueden evitar pérdidas futuras (Sanida et al, 2023). Actualmente, existen muchas herramientas a través de las cuales se puede llevar a cabo el proceso de detección y clasificación de cada una de las enfermedades que afectan a los cultivos, pero las redes neuronales convolucionales (CNN) lideran el conjunto de tecnologías o técnicas de inteligencia artificial, ya que su capacidad para identificar o detectar enfermedades ha mejorado considerablemente. Aunque su capacidad de mejora y buenos resultados se pueden observar de manera recurrente en actividades agrícolas, la verdad es que también funcionan excelentemente en otras industrias (Chen et al, 2022).

Tabla 1

Técnicas de inteligencia artificial más utilizadas

Técnica AI	Objetivo	Evaluación de desempeño	Referencia
CNN	Detección de enfermedades en el tejido foliar del tomate	99,04% de precisión	(Sanida et al., 2023)
Random forest (RF)	Detección de infección por hongos	89% de precisión	(Siedliska et al., 2018)
ANN and Support Vector Machine (SVM)	Clasificación de lesiones por enfriamiento	Precisiones que van desde 92.96% hasta 97.28%.	(Sun et al., 2017)
SVM	Detección de adulteración	97.98% de precisión	(Zhang et al., 2021)

Nota. Datos tomados de (Sanida et al., 2023), (Siedliska, et al., 2018), (Sun, et al., 2017), (Zhang, et, al., 2021).

La anterior tabla (Tabla 2) muestra con más detalle las técnicas más comúnmente utilizadas para detectar anomalías o enfermedades en cultivos y su nivel de efectividad en este proceso.

Para determinar esta efectividad, se tuvo en cuenta el rendimiento resultante de cada uno de los estudios presentados a continuación (Evaluación de desempeño):

De la misma manera, se revisaron las arquitecturas más utilizadas en el ámbito de las CNNs, dado que, estas poseen demasiada relevancia a la hora de aplicar una CNN a un problema en específico, ya que son estructuras prediseñadas sobre las cuales se puede dar solución a dicho problema. Es importante destacar que los porcentajes mostrados en estos estudios dependen del dataset empleado en el entramiento de cada uno, Sin embargo, entre las arquitecturas evaluadas, EfficientNetB7 ha demostrado un mejor rendimiento en términos de eficiencia en el uso de recursos y precisión en la clasificación. (Naman Mishra, et al., 2023, pp. 1-5)

Tabla 2

Arquitecturas de inteligencia artificial más frecuentemente utilizadas

Arquitectura AI	Objetivo	Evaluación de desempeño	Referencia
EfficientNet-B7	Reconocimiento basado en imágenes de instrumentos quirúrgicos	Precisión del 99.99%	(Lehr, et al., 2023)
AlexNet	Detección y clasificación de enfermedades en las hojas de tomate.	Precisión promedio del 98%.	(Chen H, et al., 2022)
GoogleNet	Clasificación de enfermedades en plantas de tomate.	Precisión del 99.72%.	(Maeda-Gutiérrez, et al., 2020)

Densenet_Xception	Clasificación de enfermedades del tomate.	Precisión del 97.10%	(Hong H, et al., 2020)
ResNet and Xception	Identificación temprana de la pudrición en las hojas de tomate.	Precisión del 99,952%	(Chakravarthy & Raman, 2024)
VGG16	Detección de defectos en los frutos de tomate.	Precisión del 98.75%	(Robert de Luna, et al., 2019)

Nota. Datos tomados de (Lehr, et, al., 2023), (Chen H, et al., 2022), (Maeda-Gutiérrez, et al., 2020), (Hong H, et al., 2020), (Chakravarthy & Raman, 2024, pp. 154-158), (Robert de Luna, et al.,2019, pp. 356-361).

En la anterior tabla (Tabla 3) se muestran algunos de los trabajos más relevantes sobre el uso de arquitecturas CNN.

4.1.2 Estudios que validan la implementación de CNN y ANN para la detección temprana de enfermedades en cultivos de tomate

El avance de la tecnología ha tenido un gran impacto en todos los ámbitos de la vida humana, ha llevado a grandes logros, hitos o simplemente cosas no tan útiles, pero no se puede negar que gracias a ella se ha determinado de una manera más rápida y eficiente la comprensión del mundo, de la vida y de lo que nos rodea. Es precisamente este concepto de velocidad el que ha llevado al uso generalizado de CNNs y ANNs en la actualidad. En la agricultura, las personas que dependen de ella para su sustento necesitan garantías de que sus cultivos producirán los

beneficios esperados, y eso significa asegurar que el cultivo se mantenga saludable durante todo el proceso de plantación, cultivo y cosecha. De lo contrario, la calidad, la producción y la rentabilidad de los agricultores se verán comprometidas (Maeda-Gutiérrez, et al, 2020). Por esta razón, varios estudios validan que la implementación de CNNs y RNAs ha ayudado a mantener la calidad de los cultivos y mejorar la calidad de vida de los agricultores. En la Tabla 4 se muestran algunos de estos estudios que corroboran el éxito de la implementación de las herramientas en el cultivo de tomate.

Tabla 3

Estudios que validan la implementación de CNN y ANN para la identificación temprana de enfermedades en cultivos de tomate

Artículo	Referencia
Detección de enfermedades en las hojas de tomate utilizando el modelo híbrido CNN-RNN.	(Hepzibah Elizabeth David, et al., 2021, pp. 593-597),
Comparación de arquitecturas de redes neuronales convolucionales para la clasificación de enfermedades en plantas de tomate.	(Maeda-Gutiérrez, et al., 2020)
Identificación de tipos de enfermedades del tomate y detección de áreas infectadas usando redes neuronales convolucionales profundas y técnicas de detección de objetos.	(Wang, et al., 2019)
Un enfoque híbrido para la detección y clasificación de enfermedades en las hojas de tomate.	(Altalak, et al., 2022)
Un sistema de visión por computadora para la discriminación y clasificación de defectos en tomates mediante aprendizaje automático y procesamiento de imágenes.	(Ireri, et al., 2019)

ToLeD: Detección de enfermedades en las hojas de tomate utilizando una red neuronal convolucional.	(Agarwal, et al., 2020)
Predicción del rendimiento de enfermedades en las hojas de tomate utilizando una serie de redes neuronales convolucionales en paralelo.	(Islam, et al., 2022)
Detección de enfermedades en tomates basada en aprendizaje profundo.	(J, S. A, et al., 2021)
Redes múltiples colaborativas auto-supervisadas para la categorización visual detallada de enfermedades en tomates.	(Yang, et al., 2020)
Clasificador híbrido SVM-LR para la predicción de la enfermedad del powdery mildew en plantas de tomate.	(Bhatia, et al., 2020)
Identificación temprana de la pudrición en hojas de tomate mediante aprendizaje profundo.	(Chakravarthy, et al., 2020)
Conjunto de datos de imágenes de frutos de tomate para la detección de defectos basada en aprendizaje por transferencia profunda.	(Roberth de Luna, et al., 2019)

Nota. Datos tomados de (David, et al., 2021, pp. 593-597), (Maeda-Gutiérrez, et al., 2020), (Wang, et al., 2019) (Maha Altalak, et al., 2022), (David Ireri, et al., 2021, pp. 301-302), (Mohit Agarwal, et al., 2020, pp. 293-301), (M.P. Islam, et al., 2022), (Goufeng Yang, et al., 2024) , (Anshul Bathia, et alt., 2024, pp. 218-223), (Chakravarthy & Raman, 2024, pp. 154-158), (Robert de Luna, et al.,2019, pp. 356-361).

4.1.3 Impacto que ha obtenido la implementación de CNN y ANN en el sector agrícola

La implementación de CNN y ANN ha generado un extenso y profundo campo de investigación en relación con la identificación temprana de enfermedades en los cultivos agrícolas. A lo largo de los últimos años, numerosos investigadores y científicos han dedicado sus esfuerzos a explorar cómo estas técnicas avanzadas de aprendizaje automático pueden ser

aplicadas para abordar uno de los desafíos más apremiantes en la agricultura: la detección oportuna y precisa de enfermedades que afectan los cultivos.

Los resultados de esta investigación han sido reveladores, ya que varios estudios independientes han corroborado la eficacia significativa de las redes neuronales convolucionales y artificiales en la detección temprana de enfermedades en plantas de tomate. Estas técnicas han demostrado no solo la capacidad de identificar con precisión enfermedades incluso en sus primeras etapas, sino también la capacidad de diferenciar entre plantas sanas y afectadas con una tasa de éxito impresionante.

En este sentido, se puede observar la importancia de la implementación de las CNN y ANN en la identificación temprana de enfermedades, debido a que, si se detecta a tiempo una enfermedad, directamente también se puede aumentar la tasa y la calidad de la producción. (Kyamelia Roy, et al., 2023, pp. 14983-15001)

De la misma manera, es imprescindible recordar que en el cultivo de tomate suelen aparecer muchas enfermedades, debido a cambios climáticos, calidad del suelo, cantidad de luz solar, etc. Es por eso, que la visión por computadora, es decir, el procesamiento de imágenes, hecho posible por el aprendizaje profundo es una herramienta de gran ayuda para el diagnóstico de enfermedades asistidas por cámara para el cultivo de tomate. (Robert de Luna, et al., 2019, pp. 1414-1419)

Por otra parte, en muchas partes de Colombia es muy normal ver que todavía los agricultores están utilizando los métodos tradicionales, para realizar procesos en la agricultura que hoy en día podrían realizarse por medio de la utilización de la tecnología. Evitando así posibles retrasos, tanto en el proceso de siembra como en el de recolección, además, estas prácticas tradicionales podrían implicar el uso de recursos humanos innecesarios para manejar los diversos procesos agrícolas, la falta de información precisa sobre el clima, las condiciones del suelo y el uso de fertilizantes, un mayor tiempo y esfuerzo para monitorear manualmente la salud de los cultivos y la identificación de enfermedades, aumento en la mano de obra para la identificación y el control de malezas y por último la aplicación de malas prácticas en el almacenamiento de los alimentos cosechados, que pueden llevar a su degradación y posterior pérdidas. (Manas Wakchaure, et al., 2023)

Es por eso, que se hace evidente la necesidad de utilizar tecnologías vanguardistas, tales como las CNN y ANN que faciliten el proceso de identificación y clasificación de las enfermedades en los cultivos, en este caso en el de tomate. El impacto obtenido por estas herramientas es visiblemente observable en los niveles de producción alcanzados a la hora de cosechar tales cultivos. (Akbar Hidayatuloh, et al., 2021, pp. 199-204)

4.1.4 Factores que contribuyen a la adquisición de enfermedades en los cultivos de tomates

La propagación de enfermedades en las plantas de tomate se ve muy influenciada por el clima y las condiciones de cuidado de estas, lo que las hace más propensas a adquirir patógenos que afecten su estado. Estas condiciones no solo influyen en el crecimiento del cultivo

sino también en su capacidad para resistir infecciones. De hecho, para que estas enfermedades se produzcan o manifiestes deben existir ciertos factores que favorezcan la proliferación de las mismas, los cuales son: enfermedad virulenta, planta susceptible y ambiente favorable (Giorgini & Buono, 2012), siendo este último un ambiente favorable para el desarrollo de la enfermedad y no de la planta como tal.

Por otra parte, Jaramillo Noreña, et al. (2012) afirma que "Entre los principales factores ambientales que influyen en la manifestación de enfermedades se encuentran la temperatura, la humedad relativa, la ventilación y la luminosidad".

La temperatura juega un papel crucial en el crecimiento y los procesos fisiológicos de la planta. El rango térmico adecuado dentro del invernadero es crucial para el correcto desarrollo de la misma, desde la fase de germinación hasta la maduración del fruto. Las fluctuaciones extremas de temperatura pueden crear ambientes que son propicios para la aparición de enfermedades. Si las temperaturas son mayores de 30 ºC y menores de 10 ºC puede producir que los frutos se vuelvan amarillos y hacer que las plantas sean más propensas a enfermarse o tener problemas. (Jaramillo Noreña, et al., 2012)

La humedad relativa influye significativamente en el bienestar de los cultivos de tomate. Las mejores condiciones para su crecimiento son entre 50% y 65% de humedad, debido a que demasiada humedad puede favorecer el crecimiento de hongos dañinos como Botrytis cinerea y Phytophthora infestans (Jaramillo Noreña, et al., 2012). Demasiada humedad puede provocar problemas como grietas en las frutas y polen muy compacto, lo que dificulta la

reproducción de las plantas y hace que las flores caigan. Cuando el aire está seco, las plantas pierden agua más rápido, lo que puede perjudicar su proceso de producción de alimentos y hacer que a las plantas les resulte difícil producir semillas.

En este sentido, la ventilación está directamente relacionada con el manejo de los niveles de humedad interna dentro de un invernadero. Un sistema de ventilación eficaz ayuda a detener la propagación de enfermedades causadas por hongos y bacterias, como las de los flujos de aire cálido y húmedo. En climas húmedos, un flujo de aire insuficiente puede hacer que las hojas pierden menos agua y ejercen demasiada presión sobre los frutos, lo que podría hacer que se partan (Jaramillo Noreña, et al., 2012). Los cortavientos, ya sean hechos de árboles o estructuras artificiales, ayudan a proteger las plantas de los fuertes vientos y mantienen la cantidad adecuada de humedad en el aire, lo que ayuda a mantener el invernadero a una buena temperatura.

Finalmente, la luz juega un papel clave en la fisiología del tomate. La radiación solar juega un papel fundamental en el proceso de fotosíntesis, que es esencial para el crecimiento de las plantas y la producción de biomasa. La duración de la luz solar cada día no afecta mucho a los tomates. pero una luz más débil puede provocar la aparición de enfermedades y una peor calidad, lo que da como resultado tomates huecos y descoloridos. (Jaramillo Noreña, et al., 2012)

4.1.5 Enfermedades que están afectando actualmente a los cultivos de tomate

Según el autor Mohit Agarwal, et al. (2020), “El tomate es uno de los cultivos más populares del mundo, ocupando un lugar fundamental en la gastronomía de prácticamente todas las personas”. Por esta razón, es muy importante mantener la calidad de este producto, y una de las fases en las que es necesario tener un mayor control es en el crecimiento, ya que, si las enfermedades logran matar la planta o, peor aún, el fruto, no habrá producción ni ganancia para los agricultores, ni alimento para los consumidores, en este sentido, la detección precoz de enfermedades que afectan al cultivo es muy importante (Hong H. L., et al., 2020, pp. 25-29). Algunas de las enfermedades que afectan con mayor frecuencia al cultivo de tomate son la enfermedad por el virus del tomate, el tizón tardío del tomate, el moho gris, la mancha bacteriana y el virus del enrollamiento amarillo de la hoja, entre otras. (Chang Xu, et al., 2022)

Ahora, con el fin de tener una comprensión más realista de las enfermedades que actualmente están afectando al cultivo de tomate, se ha diseñado y aplicado un instrumento de medición en las zonas rurales de Llano del Pozo, San Javier, y El Campanario, ubicadas en el municipio de Abrego, Norte de Santander, Colombia. Con base en lo anterior, se aplicó el instrumento de medición a 42 agricultores, en el cual se presentaron una serie de síntomas de algunas enfermedades del cultivo de tomate. Cada uno de los agricultores procedió a seleccionar la frecuencia con la que observaban estas enfermedades en sus cultivos, utilizando una escala de frecuencia tipo Likert con 5 niveles (Muy frecuentemente, Frecuentemente, Ocasionalmente, Rara vez y Nunca) (Ver apéndice A). Para tener en cuenta la enfermedad y seleccionarla en este estudio, se tuvieron en cuenta los grados de frecuencia con que los agricultores han observado

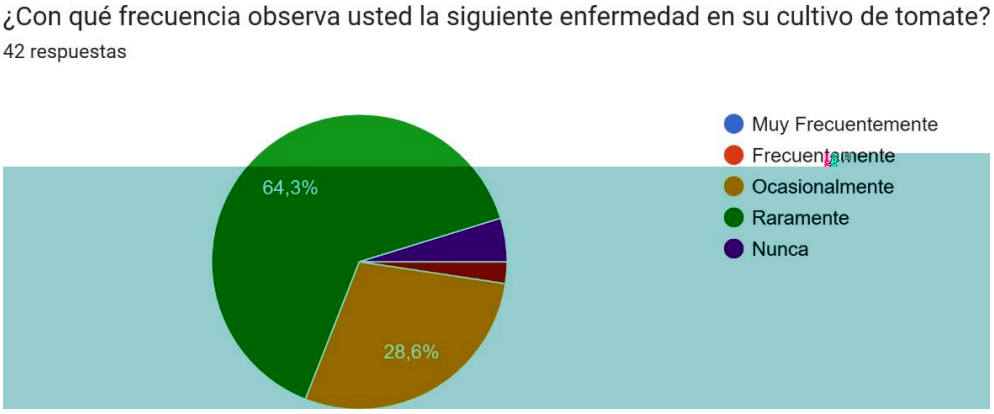
los tipos de enfermedades propuestos en cada uno de sus cultivos, tomando como referencia aquellas donde las sumas de los resultados de Muy Frecuentemente y Frecuentemente superan el 50%.

4.1.5.1 Resultados del instrumento de medición. Teniendo en cuenta el instrumento de medición aplicado, a continuación, se detallan los porcentajes obtenidos por cada una de las preguntas planteadas en el mismo.

4.1.5.1.1 Alternaria. La mayoría de los agricultores (64.3%) indicaron que observan esta enfermedad "Raramente", mientras que el 28.6% la observa "Ocasionalmente". Solo un 2.4% la considera "Frecuente", lo que indica que no es una enfermedad predominante en la región.

Figura 2

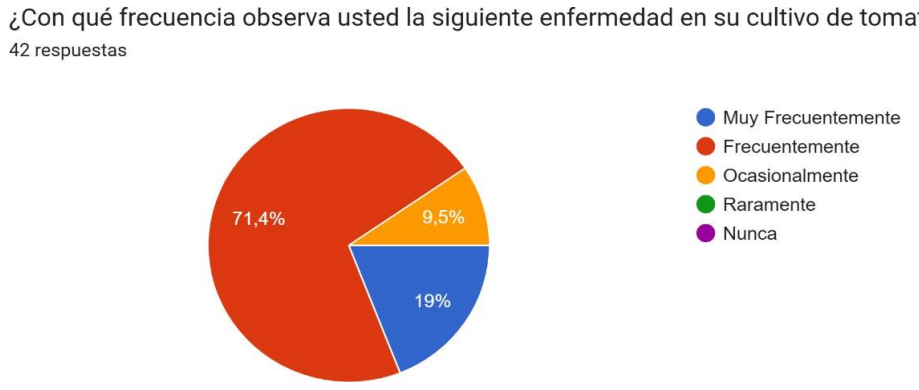
Frecuencia de Alternari en cultivos de tomate



4.1.5.1.2 Mancha bacteriana. Esta enfermedad presenta una alta incidencia, con un 71.4% de los encuestados afirmando que la observan "Frecuentemente" y un 19% "Muy frecuentemente", lo que la posiciona como una de las enfermedades más comunes.

Figura 3

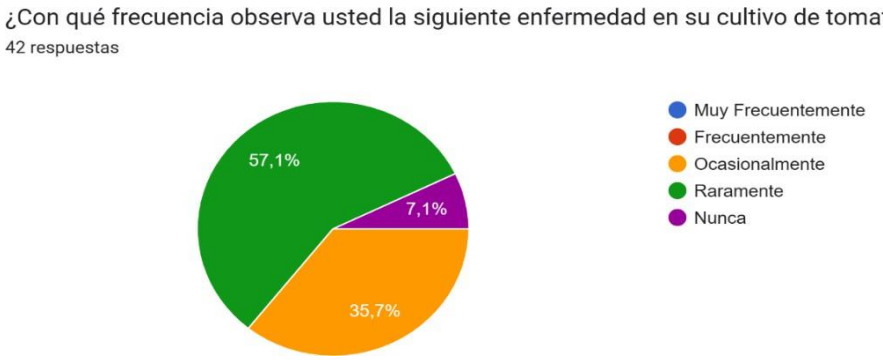
Frecuencia de Mancha Bacteriana en cultivos de tomate



4.1.5.1.3 Botritis. La incidencia de esta enfermedad es moderada, con un 57.1% de respuestas en "Raramente" y un 35.7% en "Ocasionalmente", mientras que no se reportaron casos "Frecuentes" o "Muy frecuentes".

Figura 4

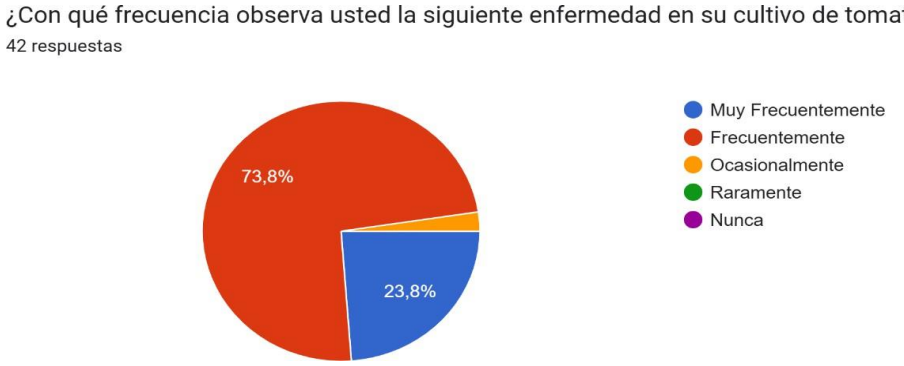
Frecuencia de Botritis en cultivos de tomate



4.1.5.1.4 Mancha foliar Causada por Septoria. Se observa con alta frecuencia en los cultivos, con un 73.8% de respuestas en "Frecuentemente" y un 23.8% en "Muy frecuentemente", lo que indica una gran afectación en la zona.

Figura 5

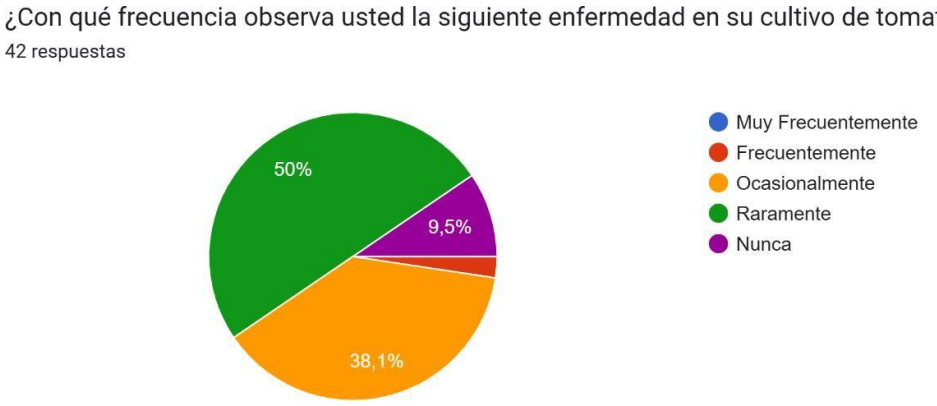
Frecuencia de La Mancha foliar causada por Septoria en cultivos de tomate



4.1.5.1.5 Marchitez del tomate. La mayoría de los agricultores (50%) reportaron que observan esta enfermedad "Raramente", mientras que un 38.1% la observa "Ocasionalmente", reflejando una presencia limitada en los cultivos.

Figura 6

Frecuencia de Marchitez del tomate en cultivos de tomate



4.1.5.1.6 Tizón Tardío. Esta enfermedad es bastante común, reflejando un 64.3% de agricultores que la observan "Frecuentemente" y un 23.8% "Muy frecuentemente".

Figura 7

Frecuencia de Tizón Tardío en cultivos de tomate



4.1.5.1.7 Tizón Temprano. De manera similar, el tizón temprano también tiene una alta incidencia, con un 66.7% de respuestas en "Frecuentemente" y un 21.4% en "Muy frecuentemente".

Figura 8

Frecuencia de Tizón Temprano en cultivos de tomate



4.1.5.1.8 Mildiu. Esta enfermedad también es recurrente, con un 64.3% de agricultores indicando como "Frecuente" y un 19% como "Muy frecuente".

Figura 9

Frecuencia de Mildiu en cultivos de tomate



4.1.5.1.9 Virus del enrollamiento amarillo de las hojas. Este virus tiene una alta incidencia, con un 47.6% de respuestas en "Frecuentemente" y otro 47.6% en "Muy frecuentemente", confirmando su impacto en los cultivos.

Figura 10

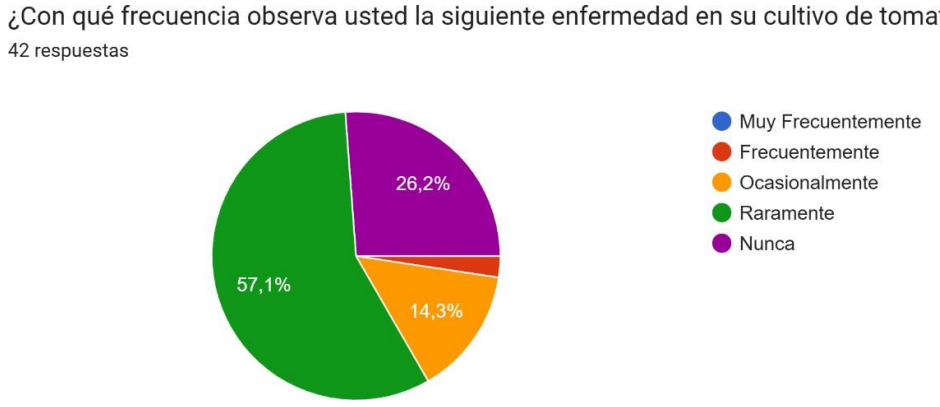
Frecuencia de Virus del enrollamiento amarillo de las hojas en cultivos de tomate



4.1.5.1.10 Podredumbre apical del tomate. Presenta una baja incidencia, con un 57.1% de respuestas en "Raramente" y un 26.2% en "Nunca", lo que sugiere que no es un problema grave en la región.

Figura 11

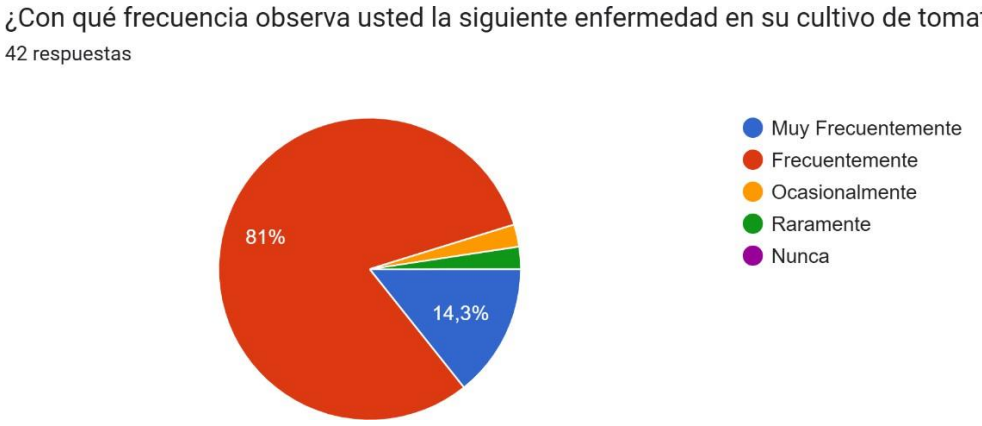
Frecuencia de Podredumbre apical en cultivos de tomate



4.1.5.1.11 Virus del Mosaico. Es una de las enfermedades más comunes en los cultivos, con un 81% de respuestas en "Frecuentemente" y un 14.3% en "Muy frecuentemente".

Figura 12

Frecuencia de Virus del Mosaico en cultivos de tomate

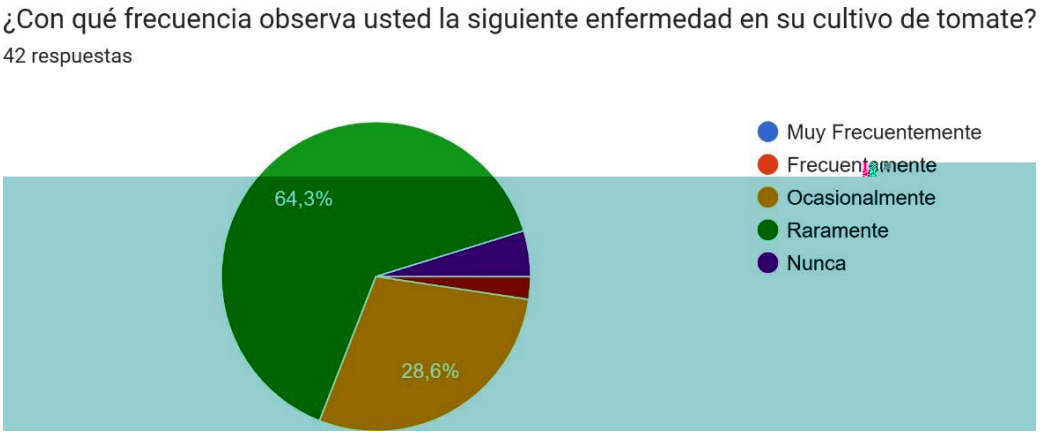


Virus rugoso del tomate

La mayoría de los agricultores (64.3%) reportaron que lo observan "Raramente", mientras que un 28.6% lo ha visto "Ocasionalmente", indicando una baja prevalencia.

Figura 13

Frecuencia del Virus rugoso del tomate



Como resultado del instrumento de medición aplicado, se identificaron las enfermedades que más afectan al cultivo de tomate en las zonas rurales del municipio de Abrego Norte de Santander; Colombia, teniendo como referencia veredas como Llano del Pozo, San Javier, y El Campanario. (ver Fig. 4 y Tabla 5).

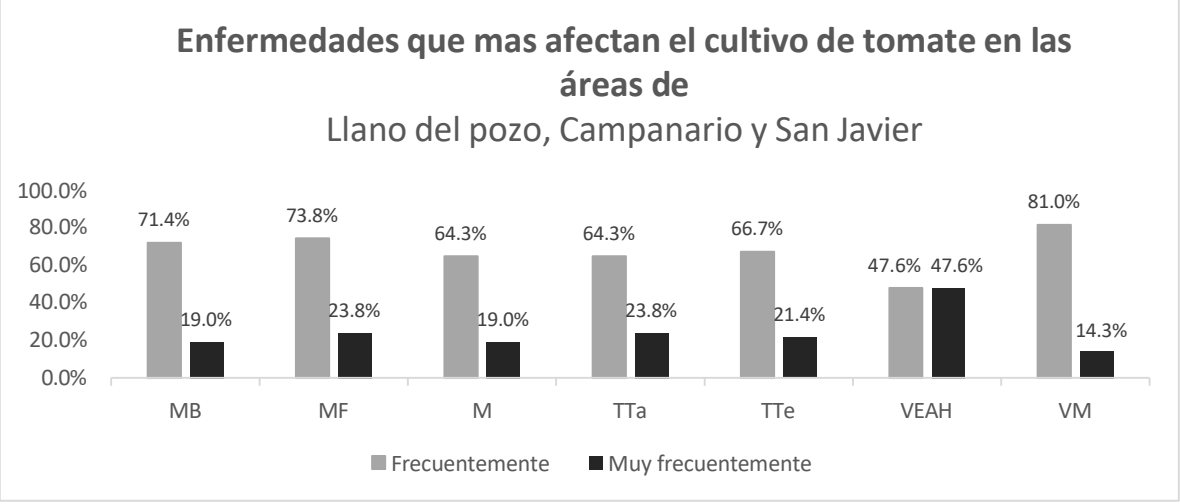
Tabla 4

Significado de las siglas correspondientes a cada enfermedad detectada en el estudio realizado en las zonas rurales del municipio de Abrego, Norte de Santander

Acrónimo de la enfermedad	Nombre de la enfermedad
MB	Mancha Bacteriana
MF	Mancha Foliar causada por septoria
M	Mildiu
TTA	Tizón Tardío
TTE	Tizón Temprano
VEAH	Virus del Enrollamiento Amarillo de las Hojas
VM	Virus del Mosaico

Figura 14

Enfermedades que más afectan al cultivo de tomate en las zonas rurales del municipio de Abrego (Llano del Pozo, San Javier y El Campanario)



4.2 Diseñar un sistema basado en conocimiento para la correcta detección e identificación de enfermedades que afectan al cultivo de tomate

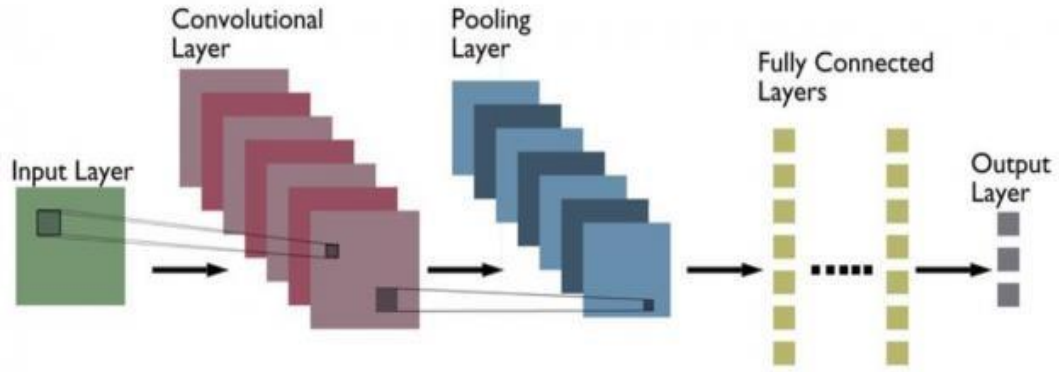
4.2.1 Modelo y arquitectura de red neuronal utilizado para el procesamiento de imágenes

Según Gattu Anwesh (2024) “En el desarrollo de este proyecto se hace uso de CNN, las cuales son un algoritmo de aprendizaje profundo especializado, utilizadas principalmente para reconocimiento y clasificación de imágenes”. Este tipo de redes se diferencian de las ANN, en que agregan una capa adicional de complejidad en la que hacen uso de capas convolucionales, las cuales realizan operaciones matemáticas avanzadas, que son multiplicaciones de matrices tomando en cuenta el conjunto de datos de entrada. Estas operaciones convolucionales permiten conservar la correlación espacial que existe entre los píxeles, aprendiendo características existentes en la imagen, sobre los cuales se usan cuadriculas de datos de entrada (Kumar, 2024).

Ese es el funcionamiento por el que se caracteriza una CNN, como se muestra a continuación:

Figura 15

Arquitectura Tradicional de una CNN



Nota. Diseño tomado Por (Kumar, 2024)

Teniendo en cuenta el análisis realizado en el resultado anterior, acerca del nivel precisión de diferentes arquitecturas de CNN, siendo la EfficientNetb7 la que brinda muy buenos resultados, se optó por utilizar esta arquitectura, dado que los resultados de precisión y eficiencia computacional que se pueden obtener a la hora de clasificar imágenes son demasiado altos, debido a su novedoso enfoque de escalamiento compuesto, en el cual se ajustan paralelamente las tres dimensiones del modelo (profundidad, ancho y resolución).

4.2.1.1 Profundidad (d). Esta dimensión se refiere al número de capas o niveles de la red. Es decir, que si se aumenta esta dimensión la red es capaz de aprender representaciones complejas o abstractas en los datos ingresados.

4.2.1.2 Ancho (w). Esta dimensión es la cantidad de neuronas que tiene la red en cada capa, es decir, que un aumento en el ancho del modelo significa que se tiene mayor capacidad de

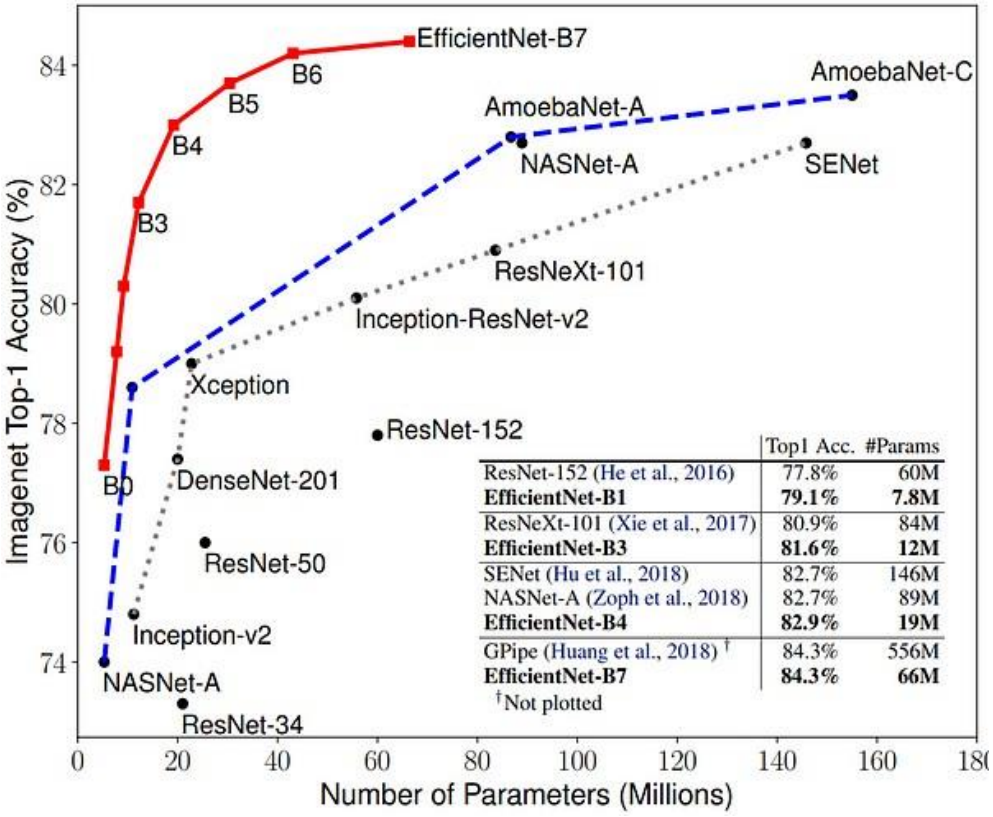
aprendizaje y almacenamiento de representaciones de los datos, aunque esto también implica un mayor uso de memoria y cómputo.

4.2.1.3 Resolución (r). Esta última dimensión se refiere al tamaño de la imagen que se brinda como entrada a la red. Una mayor resolución indica que la red puede aprender o identificar más detalles de la imagen, pero también implican un mayor tiempo de procesamiento de la misma.

En relación con lo anterior, Este tipo de escalamiento resultó ser el mejor en precisión para las ImageNet, obteniendo un 84.3%". Para obtener dichos resultados, se debe realizar un ajuste proporcional de las tres dimensiones del modelo, con el fin de lograr un equilibrio entre ellas y poder maximizar el rendimiento y disminuir el costo computacional asociado a las operaciones realizadas por dicho modelo. De hecho, EfficientNet-B7 logró resultados excepcionales en comparación con otras arquitecturas con un menor uso de recursos, como, por ejemplo, ResNet-200 o GPipe, logrando ser hasta 8,4 veces más pequeño y 6,1 veces más rápido que este último. (Mingxing Tan & Quoc Le, 2019, pp. 6105-6114)

Figura 16

Tamaño y rendimiento de EfficientNet en el conjunto de datos de ImageNet

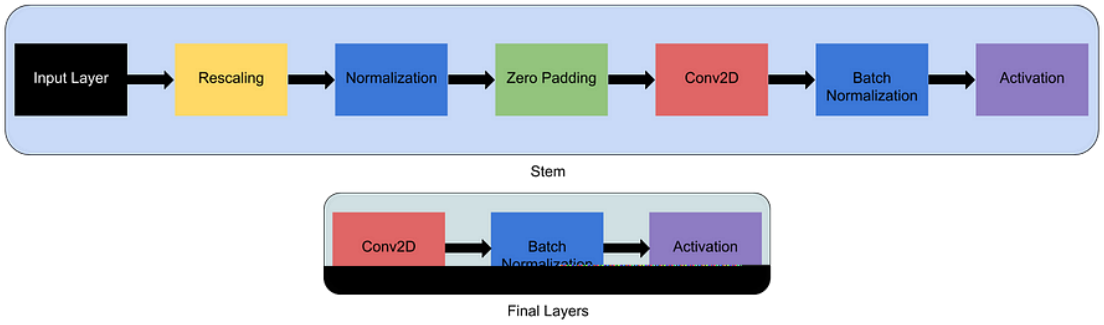


Nota. Imagen tomada según (Mingxing Tan & Quoc Le, 2019)

Para poder lograr los niveles de eficiencia con los que actualmente cuenta la EfficientNet-B7, se partió a partir de la base de todas las CNN, y a partir de ahí se fueron realizando las optimizaciones pertinentes, usando bloques y módulos repetidos con el enfoque de escalamiento compuesto.

Figura 17

Capa base para el diseño de una arquitectura de ImageNet

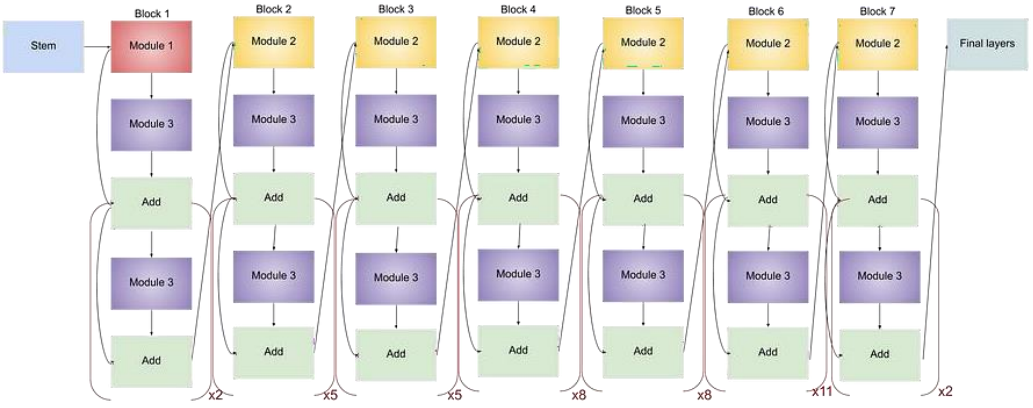


Nota. Datos tomados según autor (Joonho Oh, et al., 2023)

La anterior figura (Figura 17), sirvió como base para realizar la arquitectura de EfficientNetb7, la cual consta de bloques y sud-bloques, los cuales son equivalentes a las capas, neuronas, funciones de activación y operaciones de convolución aplicadas en dichas capas, para realizar el procesamiento adecuado de las imágenes como se puede ver a continuación.

Figura 18

Arquitectura de EfficientNetb7l



Nota. Datos obtenidos según (Mohammad Amimul Ihsan Aquil, 2023, pp. 467-475)

En el diagrama anterior se pueden observar una serie de bloques, los cuales, permiten un procesamiento jerárquico de las imágenes, con el fin de obtener las características necesarias, para lograr una correcta clasificación.

Inicialmente, se puede observar el “Stem”, que es donde se realizan las primeras operaciones convolucionales sobre la imagen que se ingrese en un momento dado, con el objetivo de determinar las características básicas de todas las imágenes como bordes, texturas, patrones, etc.

Seguidamente, en el bloque número 1 se aplican operaciones más complejas, para obtener características más detalladas de la imagen, también se realiza un aumento en el número de filtros, los cuales permiten captar más información relevante. La información de salida de este bloque sirve como entrada para los bloques siguientes. En los demás bloques, se siguen

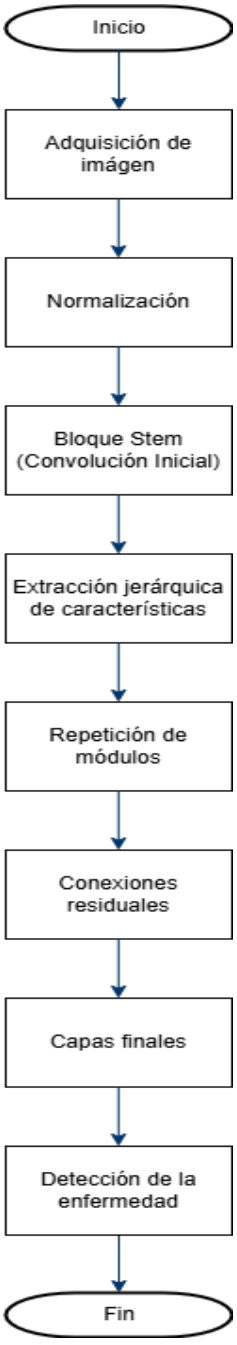
realizando operaciones complejas y repeticiones que permitan ajustar los resultados del aprendizaje de las características de la imagen, las cuales se someten a rotaciones o deformaciones, que permitan evitar el sobreajuste o predicciones no deseadas, por no haber observado las imágenes de entrenamiento desde diferentes “ángulos”.

Por último, se encuentran las capas finales, en las cuales se realiza un aplanamiento (flatten), para convertir las características que aprendió la red en los pasos anteriores en probabilidades de clase, para proporcionar una predicción, dependiendo de la etiqueta que cuente con mayor probabilidad de ser la correctamente identificada en el proceso. Teniendo en cuenta todo lo mencionado anteriormente, se procedió a hacer uso de esta arquitectura de red neuronal (EfficientNetB7), la cual se alinea con los objetivos de este trabajo, los cuales buscan la identificación precisa de las enfermedades que atacan el cultivo de tomate. Además, la eficiencia que proporciona esta red permite realizar los cálculos necesarios para procesar y determinar si las enfermedades utilizadas en este proyecto se encuentran presentes en las hojas del cultivo de tomate.

4.2.2 Arquitectura de red neuronal utilizada en TAIGRO

Figura 19

Red neuronal utilizada en TAIGRO



4.2.2.1 Uso de la metodología ágil SCRUM. El uso de la metodología ágil SCRUM en el desarrollo de proyectos tecnológicos ha ganado gran relevancia debido a su capacidad para gestionar de manera eficiente la complejidad y la incertidumbre inherente a estos proyectos. SCRUM, como se detalla en la Guía SBOK™ de SCRUMstudy (3ra edición), es un marco ágil que fomenta la colaboración, la flexibilidad y la entrega continua de valor, lo que lo convierte en una opción ideal para el desarrollo de software y productos innovadores. (Tridibesh Satpathy, 2017)

Este proyecto ha seguido las recomendaciones brindadas en la Guía SBOK™ las cuales detallan como debe darse inicio, seguimiento y finalización de un proyecto.

4.2.3 Inicio del Proyecto según la Guía SBOK™

4.2.3.1 Crear la Visión del Proyecto. Este proceso fue fundamental para establecer un objetivo claro y alineado con las necesidades de los agricultores.

Tabla 5

Visión del Proyecto

VISIÓN DEL PROYECTO
TAIGRO será una herramienta móvil que permitirá a los agricultores enfrentar el desafío creciente de detectar y gestionar enfermedades en los cultivos de tomate de manera eficiente. Esta aplicación se enfocará en proporcionar un diagnóstico temprano y preciso basado en el análisis de imágenes, permitiendo a los agricultores identificar problemas en las hojas de tomate antes de que se conviertan en amenazas para el cultivo. El objetivo de TAIGRO será empoderar a los agricultores con una solución accesible, que les permita actuar rápidamente para minimizar el impacto de las enfermedades y mejorar la sostenibilidad y productividad de sus cultivos. TAIGRO busca transformar la manera en que los agricultores gestionan la salud de sus cultivos, ofreciendo una solución tecnológica confiable y accesible, sin requerir conocimientos técnicos avanzados ni equipos costosos. El foco estará en proporcionar a los agricultores una herramienta flexible y adaptable que les permita tomar decisiones informadas para proteger sus cultivos y asegurar una mayor eficiencia en su trabajo diario.

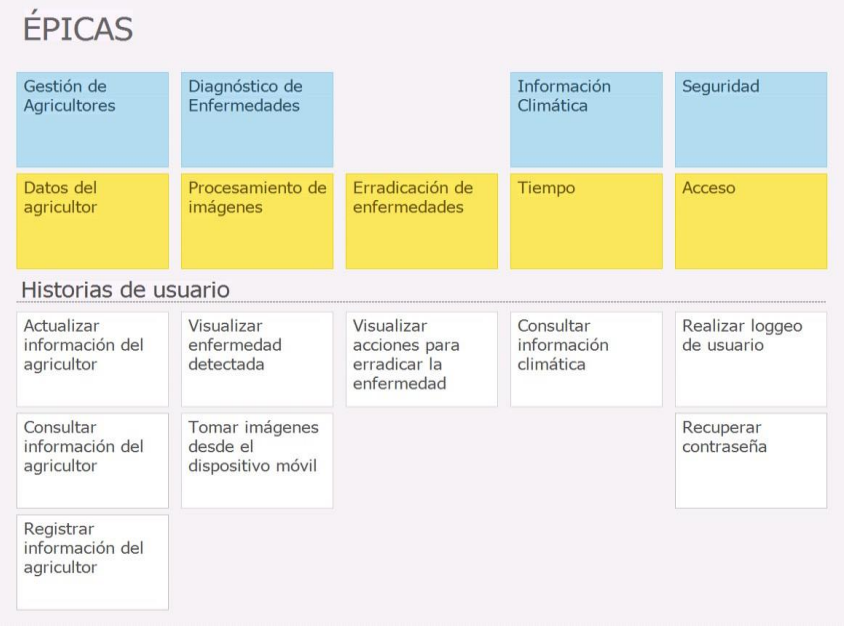
4.2.3.2 Identificar al Scrum Master y Stakeholders. De acuerdo con la Guía SBOK™, identificar al Scrum Master y a los stakeholders es crucial para el éxito del proyecto. Josué Campo asumió el rol de Scrum Master, facilitando el proceso y asegurando el cumplimiento de las prácticas SCRUM. Los agricultores locales fueron identificados como stakeholders clave, dado su rol en proporcionar retroalimentación sobre los requisitos y la funcionalidad del producto.

4.2.3.3 Formar el Equipo SCRUM. Conforme a la Guía SBOK™, el equipo SCRUM debe estar compuesto por profesionales multifuncionales y autónomos. En este proyecto, el equipo estuvo formado por dos miembros: Josué Campo y Yeison Danuil. Este equipo reducido permitió una mayor cohesión y comunicación directa, factores clave para el éxito del proyecto.

4.2.3.4 Desarrollar Épicas. El desarrollo de épicas se llevó a cabo utilizando la visión del proyecto como base. Las épicas principales se centraron en “Gestión de agricultores”, “Diagnóstico de enfermedades”, “Información climática” y “Seguridad”. Estas épicas fueron descompuestas en historias de usuario para facilitar su desarrollo iterativo.

Figura 20

Épicas



4.2.3.5 Crear el Backlog Priorizado del Producto. Según la Guía SBOK™, el Backlog Priorizado del Producto es una lista ordenada de todo lo que podría ser necesario en el producto. Se desarrolló un backlog priorizado, donde las historias de usuario fueron organizadas para su respectiva gestión (Ver apéndice B).

Tabla 6

Requerimientos funcionales

Código	Descripción
RF1	Permitir a los usuarios registrar su información personal.
RF2	Validar que todos los campos obligatorios estén completos antes de guardar la información.
RF3	Almacenar correctamente la información ingresada en la base de datos.
RF4	Enviar un código de activación de la cuenta al correo electrónico registrado tras el éxito del registro.
RF5	Mostrar mensajes de error si los datos ingresados están incompletos o no cumplen con los criterios.
RF6	Permitir a los usuarios consultar la información personal almacenada.
RF7	Mostrar los datos de manera clara y organizada.
RF8	Garantizar que la información mostrada sea consistente con la base de datos.
RF9	Permitir a los usuarios actualizar su información personal.
RF10	Validar los campos antes de guardar los cambios.
RF11	Mostrar una confirmación al actualizar exitosamente.
RF12	Mostrar mensajes de error en caso de fallo de conexión o datos no válidos.
RF13	Integrar la funcionalidad de cámara para permitir a los usuarios tomar imágenes de las hojas de tomate.
RF14	Mostrar un mensaje de espera mientras se procesa la imagen.
RF15	Permitir retomar la foto si no se procesa correctamente.

RF16	Mostrar mensajes claros en caso de errores durante el procesamiento de la imagen.
RF17	Mostrar el diagnóstico de la enfermedad detectada en la hoja, incluyendo nombre y descripción de la enfermedad o indicar que está sana.
RF18	Proporcionar una imagen de referencia asociada a la enfermedad detectada.
RF19	Mostrar una lista de recomendaciones claras y detalladas para erradicar la enfermedad detectada.
RF20	Permitir a los usuarios consultar información climática actualizada en tiempo real.
RF21	Mostrar predicciones del clima para un número determinado de días futuros.
RF22	Validar usuario y contraseña al iniciar sesión.
RF23	Mostrar mensajes de error si las credenciales son incorrectas o el usuario no está registrado.
RF24	Redirigir al usuario al dashboard tras iniciar sesión correctamente.

Tabla 7

Requerimientos no funcionales

Ítem	Descripción
Seguridad	Implementar encriptación para la protección de datos sensibles como contraseñas y datos personales. Garantizar que solo usuarios autenticados puedan acceder a información sensible.
Usabilidad	Diseñar una interfaz de usuario intuitiva y fácil de usar para todas las funcionalidades. Proporcionar mensajes de error claros y útiles para guiar a los usuarios en caso de errores.
Rendimiento	Asegurar tiempos de respuesta rápidos, especialmente para funciones críticas como el inicio de sesión y la consulta de información climática. Optimizar el procesamiento de imágenes para minimizar el tiempo de espera.
Disponibilidad	Garantizar una disponibilidad del sistema del 99.9% para asegurar que los usuarios puedan acceder a la aplicación en cualquier momento.
Compatibilidad	Integrar correctamente con servicios de terceros como APIs climáticas y servicios de correo electrónico.

Historias de usuario

Tabla 8

Historia de usuario de registro de información personal.

Historia	Registro de Información Personal
Descripción	Como agricultor, quiero registrar mi información personal, para tener un perfil personalizado que permita el acceso a funcionalidades del sistema.
Criterios de Aceptación	
La información ingresada debe almacenarse correctamente en la base de datos. Debe haber validación de campos obligatorios. Notificación de éxito al guardar los datos. En caso de éxito, enviar código de activación de la cuenta por correo electrónico. Mensaje de error en caso de datos incompletos.	

Tabla 9

Historia de usuario de consultar información personal registrada

Historia	Consulta de Información Personal
Descripción	Como agricultor, quiero consultar mi información registrada, para revisar mis datos o actualizarlos si es necesario.
Criterios de Aceptación	
Mostrar los datos almacenados de manera clara y organizada. Garantizar que los datos mostrados sean consistentes con la base de datos.	

Tabla 10

Historia de usuario de Actualizar información personal

Historia	**Actualización de Información personal**
Descripción	Como agricultor, quiero actualizar mi información, para mantener mis datos correctos y actualizados.
Criterios de Aceptación	
Los datos deben reflejarse inmediatamente después de actualizarlos.	
Validación de campos antes de guardar cambios.	
Mensaje de confirmación al actualizar exitosamente.	
Mensaje de error en caso de fallo en la conexión o datos no válidos.	

Tabla 11

Historia de usuario de captura de imágenes de hojas de tomate

Historia	**Captura de imágenes de hojas**
Descripción	Como agricultor, quiero tomar imágenes de las hojas de tomate desde el dispositivo móvil, para realizar un diagnóstico de la enfermedad del cultivo.
Criterios de aceptación	
La cámara del dispositivo debe abrirse correctamente desde la aplicación.	
Mensaje de espera mientras se procesa la imagen.	
Mostrar un mensaje claro si no se puede procesar la imagen.	
Permitir retomar la foto en caso de que no se haya procesado correctamente.	

Tabla 12

Historia de usuario de visualización de enfermedades

Historia	Visualización de Enfermedades
Descripción	Como agricultor, quiero visualizar la enfermedad detectada en la hoja, para conocer el estado de salud del cultivo y tomar medidas necesarias.
Criterios de aceptación	
Mostrar el diagnóstico con el nombre y descripción de la enfermedad o indicar que está sana. Proporcionar una imagen de referencia asociada a la enfermedad detectada.	

Tabla 13

Historia de usuario de acciones recomendadas

Historia	Acciones Recomendadas
Descripción	Como agricultor, quiero ver las acciones recomendadas para erradicar la enfermedad, para implementar las medidas correctivas y evitar la propagación de la enfermedad.
Criterios de aceptación	
Mostrar una lista de recomendaciones claras y detalladas, basadas en la enfermedad detectada.	

Tabla 14

Historia de usuario de consultar información climática

Historia	**Consulta de información climática**
Descripción	Como agricultor, quiero consultar información climática, para adaptar mis decisiones agrícolas en función de las condiciones climáticas.
Criterios de aceptación	
Visualizar datos climáticos precisos y actualizados en tiempo real. Permitir visualizar predicciones del clima en un número determinado de días futuros.	

4.2.4 Arquitectura utilizada para el desarrollo del aplicativo móvil

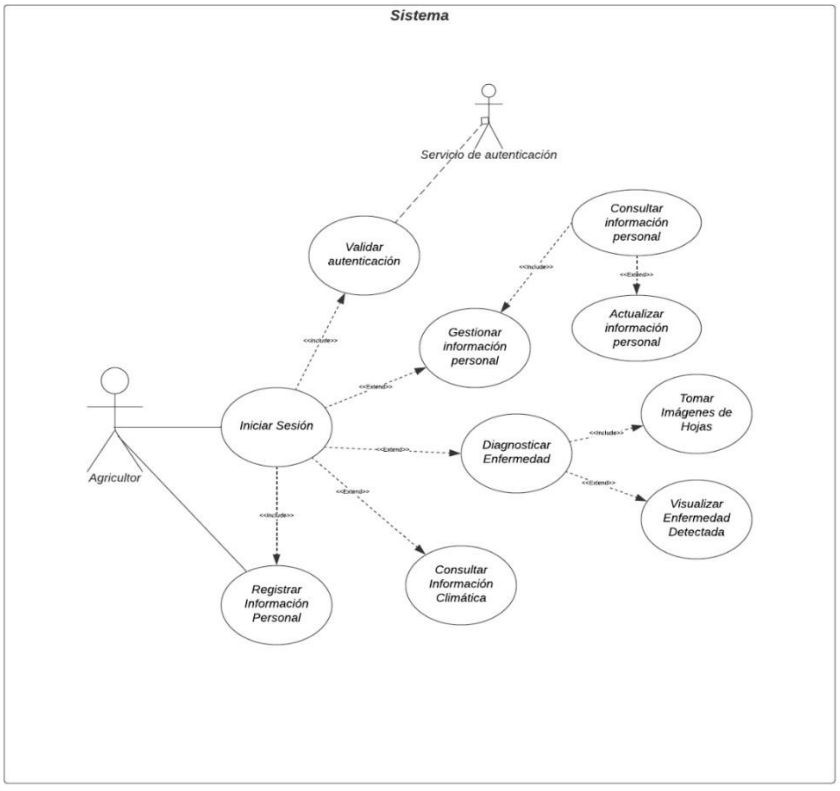
4.2.4.1 Diagrama de casos de uso. La construcción de un sistema eficiente y funcional requiere una comprensión profunda de los requerimientos del usuario y cómo estos se traducen en interacciones con el sistema. Como señala Pfleeger, un requerimiento es una característica o una descripción de algo que el sistema es capaz de hacer para cumplir su propósito, siendo esencial para definir el alcance del proyecto (Pfleeger, 2004). Es en esta fase donde el diagrama de casos de uso se convierte en una herramienta esencial, ya que permite representar de manera gráfica y comprensible cómo los usuarios interactúan con el sistema y qué funcionalidades deben estar presentes para cumplir con sus expectativas.

El diagrama de casos de uso facilita la comunicación entre los desarrolladores y los usuarios, asegurando que se entiendan claramente las funcionalidades requeridas antes de proceder al diseño y desarrollo. Según Fernández Benassati y Elsa Estévez (2004) “Fernández Benassati y Estévez, los casos de uso son efectivos medios de comunicación, ya que no solo especifican los requerimientos funcionales y no funcionales, sino que también ayudan a asegurar la trazabilidad de estos a lo largo del ciclo de vida del sistema”.

El siguiente diagrama de casos de uso ilustra las principales interacciones del usuario con el sistema propuesto para la detección de enfermedades en cultivos de tomate.

Figura 21

Diagrama de casos de uso



4.2.4.2 Funcionalidad del producto. El producto desarrollado no solo debe cumplir con los requerimientos funcionales identificados, sino que también debe proporcionar una experiencia de usuario efectiva. Los requerimientos funcionales detallan las transformaciones que el sistema realizará sobre las entradas para generar salidas, como la identificación de patrones de enfermedades en las imágenes de los cultivos. Estos requerimientos aseguran que el sistema cumpla con las expectativas del usuario en términos de funcionalidad y respuesta, aspectos críticos para la aceptación del producto en el mercado.

Así mismo, los requerimientos no funcionales, también son esenciales para el éxito del sistema. Incluyen consideraciones como la usabilidad, la robustez, la disponibilidad y la facilidad de mantenimiento. Estos aspectos aseguran que el sistema sea no solo funcionalmente adecuado, sino también accesible y confiable para los usuarios en el entorno agrícola, donde el tiempo y la precisión son cruciales.

En el contexto del desarrollo del aplicativo móvil para la detección de enfermedades en cultivos de tomate, se ha utilizado un enfoque iterativo en la especificación de casos de uso, lo que ha permitido una mejor adaptación a los requerimientos cambiantes y una mayor flexibilidad en el diseño del sistema. Como indican el autor Ghezzi, Jazayeri & Mandrioli. (1991), “las especificaciones de casos de uso operacionales permiten describir el comportamiento deseado del sistema, proveyendo un modelo del mismo que facilita su implementación”.

A continuación, se detallan los flujos correctos de cada proceso que debe seguir el sistema, con respecto a la interacción que tiene con el usuario final.

4.2.5 Especificación de requerimientos

Tabla 15

Caso de uso de registro de información personal

Caso de uso	**Registrar información personal**
Descripción	El sistema debe permitir a los agricultores registrar su información personal para crear un perfil que facilite el acceso a las funcionalidades del sistema.
Actor	Agricultor
Precondiciones	El agricultor no debe tener un perfil previamente registrado.
Postcondiciones	La información del agricultor se almacena correctamente en la base de datos y el usuario recibe un código de activación por correo electrónico.
Flujo básico	
Actor	**Sistema**
1. El agricultor selecciona la opción de registrar su información personal.	2. El sistema muestra un formulario de registro con los campos necesarios.
3. El agricultor llena los campos requeridos en el formulario.	
4. El agricultor confirma la información ingresada y selecciona "Guardar".	5. El sistema valida los campos obligatorios. 6. El sistema almacena los datos en la base de datos.

	7. El sistema envía un código de activación por correo electrónico.
8. El agricultor ingresa el código de activación de la cuenta.	
	9. El sistema valida el código de activación de la cuenta. 10. El sistema notifica activación exitosa de la cuenta.

Flujos alternativos

- Si los datos se encuentran incompletos, el sistema muestra un mensaje de error y vuelve al punto 3.
- Si el código de activación es incorrecto, el sistema muestra un mensaje de error y vuelve al punto al punto 8.
- Si el código se ingresa de manera incorrecta tres veces, el sistema muestra un mensaje de error y vuelve al punto 7.

Tabla 16

Caso de uso de inicio de sesión en el aplicativo móvil

Caso de uso	**Iniciar sesión en la aplicación**
Descripción	El sistema debe permitir a los agricultores iniciar sesión para acceder de manera segura a sus datos y funcionalidades del sistema.
Actor	Agricultor
Precondiciones	El agricultor debe estar registrado en la plataforma.
Postcondiciones	El agricultor está autenticado y redirigido al dashboard de la aplicación.
Flujo básico	
Actor	**Sistema**
1. El agricultor selecciona la opción de iniciar sesión. 3. El agricultor ingresa las credenciales requeridas. 4. El agricultor selecciona "Iniciar Sesión".	2. El sistema muestra un formulario para ingresar usuario y contraseña. 5. El sistema valida las credenciales. 6. El sistema valida que el usuario esté activo. 7. Si las credenciales son correctas y el usuario está activo, el sistema redirige al agricultor al dashboard.
Flujos alternativos	

Si las credenciales son incorrectas:

- El sistema muestra un mensaje de error y vuelve al punto 3.

Si el usuario está inactivo:

- El sistema envía un código de activación.
- El usuario debe ingresar el código.
- El sistema valida el código.

Si el código es incorrecto:

- El sistema muestra un mensaje de error y el usuario deberá ingresar el código nuevamente.

Si el número de intentos fallidos es de 3 veces al ingresar el código:

- El sistema envía un nuevo código de activación.

Tabla 17

Caso de uso de consultar información personal registrada

Caso de Uso	Consultar información registrada
Descripción	El sistema debe permitir a los agricultores revisar sus datos personales registrados.
Actor	Agricultor
Precondiciones	El agricultor debe estar registrado en el sistema.
Postcondiciones	Los datos personales del agricultor se muestran correctamente.
Flujo básico	
Actor	**Sistema**
1. El agricultor selecciona la opción de consultar su información registrada.	2. El sistema muestra los datos personales almacenados de manera clara y organizada.
Flujos alternativos	

Tabla 18

Caso de uso de Actualizar información personal

Caso de uso	Actualizar información personal
Descripción	El sistema debe permitir a los agricultores actualizar su información personal para mantenerla correcta y actualizada.
Actor	Agricultor
Precondiciones	El agricultor debe estar registrado y autenticado en el sistema.
Postcondiciones	Los datos personales del agricultor se actualizan correctamente y se reflejan de inmediato en el sistema.
Flujo básico	
Actor	**Sistema**
1. El agricultor selecciona la opción de selecciona la opción de actualizar su información personal.	2. El sistema muestra un formulario con los datos actuales del agricultor.
3. El agricultor edita los campos necesarios.	
4. El agricultor confirma la información ingresada y selecciona "Actualizar".	5. El sistema valida los campos antes de guardar.
6. El agricultor selecciona la opción de selecciona la opción de actualizar su información personal.	7. El sistema almacena los datos en la base de datos y muestra un mensaje de confirmación.

8. El agricultor edita los campos necesarios.

Flujos alternativos
Si la validación falla (datos incompletos o inválidos): • El sistema muestra un mensaje de error y vuelve al punto 3.

Tabla 19

Caso de uso de toma de imágenes de las hojas de tomate

Caso de uso	Tomar imágenes de las hojas de tomate
Descripción	El sistema debe permitir a los agricultores tomar imágenes de las hojas de tomate desde el dispositivo móvil para diagnosticar enfermedades.
Actor	Agricultor
Precondiciones	El agricultor debe estar autenticado en la aplicación y el dispositivo móvil debe tener una cámara funcional.
Postcondiciones	La imagen de la hoja de tomate se toma correctamente y está lista para ser procesada.

Flujo básico	
Actor	**Sistema**
1. El agricultor selecciona la opción de tomar una imagen.	2. El sistema muestra la opción de abrir cámara o seleccionar foto de la galería.
3. El agricultor selecciona abrir cámara o seleccionar foto de la galería.	4.
5. El agricultor selecciona abrir cámara.	6. El sistema abre la cámara del dispositivo.
7. El agricultor toma la foto.	8. El sistema muestra un mensaje de espera mientras procesa la imagen.
9. El agricultor escoge la opción de seleccionar foto de la galería.	10. El sistema abre la galería.
11. El agricultor selecciona la foto.	12. El sistema muestra un mensaje de espera mientras procesa la imagen.

Flujos alternativos
Si la imagen no se procesa correctamente: • El sistema muestra un mensaje de error y permite al agricultor retomar la foto o seleccionar otra de la galería.

Tabla 20

Caso de uso de visualización de la enfermedad detectada en la hoja de tomate

Caso de uso	**Visualizar la enfermedad detectada en la hoja de tomate**
Descripción	El sistema debe mostrar al agricultor el diagnóstico de la enfermedad detectada en la hoja de tomate.
Actor	Agricultor
Precondiciones	El agricultor debe haber tomado una imagen de la hoja de tomate.
Postcondiciones	El diagnóstico de la enfermedad se muestra correctamente con el nombre y descripción.
Flujo básico	
Actor	**Sistema**
	1. El sistema ha procesado la imagen de la hoja de tomate. 2. El sistema muestra el diagnóstico de la enfermedad con una imagen de referencia. 3. El sistema muestra una lista de recomendaciones basadas en la enfermedad detectada.
Flujos alternativos	

Tabla 21

Caso de uso de consultar información climática

Caso de uso	**Consultar información climática**
Descripción	El sistema debe permitir a los agricultores consultar información climática para tomar decisiones agrícolas informadas.
Actor	Agricultor
Precondiciones	El agricultor debe estar registrado y autenticado en el sistema.
Postcondiciones	El agricultor visualiza datos climáticos precisos y actualizados.
Flujo básico	
Actor	**Sistema**
1. El agricultor selecciona la opción de consultar información climática.	2. El sistema muestra datos climáticos actuales y predicciones para los días siguientes.
Flujos alternativos	

4.2.5.1 Diagrama de procesos. Un diagrama de actividades o procesos es una buena manera de mostrar cómo se gestionan los diferentes flujos de trabajo, es decir, cómo comienzan, continúan y terminan. Además, muestra muchas rutas de decisión diferentes que se pueden tomar desde el principio hasta el final (Al-Fedaghi, 2021, pp. 1-14). A continuación, se presentan los diagramas de procesos que involucran cada uno de los flujos de trabajo presentes en la aplicación móvil desarrollada.

Figura 22

Registro de información personal

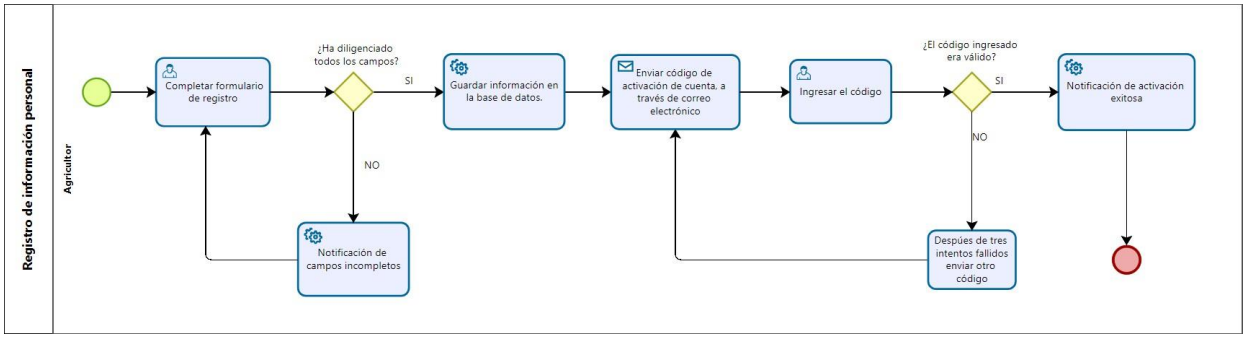


Figura 23

Inicio de sesión

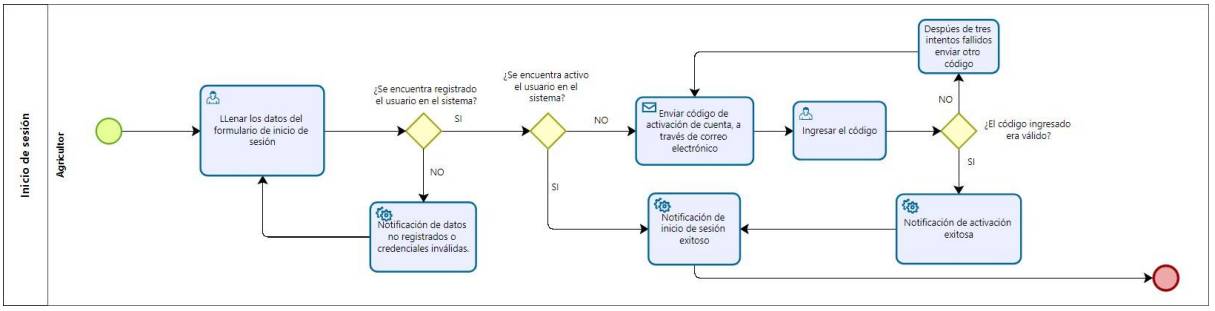


Figura 24

Visualización de información personal

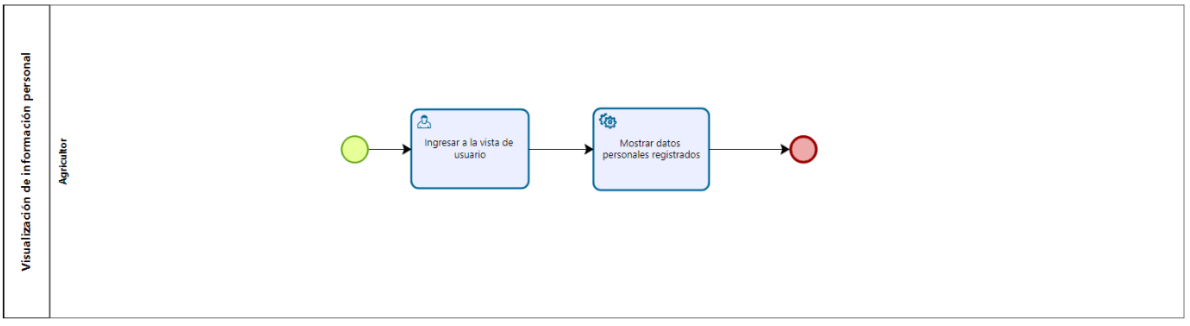


Figura 25

Actualización de información personal

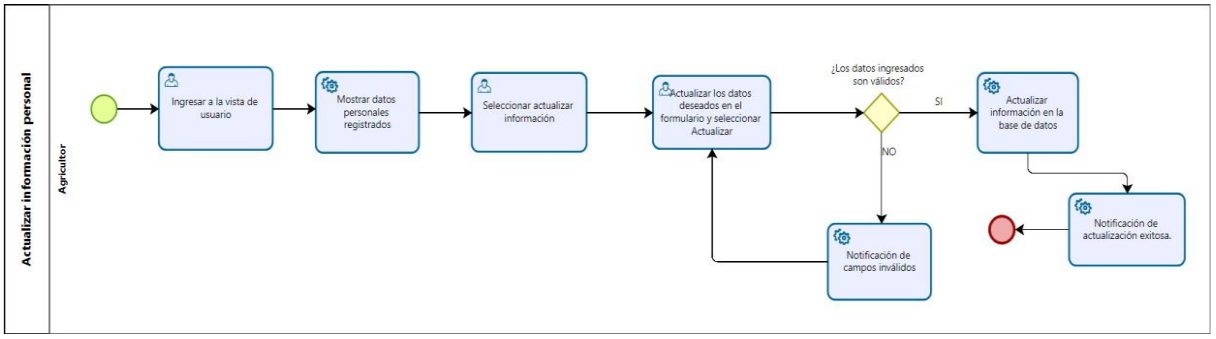


Figura 26

Toma y diagnóstico de enfermedades presentes en la hoja del tomate

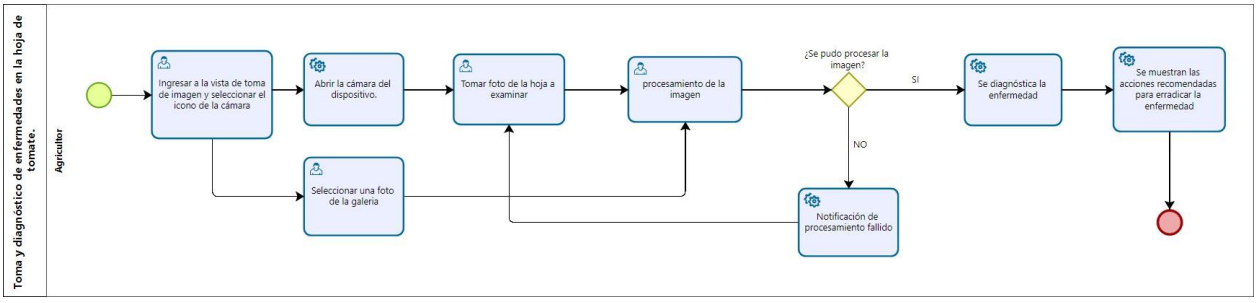
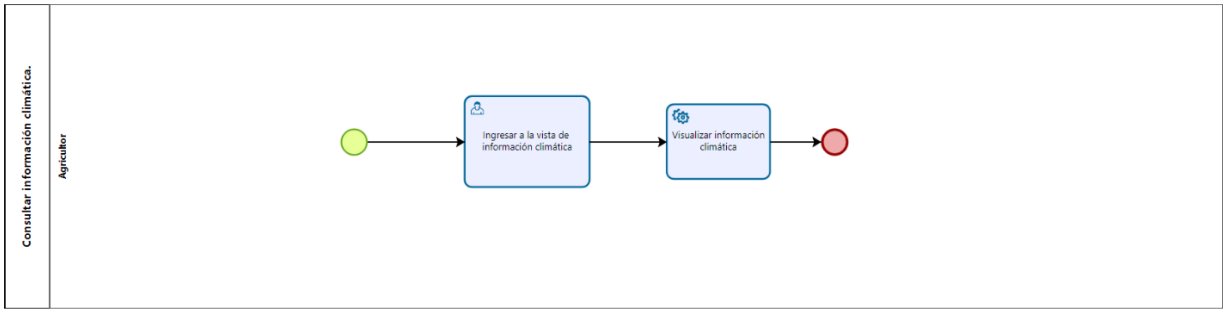


Figura 27

Consulta de información climática



4.2.5.2 Diseño de interfaces. El diseño de las interfaces para el aplicativo móvil se orientó principalmente en garantizar una interfaz de usuario (UI) amigable con el usuario, teniendo en cuenta la interacción intuitiva y las necesidades específicas de los agricultores que habitan en las zonas rurales de Llano del Pozo, San Javier, Campanario. Con el fin de desarrollar una solución efectiva, se implementó un proceso en el que los usuarios finales estuvieron involucrados. Este enfoque permitió ajustar las interfaces no solo a las funcionalidades requeridas, sino también a las expectativas de los agricultores, quienes fueron de vital importancia a la hora de ir definiendo los respectivos diseños.

Figura 28

Vista de bienvenida

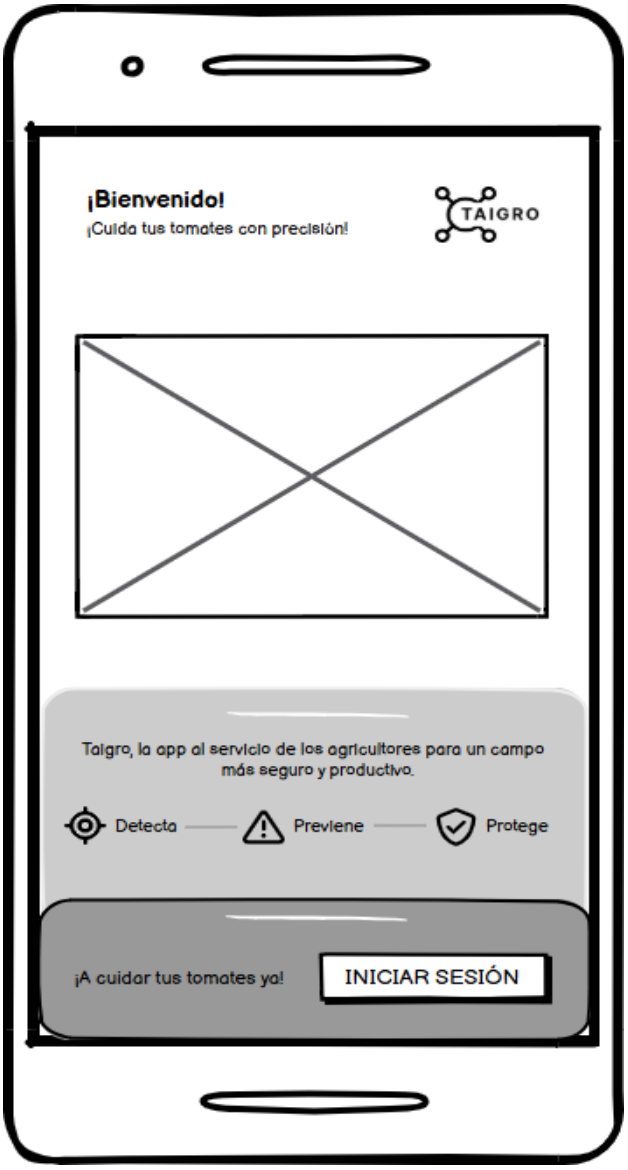


Figura 29

Vista de Inicio de sesión



Figura 30

Vista de Registro de usuarios



Figura 31

Vista de Home



Figura 32

Vista de actualización de datos



Figura 33

Vista de detección



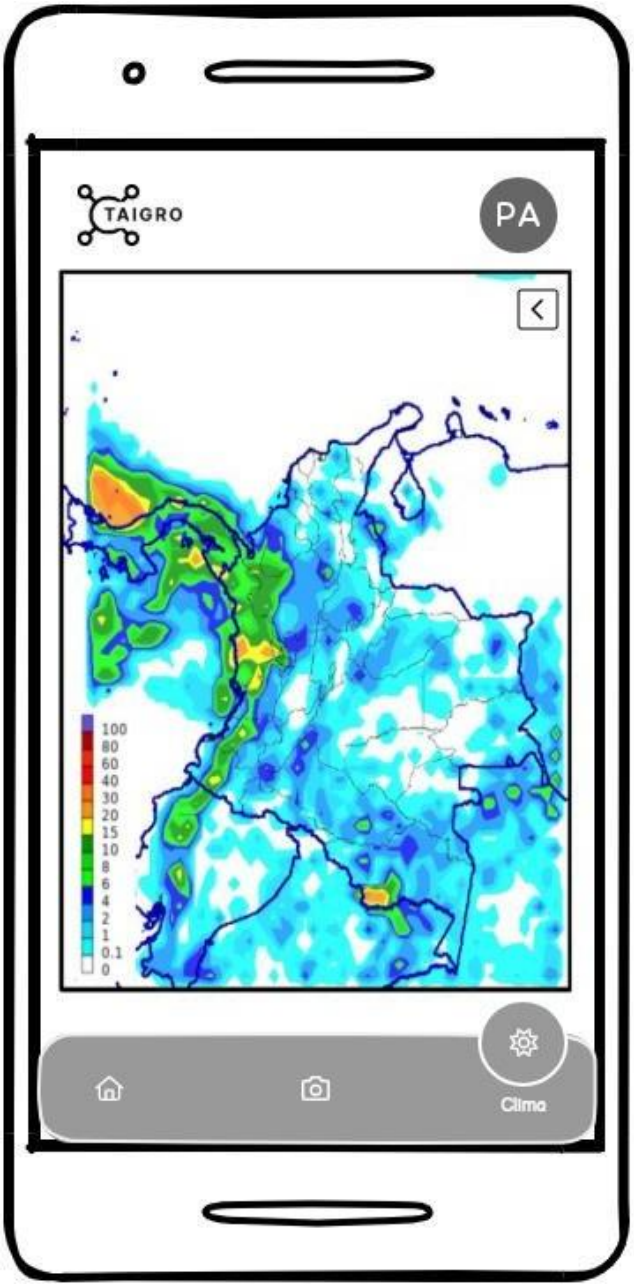
Figura 34

Vista de visualización de la enfermedad detectada



Figura 35

Vista de clima



4.2.5.3 Arquitectura del aplicativo móvil. La arquitectura del aplicativo móvil se ha diseñado para integrar eficientemente diversas tecnologías modernas, garantizando un rendimiento óptimo y una experiencia de usuario de alta calidad. A continuación, se detallan los componentes principales y su interacción:

4.2.5.3.1 Desarrollo del Frontend con Vue, TypeScript y Vite. El frontend del aplicativo se ha construido utilizando Vue.js, un framework progresivo de JavaScript que facilita la creación de interfaces de usuario interactivas y reactivas. La elección de Vue.js se debe a su flexibilidad y facilidad de integración en proyectos de diversa índole. Para mejorar la robustez y mantenibilidad del código, se ha empleado TypeScript, un superconjunto de JavaScript que introduce tipado estático, permitiendo una detección temprana de errores y una mejor autocompletación en los entornos de desarrollo. La herramienta de construcción Vite ha sido seleccionada por su capacidad para ofrecer un entorno de desarrollo rápido y eficiente, optimizando el proceso de bundling y facilitando una recarga en caliente durante el desarrollo.

4.2.5.3.2 Transpilación a Aplicación Nativa con Capacitor. Una vez desarrollado el frontend, se utiliza Capacitor para transpilar la aplicación web en una aplicación móvil nativa. Capacitor, desarrollado por el equipo de Ionic, permite que las aplicaciones web accedan a funcionalidades nativas del dispositivo, como la cámara o el GPS, manteniendo una única base de código. Esta herramienta facilita la creación de aplicaciones híbridas que pueden desplegarse tanto en iOS como en Android, aprovechando las capacidades nativas de cada plataforma.

4.2.5.3.3 Comunicación con el Backend a través de FastAPI. El aplicativo móvil se comunica con un backend desarrollado en FastAPI, un framework moderno y de alto rendimiento para construir APIs con Python, basado en estándares como OpenAPI y JSON Schema. FastAPI es conocido por su eficiencia y rapidez, lo que lo convierte en una elección adecuada para aplicaciones que requieren respuestas rápidas y manejo eficiente de múltiples solicitudes simultáneas.

4.2.5.3.4 Gestión de Bases de Datos: MongoDB y PostgreSQL. El backend interactúa con dos bases de datos distintas para manejar diferentes tipos de información:

MongoDB: Utilizada para almacenar imágenes, aprovechando su naturaleza NoSQL y su eficiencia en el manejo de datos no estructurados. La integración de FastAPI con MongoDB se realiza mediante el uso de la biblioteca Motor, que permiten operaciones asíncronas y eficientes.

PostgreSQL: Empleada para almacenar información estructurada, es decir los datos tanto de los usuarios como de las enfermedades utilizadas en este proyecto. La integración con FastAPI se facilita a través del ORM SQLAlchemy, permitiendo una interacción fluida y eficiente con la base de datos.

4.2.5.3.5 Integración de la Red Neuronal con Keras y PyTorch. El sistema incorpora una red neuronal diseñada para la detección de enfermedades en cultivos de tomate, implementada utilizando Keras y PyTorch. Keras proporciona una interfaz de alto nivel que facilita la construcción y entrenamiento de modelos de aprendizaje profundo, mientras que PyTorch ofrece una mayor flexibilidad y control durante el proceso de desarrollo del modelo. La

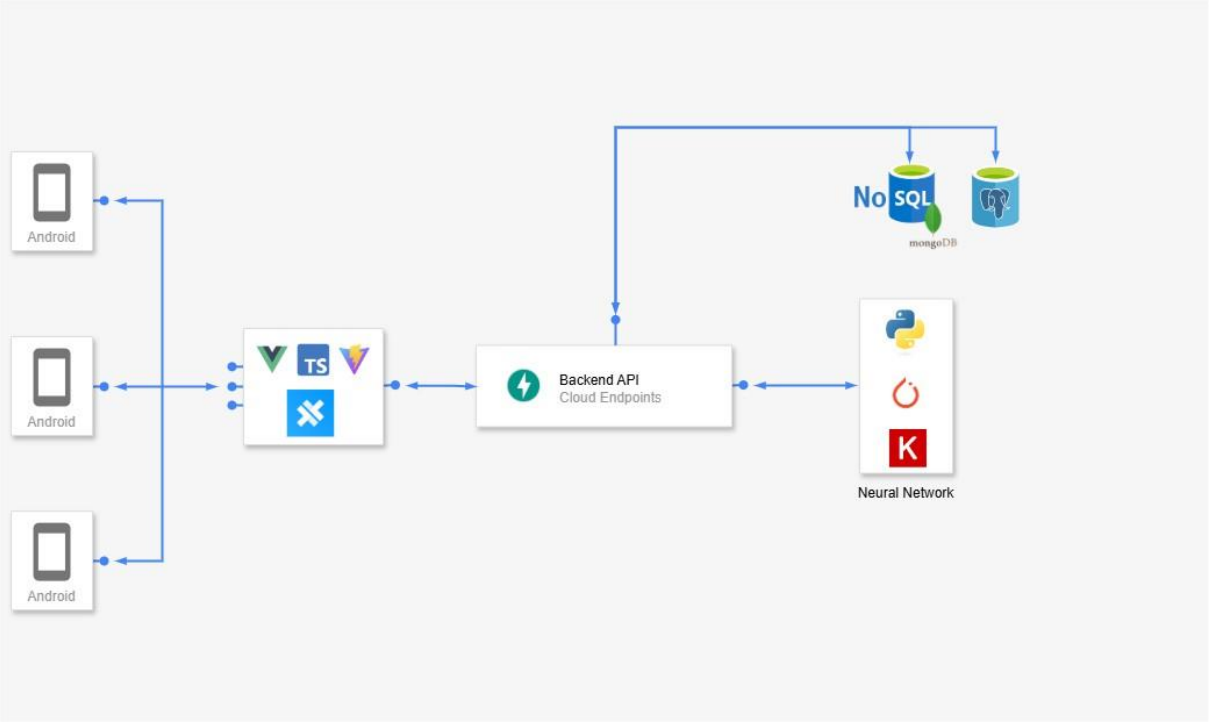
combinación de ambas herramientas permite aprovechar sus respectivas fortalezas, logrando un modelo eficiente y preciso.

Además, se utilizó la contenerización como herramienta para que cada componente del sistema funcione de manera independiente y eficiente en su propio entorno aislado. Se implementaron contenedores para MongoDB, que tiene un puerto expuesto para la conexión externa y se utiliza para almacenar imágenes enviadas por los usuarios para el diagnóstico de enfermedades, así como referencias visuales y fotos de perfiles de los usuarios. PostgreSQL también cuenta con un contenedor con puerto expuesto, encargado de gestionar la información estructurada del sistema, incluyendo datos de usuarios y enfermedades detectadas. Además, se incluyó un contenedor de Celery, que se ocupa de ejecutar tareas en segundo plano, como el envío de correos electrónicos, optimizando así el rendimiento del sistema. Aunque inicialmente se consideró trasladar el procesamiento de imágenes a segundo plano, se decidió mantener este proceso dentro del flujo principal de la API debido a la necesidad de esperar una respuesta antes de almacenarlas en la base de datos. La API, desarrollada en FastAPI, está contenida en una imagen basada en Linux y maneja las solicitudes del frontend, así como la comunicación con la base de datos. También se integró Redis como sistema de mensajería para gestionar tareas en Celery, asegurando un procesamiento eficiente y asincrónico de trabajos pesados. Todos estos contenedores están conectados a través de la red interna proporcionada por Docker Compose, lo que facilita la comunicación entre la base de datos, la API, el servicio de tareas en segundo plano y el almacenamiento de imágenes sin necesidad de configuraciones externas adicionales.

A continuación, se puede observar lo anteriormente descrito en el diagrama n, el cual ilustra la arquitectura general del aplicativo móvil.

Figura 36

Arquitectura general de TAIGRO

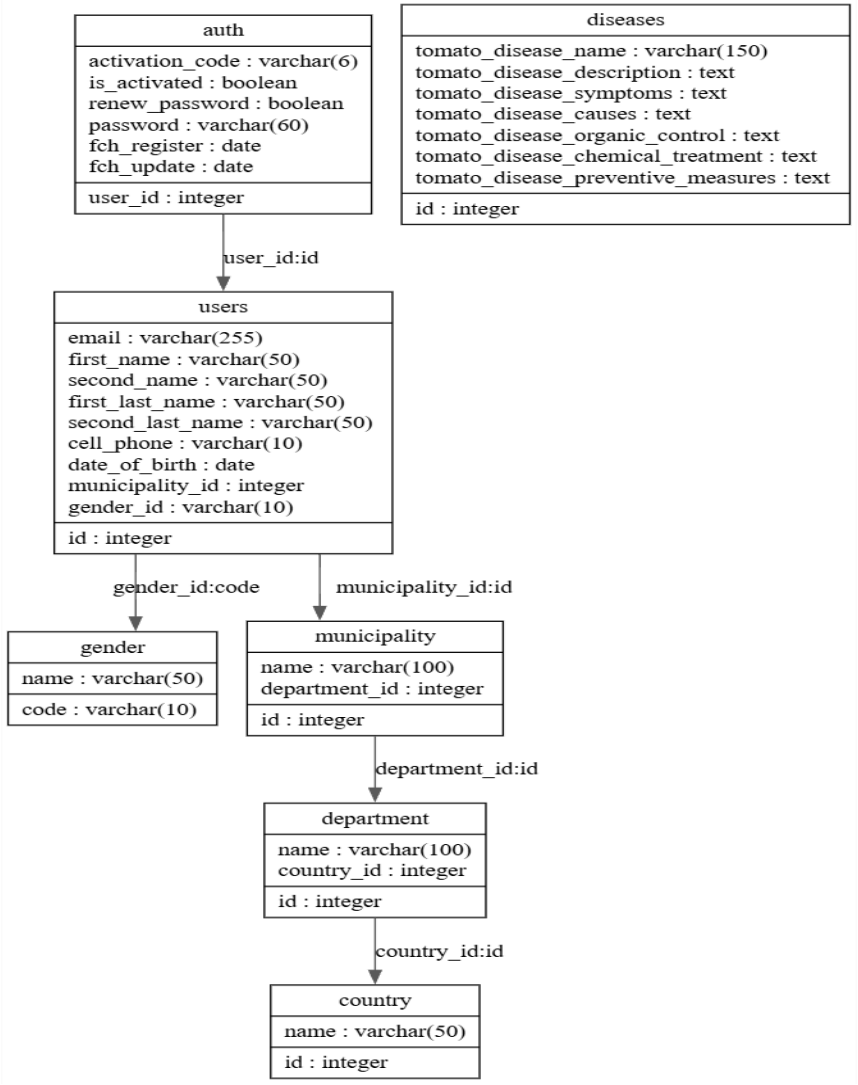


4.2.6 Diseño de la base de datos

Se tiene una base de datos en postgres para almacenar la información estructurada, como por ejemplo los datos del usuario, así como también los de las enfermedades que se tuvieron en cuenta en este estudio.

Figura 37

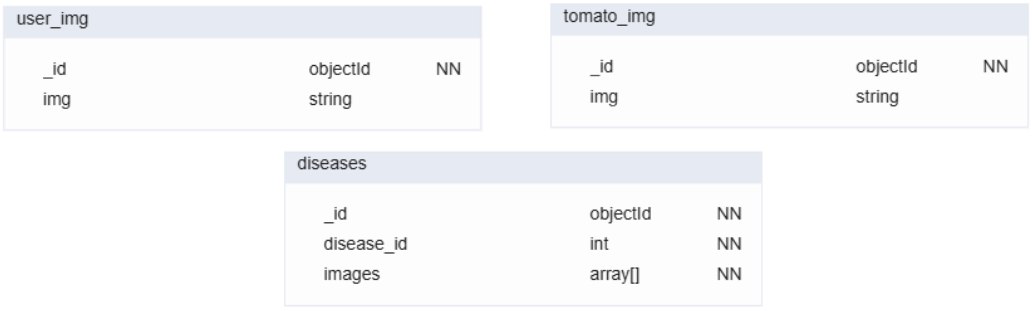
Base de datos en postgresSQL



Además, se utilizó una base de datos en MongoDB para almacenar la información multimedia utilizada en el aplicativo, como lo fueron las imágenes tanto de los usuarios, como de las enfermedades utilizadas para ser utilizadas como referencia visual de las enfermedades detectadas en el aplicativo y así mismo, también se almacenan imágenes que son correctamente procesadas por el aplicativo, con el fin de armar un Dataset propio.

Figura 38

Base de datos en MongoDB



4.2.6.1 Dataset utilizado para el entrenamiento y evaluación de la red neuronal. El concepto de "conjunto de datos" ha evolucionado considerablemente a lo largo de la historia de la investigación en visión artificial. Antes de la era computacional, los científicos ya empleaban “muestras de prueba” o “estímulos” para evaluar sus modelos, los cuales solían consistir en patrones sintetizados como líneas y manchas. Esta práctica inicial sentó las bases para el uso de conjuntos de datos más estructurados con la llegada de los dispositivos de digitalización de fotografías (Antonio Torralba & Elexei A. Efros, 2011). Sin embargo, no fue hasta la incorporación de métodos de aprendizaje automático que el concepto moderno de "conjuntos de datos" se formalizó, definiendo claramente datos de entrenamiento y validación como componentes fundamentales para optimizar modelos y evaluar su desempeño. (Zhuang Liu & Kaiming He, 2024)

En este proyecto, se utilizó un conjunto de datos tomado de la plataforma Kaggle para entrenar y evaluar la red neuronal destinada a la detección de enfermedades en cultivos de tomate y se seleccionó teniendo en cuenta las enfermedades identificadas en el instrumento de medición aplicado. El dataset contiene 24,565 registros, de los cuales el 79.43% (19,513

imágenes) se utilizó para el entrenamiento, mientras que el 20.57% (5,052 imágenes) se destinó a la validación. Esta distribución responde a prácticas comunes en la investigación en aprendizaje profundo, garantizando suficiente información para optimizar los parámetros del modelo y un tamaño adecuado para evaluar su capacidad de generalización.

Figura 39

Imágenes en el Dataset



El conjunto de datos seleccionado permite abordar una tarea específica de clasificación relacionada con enfermedades del tomate. Este enfoque sigue una lógica similar a la empleada en conjuntos clásicos como MNIST para la clasificación de dígitos o ImageNet para la clasificación de objetos (Zhuang Liu & Kaiming He, 2024). La elección de un dataset bien balanceado y representativo es crucial para minimizar los sesgos y garantizar que el modelo sea capaz de realizar predicciones confiables en condiciones reales de aplicación.

Es importante destacar que la selección y manejo de los datos no solo involucra su distribución, sino también la aplicación de estrategias para mitigar problemas comunes como la fuga de datos (“data leakage”), la redundancia y la variabilidad insuficiente, los cuales pueden afectar significativamente el rendimiento del modelo (Liu & He, 2024). Por tanto, se realizaron procesos de limpieza y normalización para asegurar la calidad del dataset empleado.

4.3 Desarrollar un sistema basado en conocimiento para la correcta detección e identificación de enfermedades que afectan al cultivo de tomate por medio de toma de imágenes de este

4.3.1 Entrenamiento de la red neuronal

4.3.1.1 Conjunto de datos. El conjunto de datos utilizado en este estudio consta de un total de 24,565 imágenes recopiladas de la base de datos kaggle. Estas imágenes fueron seleccionadas con base en la incidencia de enfermedades identificadas en el instrumento de medición aplicado en la fase inicial del estudio. Se priorizaron aquellas enfermedades con mayor impacto en la población, asegurando que el modelo se enfocara en los casos más representativos.

Para mejorar la representatividad y equilibro del conjunto de datos, se aplicaron las siguientes técnicas:

4.3.1.1.1 Normalización de imágenes. Se ajustaron los valores de los píxeles al rango [0,1] para estabilizar el entrenamiento y mejorar la convergencia.

$$I' = \frac{I - Imin}{Imax - Imin}$$

Donde I′ representa la imagen normalizada, I es la imagen original, y I_{min} e I_{max} son los valores mínimos y máximos del conjunto de datos respectivamente. Esto permitió estabilizar el entrenamiento y mejorar la convergencia del modelo.

$$I' = \frac{I - Imin}{Imax - Imin}$$

4.3.1.1.2 Redimensionamiento. Todas las imágenes fueron convertidas a un tamaño estándar de 256x256 píxeles, garantizando compatibilidad con la arquitectura de la red neuronal.

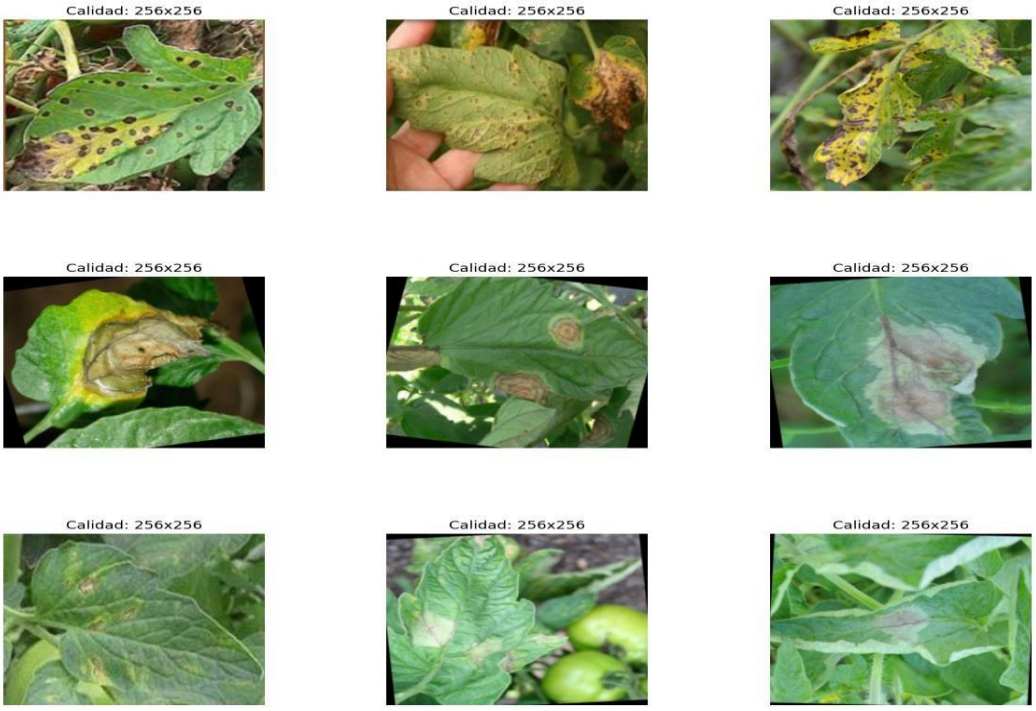
Este proceso se llevó a cabo mediante interpolación bilineal definida como:

$$I'(x, y) = \sum_{i=0}^{1} \sum_{j=0}^{1} w_{ij} I(x_i, y_j)$$

Donde W_{ij} son los coeficientes de ponderación calculados en función de la distancia entre los píxeles originales y los píxeles redimensionados.

Figura 40

Redimensionamiento



4.3.1.2 Fase de entrenamiento. El modelo se entrenó utilizando la arquitectura EfficientNet-B7, que es una red neuronal convolucional avanzada con 66 millones de parámetros, diseñada para optimizar la relación entre el tamaño del modelo y su capacidad de generalización (Tan, M., & Le). Esta optimización se logra mediante un escalamiento compuesto, que permite aumentar simultáneamente la profundidad de la red, el ancho de sus capas convolucionales y la resolución de entrada de las imágenes, manteniendo un equilibrio eficiente en cada una de estas dimensiones.

El modelo se entrenó utilizando la arquitectura EfficientNet-B7, una red neuronal convolucional de última generación con 66 millones de parámetros optimizados mediante escalamiento compuesto, definido por:

$$d = \alpha\phi,\ w = \beta\phi,\ r = \gamma\phi$$

Donde d representa la profundidad de la red, es decir, el número de capas en la arquitectura; w se refiere al ancho de las capas convolucionales, lo que influye en la cantidad de filtros aplicados en cada capa y, por ende, en la capacidad del modelo para captar patrones complejos en las imágenes; y r define la resolución de entrada de la imagen, que impacta el nivel de detalle con el que la red puede analizar las características de cada muestra.

El parámetro ϕ actúa como un coeficiente de escalamiento global, controlando el crecimiento simultáneo de las tres dimensiones mencionadas. Los valores α, β y γ son constantes que determinan el equilibrio de escalamiento, asegurando que la expansión del modelo se realice de manera proporcional y eficiente. Este enfoque permite que EfficientNet-B7 supere a arquitecturas anteriores en términos de precisión y eficiencia computacional, maximizando su capacidad de aprendizaje sin incrementar innecesariamente el costo

La función de pérdida utilizada fue Categorical Cross-Entropy:

$$L = -\sum_{i=1}^{N} y_i \log(\hat{y}_i)$$

En este caso y_i es la etiqueta real y y_i es la probabilidad predicha para la clase correcta.

Para la optimización de pesos se empleó el algoritmo AdamW, cuya actualización está dada por:

$$w_{t+1} = w_t - \eta \left(\frac{m_t}{(\sqrt{v_t}) + e} + \lambda w_t \right)$$

Donde η es la tasa de aprendizaje, m_t y v_t son los primeros y segundos momentos del gradiente respectivamente y λ es el coeficiente de decaimiento de pesos. Este último juega un papel importante en la regularización del modelo, ya que evita que los pesos se inflen demasiado durante el entrenamiento.

Para este estudio se entrenó el modelo durante 10 épocas, aplicando Dropout (0.5) y L2 Regularization ($\lambda = 0.001$) para evitar sobreajuste. Se monitoreó la métrica de precisión Top-1 Accuracy, definida como:

$$\text{Accuracy} = \frac{TP}{TP+FP+FN}$$

En la fórmula previa, TP hace referencia a los valores verdaderos positivos, que son las imágenes que han sido clasificadas correctamente dentro de su propia categoría. A su vez, los valores FP y FN simbolizan los falsos positivos y los falsos negativos, respectivamente, lo que indica errores en la clasificación. Un alto valor de Top-1 Accuracy indica que el modelo ha obtenido una clasificación correcta en la mayoría de los casos, lo que significa que cuenta con un alto nivel de confianza al predecir.

Con respecto al entrenamiento se realizaron un total de 10 épocas, dentro de las cuales, se logró visualizar un buen resultado en cuanto al porcentaje de precisión y reducción de pérdidas respectivamente, debido a que, a partir de la segunda época, el modelo superó el umbral del 90% de precisión.

Tabla 22

Proceso de entrenamiento de la CNN por épocas

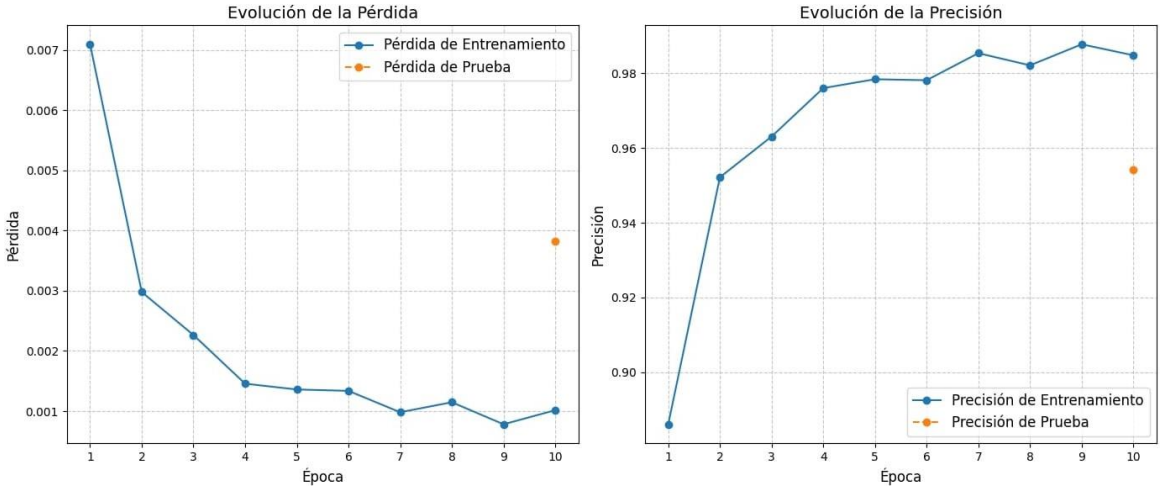
Época	Pérdida	Precisión
1	0.007	0.886
2	0.003	0.952
3	0.002	0.963
4	0.001	0.976
5	0.001	0.978
6	0.001	0.978
7	0.001	0.985
8	0.001	0.982
9	0.001	0.988
10	0.001	0.985

Las métricas del entrenamiento han quedado reflejadas en la evolución de la función de pérdida y de la función de precisión a lo largo de las épocas. En la figura 39, se puede apreciar cómo la función de pérdida disminuye de manera continua y va estabilizándose en unos mínimos, de lo que se observa la convergencia del modelo. A su vez, la función de precisión presenta un aumento rápido en las 3 primeras épocas y se mantiene en valores próximos al 97-

98% en las siguientes, lo que indica que se logra una buena capacidad de clasificación, logrando llegar hasta un 98.5% al final del entrenamiento. El comportamiento conjunto de ambas funciones sugiere que el modelo ha aprendido correctamente las características que hacen que cada enfermedad sea única.

Figura 41

Pérdida y precisión por épocas

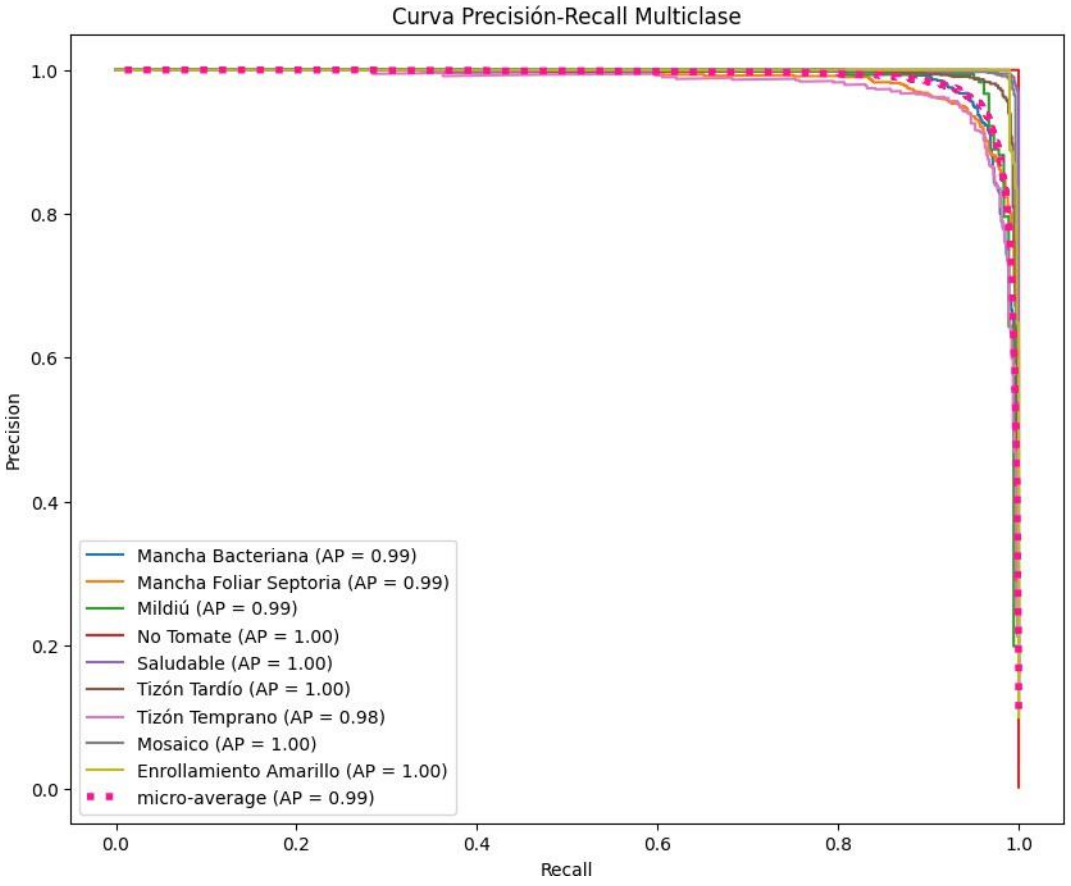


La Curva de Precisión-Recall Multiclase, como se muestra en la figura 40, ofrece un análisis complementario sobre el balance entre la detección de verdaderos positivos y la reducción de falsos negativos. Se observa que el modelo ofrece siempre valores altos en precisión y recall en todas las clases, lo que verifica la estable clasificación de las clases. La clase No Tomate ha obtenido el resultado de un 100% en precisión y recall, corroborando la capacidad del modelo para reconocer imágenes que no forman parte de la temática de enfermedades del tomate, esto con el fin de indicarle al agricultor cuando una imagen no corresponda a una hoja de tomate, para que pueda volver a tomar una imagen que si le permita al modelo identificar alguna de las enfermedades usadas en el entrenamiento. Para las

enfermedades Mildiu y el enrollamiento Amarillo, los resultados de precisión y recall están también cerca del 100% logrando reconocer de manera precisa estas patologías.

Figura 42

Curva de precisión-Recall Multiclase

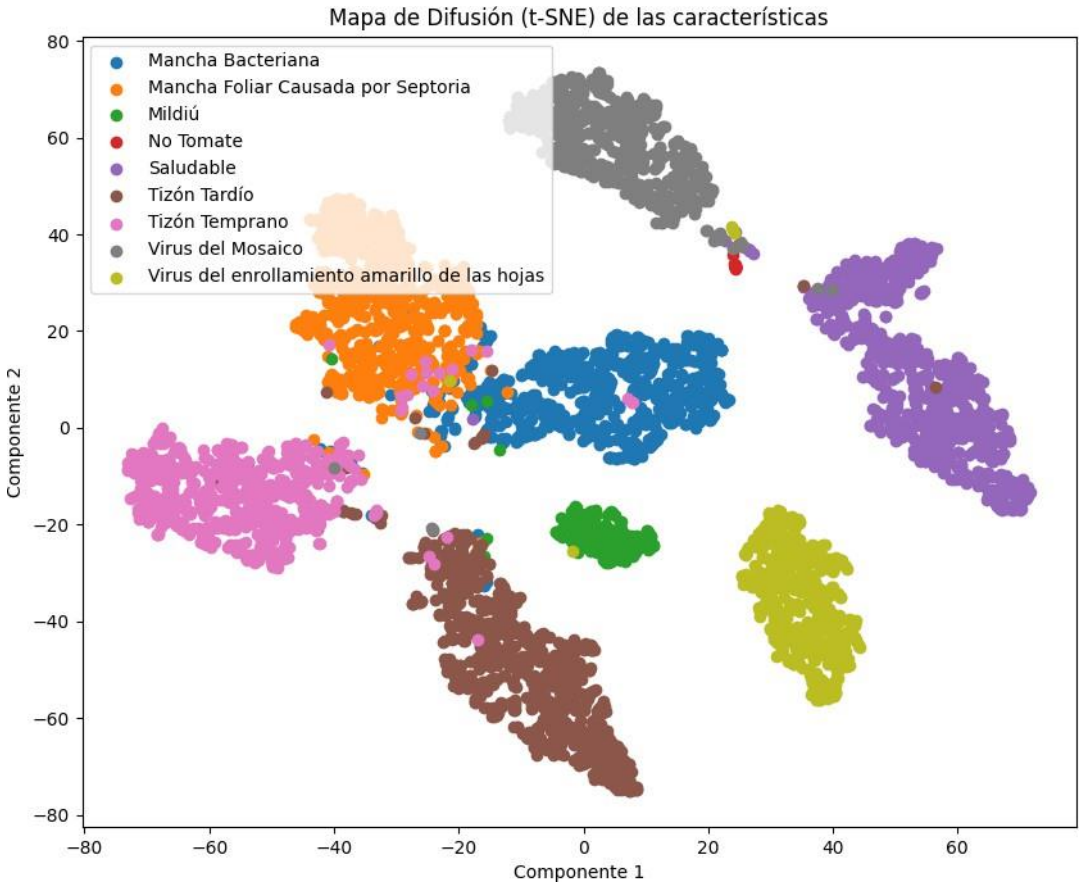


Así mismo, se realizó el análisis de la representación de las características extraídas por el modelo mediante un Mapa de difusión (t-SNE), tal y como se observa en la figura 41. Esta técnica sirve para obtener una representación visual de la distribución de las características en un espacio de menor dimensión, de tal forma que las muestras se agruparían de acuerdo a su similitud. Las enfermedades pueden observarse muy separadas en el espacio latente, lo que

indica que el modelo ha aprendido representaciones discriminativas adecuadas y aunque en algunos casos se puede observar superposición en la clasificación, es tolerable el grado de desacierto del modelo, siendo evidente una correcta separación de las clases o etiquetas de las enfermedades utilizadas en el entrenamiento.

Figura 43

Mapa de difusión (t-SNE) de las características

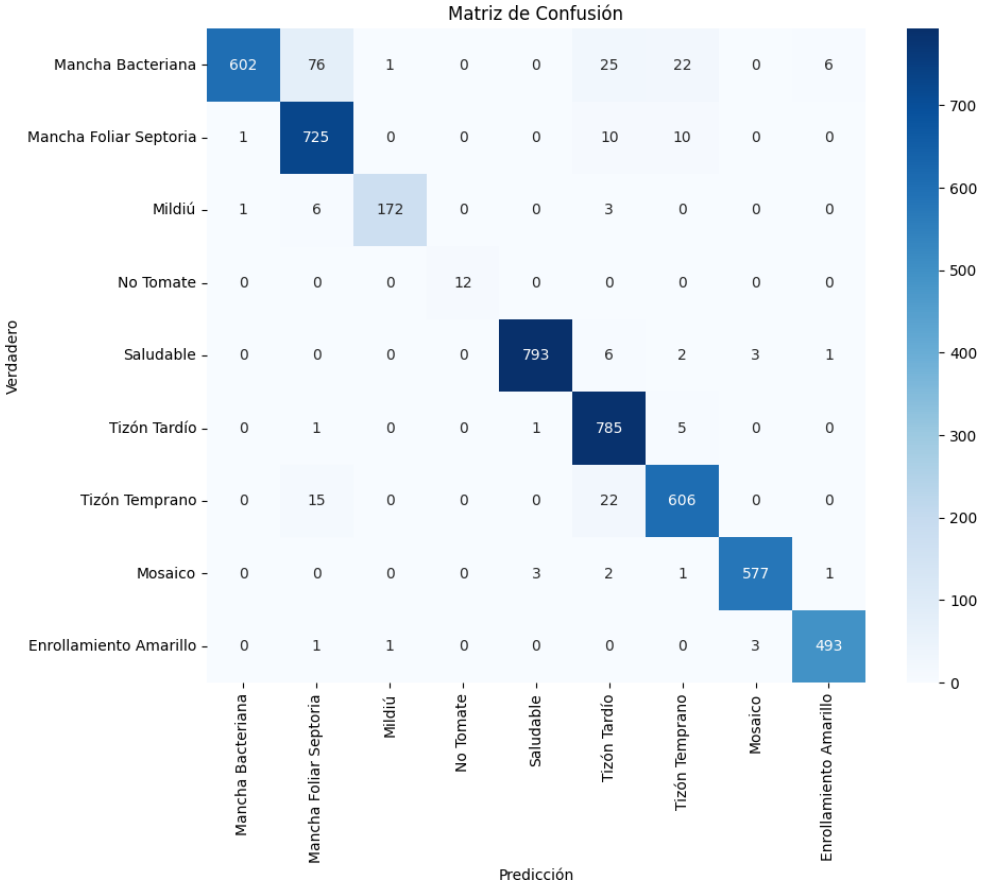


Por último, la Matriz de Confusión, que se muestra en la figura 42, ofrece una visión clara de la precisión del modelo al clasificar cada una de las enfermedades. Se puede notar que la mayoría de las clases tienen una alta tasa de aciertos, con valores altos en la diagonal principal,

lo que sugiere un excelente desempeño en la predicción de las categorías correctas. Sin embargo, se observan algunas confusiones entre Tizón Temprano, Tizón Tardío y mancha foliar causada por septoria, lo cual es comprensible dado su cercanía en el espacio latente de características. Por otro lado, las demás etiquetas, logran ser clasificadas de manera correcta en su gran mayoría, mostrando la buena capacidad que posee la red en el proceso de detección y clasificación de enfermedades en el cultivo de tomate.

Figura 44

Matriz de confusión



El modelo final basado en EfficientNet-B7 demostró una alta capacidad de generalización, validando su aplicabilidad para la detección automática de enfermedades en cultivos de tomate con un alto nivel de precisión.

4.3.2 Desarrollo del Aplicativo

El desarrollo del aplicativo se llevó a cabo siguiendo la metodología ágil Scrum para garantizar una implementación estructurada y eficiente. Se realizaron múltiples iteraciones a lo largo de diversos sprints, permitiendo realizar ajustes constantes en función de los resultados obtenidos y el feedback recibido de pruebas intermedias realizadas al aplicativo a medida que se avanzaba con el desarrollo.

4.3.2.1 Sprint 1. Implementación de la Infraestructura Base y Registro de Usuarios.

El primer sprint se centró en establecer unas bases sólidas y robustas del sistema, para que desde el inicio el sistema lograra ser escalable y su gestión futura no fuera demasiado tediosa. En este sentido, la prioridad fue garantizar una gestión adecuada de los datos, implementar un sistema de autenticación seguro y establecer una comunicación eficiente entre el backend y la aplicación móvil.

Para ello, se tomaron en cuentas 4 historias de usuario del Product Backlog refinado (Ver apéndice C) (ST-01-1, ST-01-2, ST-01-3, ST-01-4). Teniendo en cuenta lo anterior, se comenzó con el diseño y la configuración de las bases de datos en PostgreSQL y MongoDB, organizando la información clave del sistema, como los registros de usuarios, diagnósticos y datos de los

cultivos. La elección de estas tecnologías permitió estructurar los datos de manera óptima y asegurar un rendimiento adecuado para futuras consultas y almacenamiento de información.

También se trabajó en el desarrollo del sistema de autenticación utilizando FastAPI, implementando tokens de autenticación seguros y aplicando mecanismos de encriptación de contraseñas para proteger la información de los usuarios. Además, se establecieron validaciones en los formularios de registro e inicio de sesión para prevenir accesos no autorizados y mejorar la experiencia del usuario.

El desarrollo del frontend se llevó a cabo con Vue.js, lo que permitió crear una interfaz moderna, interactiva y fácil de usar. Durante este proceso, se implementaron componentes reutilizables y un sistema de gestión de estados eficiente para garantizar una navegación fluida dentro de la aplicación. Una vez que la funcionalidad estuvo lista y completamente conectada con el backend, se utilizó Capacitor para generar la versión móvil del aplicativo y realizar pruebas en dispositivos físicos. Esto permitió verificar el comportamiento real de la aplicación en entornos móviles y hacer los ajustes necesarios antes de avanzar con el siguiente sprint.

Durante este proceso se realizó el respectivo seguimiento del flujo de trabajo del equipo mediante la herramienta de gestión de proyectos de **Notion** (ver apéndice B), la cual fue de vital importancia para determinar un orden y ejecutar de manera adecuada cada una de las tareas asignadas.

A continuación, se muestran los diseños correspondientes del aplicativo móvil que fueron desarrollados en el sprint 1.

Figura 45

Interfaz gráfica de registro de información personal



Figura 46

Interfaz gráfica de bienvenida



Figura 47

Interfaz gráfica de inicio de sesión



Figura 48

Interfaz gráfica de consultar información personal

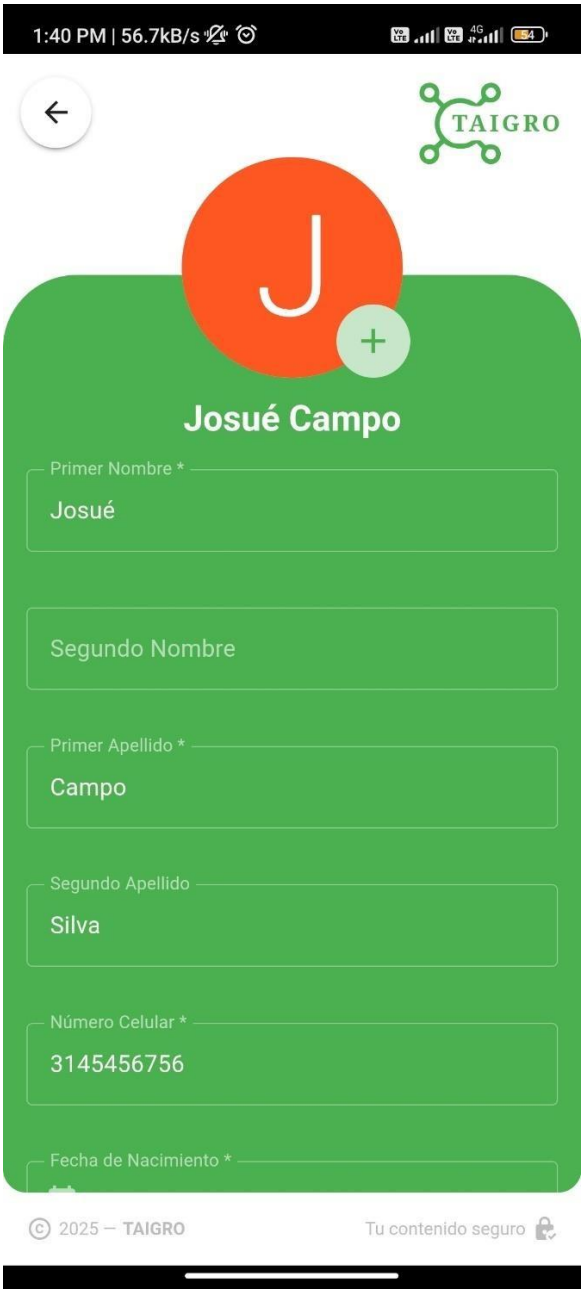
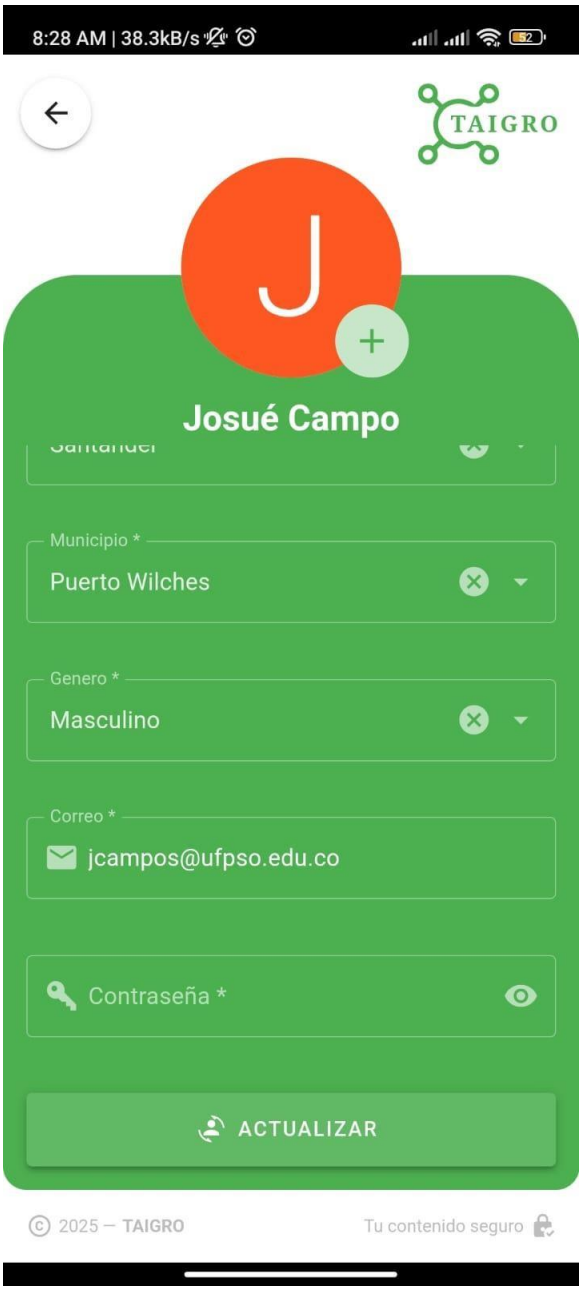


Figura 49

Interfaz gráfica de actualizar información personal

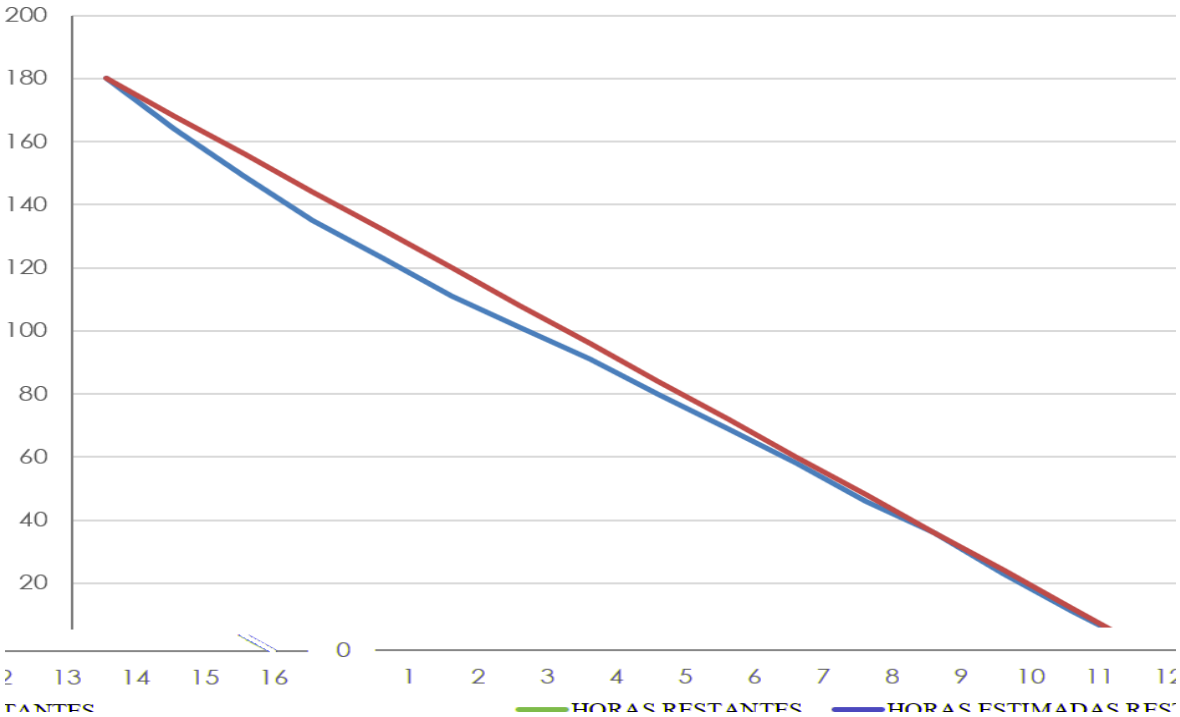


4.3.2.1.1 Análisis del Desempeño del Sprint 1. Para evaluar el desarrollo del Sprint 1, se utilizó el Burndown Chart como herramienta de seguimiento, permitiendo visualizar la disminución progresiva de las horas de trabajo restantes en relación con las horas estimadas restantes. A través de este gráfico, se monitoreó la eficiencia del equipo, identificando el ritmo de avance y posibles desviaciones respecto a la planificación inicial.

Figura 50

Burndown Chart sprint 1

HORAS RESTANTES	180	164	149	135	123	111	101	91	80	69	58	46	36	23	11	0
ESTIMADAS RESTANTES	180	168	156	144	132	120	108	96	84	72	60	48	36	24	12	0



El Burndown Chart muestra la relación entre las horas estimadas restantes y las horas reales restantes a lo largo de los días del sprint. En el primer día, ambas líneas mostraron una tendencia descendente alineada, lo que indica que el equipo trabajó al ritmo previsto. Sin

embargo, a partir del segundo día, la línea amarilla (horas reales restantes) comenzó a situarse por debajo de la línea morada (horas estimadas restantes), lo que demuestra que el equipo pudo completar tareas a un ritmo más rápido de lo estimado. Este desempeño se debió a la naturaleza poco complejas de las actividades realizadas, lo que permitió que ciertas tareas se completaran en menos tiempo del previsto.

En el sexto día de ejecución del proyecto, se puede notar una disminución en el ritmo que el equipo había mantenido en relación con las horas estimadas restantes, ya que la complejidad de las tareas a realizar comenzó a aumentar, lo que provocó una disminución en la velocidad. Por esta razón, en la etapa final del sprint, la línea de horas reales comenzó a acercarse nuevamente a la línea de horas estimadas. A pesar de esta estabilización, el equipo logró finalizar todas las tareas dentro del plazo establecido, cumpliendo con los objetivos planificados sin acumulaciones de trabajo al final del sprint.

4.3.2.1.2 Velocidad del equipo. El cálculo de la velocidad del sprint es una herramienta clave para medir la eficiencia del equipo en la realización de las tareas asignadas dentro del tiempo establecido. Este indicador es esencial para evaluar la capacidad de entrega en futuras iteraciones, ya que ofrece datos concretos sobre el rendimiento del equipo y permite ajustar la planificación de los siguientes sprints según la realidad del desarrollo (Gaete et al, 2021).

Teniendo en cuenta lo anterior, se procedió a realizar el cálculo de la velocidad del equipo utilizando la siguiente fórmula:

$$V = \frac{T}{t} \cdot 100$$

Donde T representa los puntos de trabajo completados y t es el total de jornadas trabajadas, obtenidas al multiplicar el número de integrantes del equipo (N) por la cantidad de días hábiles del sprint (J). En este caso, con dos integrantes trabajando durante 15 días hábiles, se tiene:

t = 2 · 15 = 30

Dado que el total de puntos de trabajo realizados fue de 26, la velocidad del sprint se obtiene como:

$$V = \frac{26}{30} \quad V = \quad = 86.7\%$$

El resultado muestra que el equipo alcanzó una velocidad del 86.7%, lo que indica un alto nivel de eficiencia en la ejecución del trabajo. Este porcentaje refleja que la mayoría de las tareas se completaron dentro del tiempo estimado y que el sprint se llevó a cabo sin retrasos ni acumulación de trabajo al final de la iteración.

El rendimiento observado en este primer sprint evidencia una ejecución efectiva del plan de trabajo, con una adecuada distribución de las tareas y una gestión eficiente del tiempo. El equipo logró avanzar rápidamente en la primera mitad del sprint, optimizando la entrega de tareas, y luego ajustó su ritmo en la fase final para asegurar la finalización de las actividades más complejas. Esto permitió que el sprint concluyera de manera satisfactoria, sin comprometer los plazos de entrega ni la calidad del desarrollo.

4.3.2.2 Planificación del sprint 2. Para la planificación del Sprint 2, se tomó como referencia la velocidad del Sprint 1 para estimar la cantidad de trabajo que se podía abordar en esta iteración. Basado en la metodología Scrum, se realizó un cálculo de la capacidad del equipo en función del tiempo disponible y las posibles ausencias, asegurando una planificación realista y alineada con el rendimiento observado en el primer sprint.

La velocidad calculada del Sprint 1 fue del 86.7%. El equipo se mantuvo con dos integrantes, con una duración del Sprint de 15 días hábiles, trabajando en jornadas de 8 horas diarias por persona. Con estos datos, se calculó la capacidad total de trabajo disponible utilizando la fórmula:

t = (N)(J)(H)

donde:

t = (2) (15) (8) = 240 horas disponibles

Dado que la velocidad del Sprint 1 fue 86.7%, se aplicó esta proporción para determinar la cantidad de horas de trabajo abordables en el Sprint 2:

T = (0.867) (240) =208.08 horas

Para obtener una estimación más precisa, se consideraron posibles ausencias o interrupciones en el equipo durante la ejecución del sprint. Se estableció un margen de 20 horas de ausencias estimadas, lo que llevó a la siguiente corrección:

T = 208 – 20 = 188 horas

T ≤ 188 horas

Este resultado permitió definir la cantidad de trabajo que se podía abordar en el Sprint 2, las cuales corresponden a 152 horas, cumpliendo con la capacidad estimada del equipo.

4.3.2.2.1 Sprint 2. Diagnóstico, recomendaciones e información climática. El segundo sprint se enfocó en desarrollar funcionalidades clave para identificar y diagnosticar enfermedades en el cultivo de tomate, así como en generar recomendaciones basadas en los resultados obtenidos e integrar información climática. Durante esta iteración, se priorizó la implementación del módulo para capturar y procesar imágenes, asegurando que el sistema pudiera analizar con precisión las hojas del cultivo y ofrecer un diagnóstico confiable. También se trabajó en mejorar la experiencia del usuario mediante una interfaz intuitiva y la inclusión de datos relevantes para la toma de decisiones agrícolas.

Para ello, se consideraron cuatro historias de usuario del Product Backlog refinado (Ver apéndice C) (ST-01-5, ST-01-6, ST-01-7 y ST-01-8). Como primer paso, se implementó la funcionalidad que permite abrir la cámara del dispositivo desde la aplicación móvil, facilitando a los agricultores la captura de imágenes de las hojas de tomate. Luego, se diseñó un flujo de

captura de imágenes que incluye un mensaje de espera para informar al usuario mientras se procesa la imagen. En esta etapa, se integró el modelo de red neuronal EfficientNetB7, previamente entrenado para detectar y clasificar enfermedades en el cultivo con un alto nivel de precisión. La incorporación de este modelo en la aplicación permitió automatizar el diagnóstico y mejorar la fiabilidad del sistema.

Así mismo, se trabajó en la lógica para diagnosticar enfermedades, asegurando que el sistema pudiera interpretar los resultados del análisis de imágenes y presentarlos de manera clara para el usuario. En los casos en que la hoja analizada no muestra signos de enfermedad, el sistema informa al usuario que el cultivo está sano, evitando confusiones y facilitando la toma de decisiones.

Otro aspecto clave de este sprint fue la generación de recomendaciones basadas en el diagnóstico obtenido. Para ello, se llevó a cabo una investigación sobre las medidas correctivas más efectivas para cada enfermedad y dependiendo de la enfermedad detectada, se le presentan al agricultor las acciones recomendadas que el agricultor puede implementar.

Además, se trabajó en la integración de información climática dentro de la aplicación, es por esto que se seleccionó y se conectó al API climática Meteoblue, la cual permite que el sistema proporcione datos meteorológicos actualizados en tiempo real. A través de una interfaz intuitiva, el usuario puede consultar predicciones del clima a futuro y adaptar su planificación agrícola según las condiciones climáticas esperadas.

A continuación, se muestran los diseños correspondientes del aplicativo móvil que fueron desarrollados en el sprint 2.

Figura 51

Interfaz gráfica de la vista del home

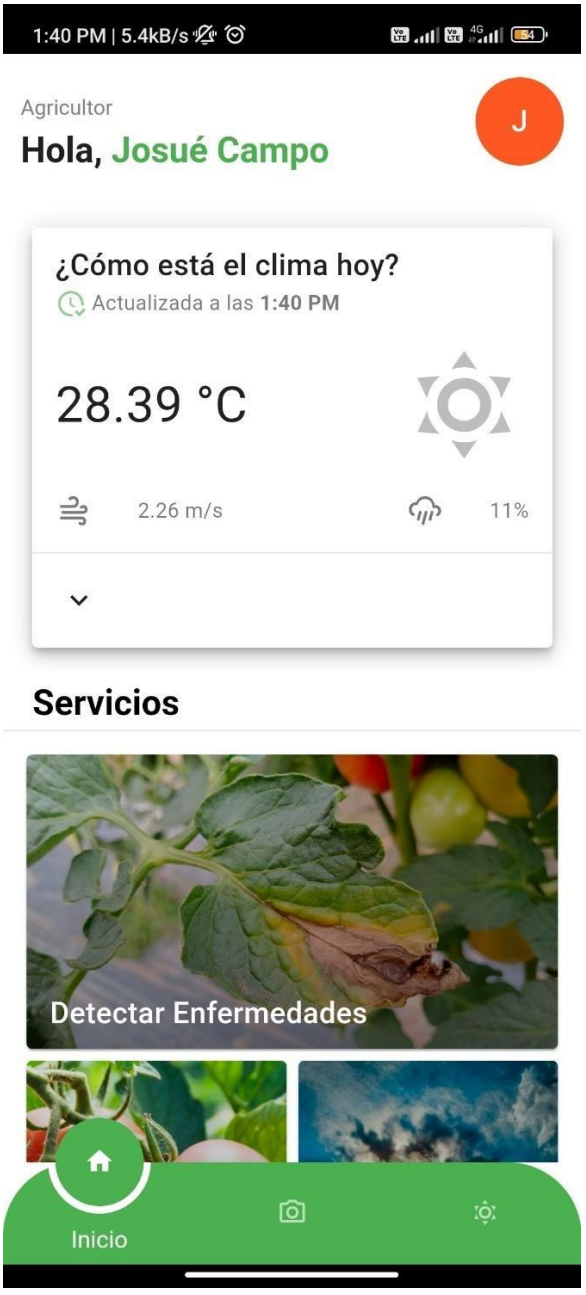


Figura 52

Interfaz gráfica de la sección de captura de imágenes



Figura 53

Interfaz gráfica de la sección de captura de imágenes

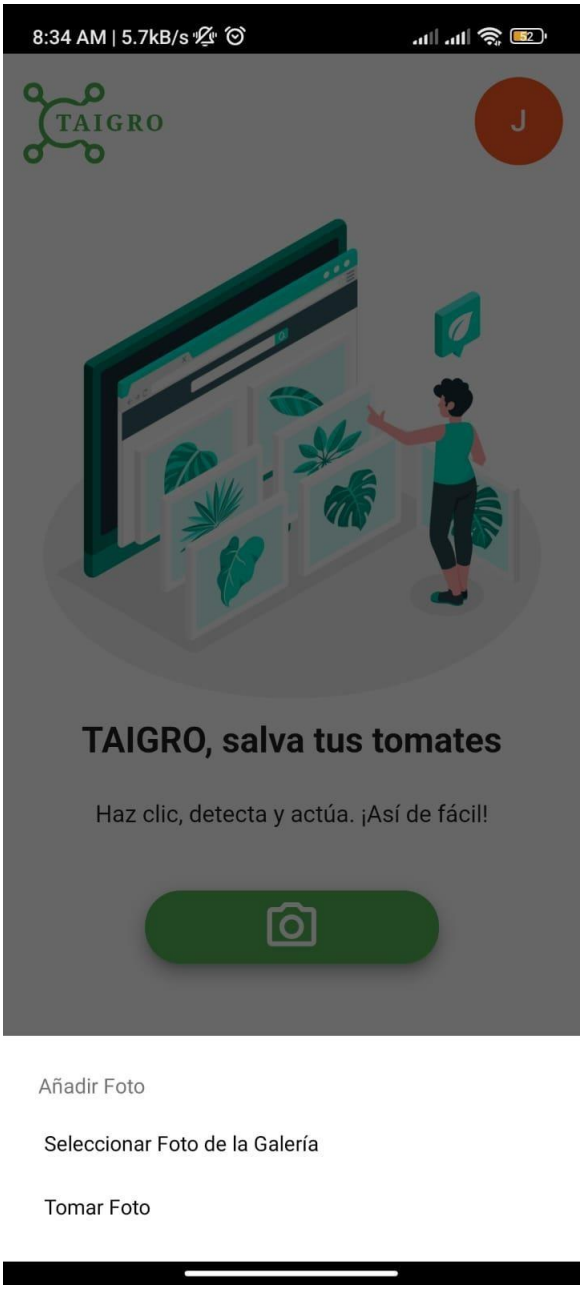


Figura 54

Interfaz gráfica de visualización de la enfermedad detectada



Figura 55

Interfaz gráfica sobre información de la enfermedad y como tratarla

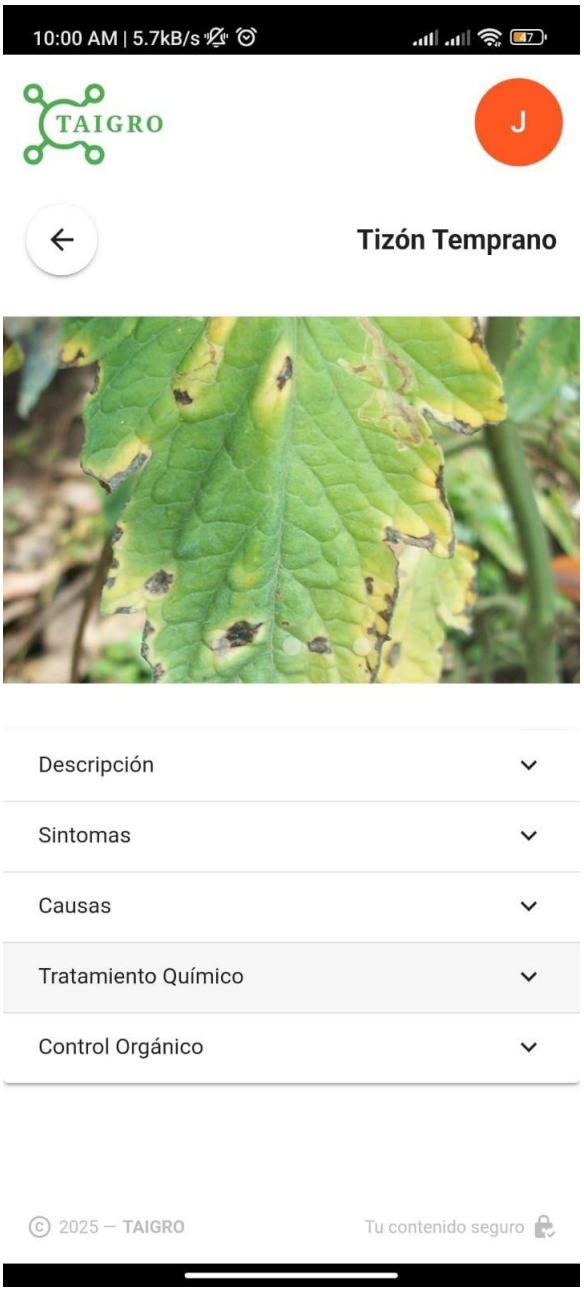


Figura 56

Interfaz gráfica sobre información de la enfermedad y como tratarla

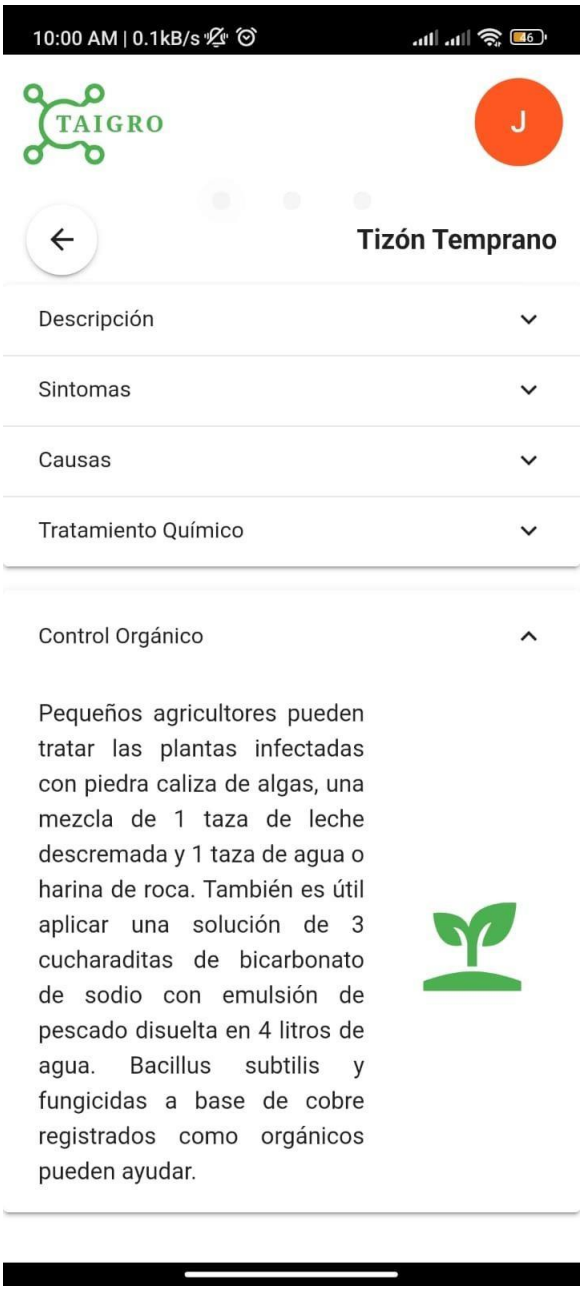


Figura 57

Interfaz gráfica de la sección de información climática

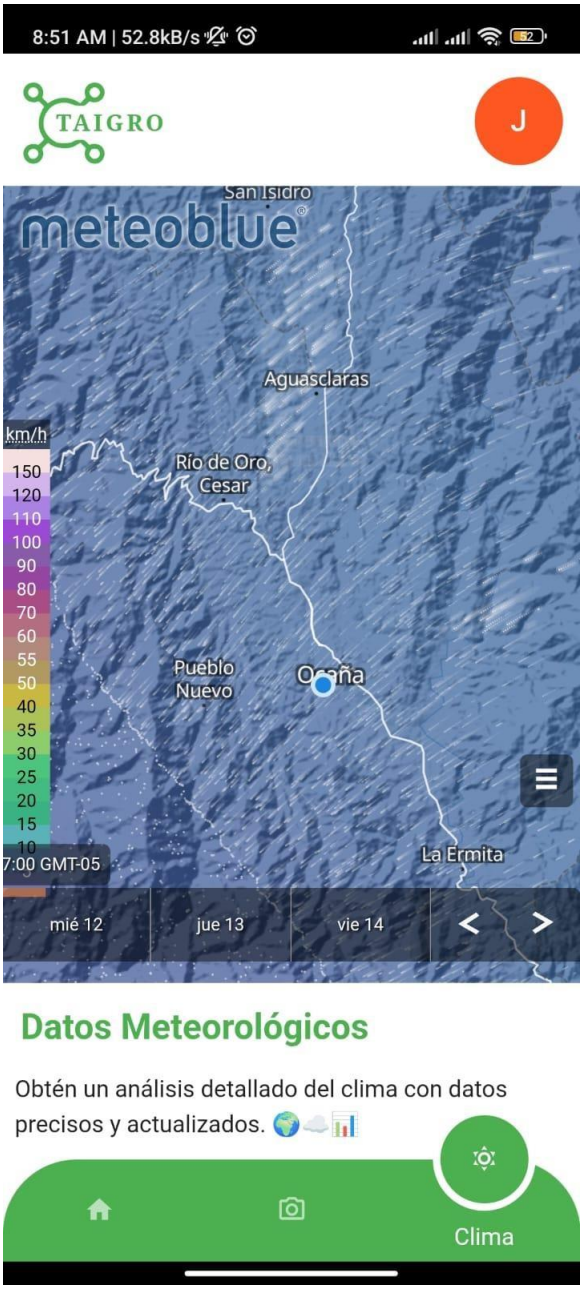
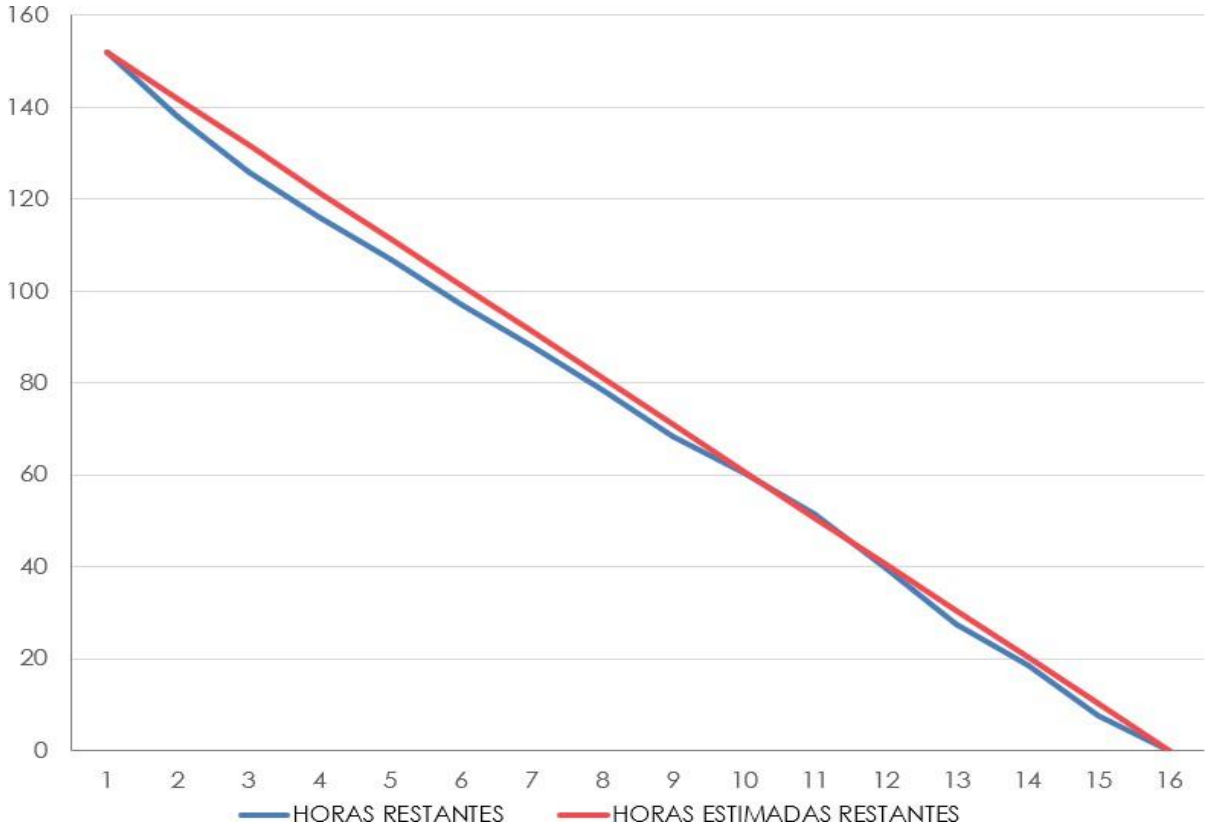


Figura 58

Análisis del Desempeño del Sprint 2

HORAS RESTANTES	152	138	126	116	107	97	88	78,5	68,5	60,5	51,5	39,5	27,5	18,5	7,5	0
ESTIMADAS RESTANTES	152	141,9	131,7	121,6	111,5	101,3	91,2	81,1	70,9	60,8	50,7	40,5	30,4	20,3	10,1	0,0



Desde el inicio de este sprint, se puede notar una diferencia significativa entre ambas líneas, donde la línea azul empieza a estar por debajo de la línea estimada. Este comportamiento indica que el equipo logró completar algunas tareas antes de lo previsto, mostrando un rendimiento superior en la ejecución. La eficiencia en esta fase se debió a la rápida resolución de tareas bien definidas y a una optimización en los flujos de trabajo, lo que permitió avanzar más rápidamente.

A partir del día 10, la diferencia entre ambas líneas comienza a disminuir, lo que muestra que el ritmo de trabajo se ajustó a la complejidad de las tareas restantes. En esta etapa del sprint, el equipo se enfrentó a actividades que requerían un mayor esfuerzo técnico y tiempos de desarrollo más largos. La ejecución demandó un enfoque más detallado en la implementación de funcionalidades clave, lo que llevó a una estabilización en la reducción de horas restantes.

Al llegar al día 15, ambas líneas convergen en cero, lo que indica que todas las tareas se completaron dentro del tiempo estimado. Esto confirma que el equipo logró gestionar adecuadamente la carga de trabajo y finalizar el sprint sin acumulaciones al final de la iteración. La ejecución mantuvo un equilibrio entre la planificación y la realidad del desarrollo, permitiendo cumplir con los objetivos establecidos y garantizando la entrega de las funcionalidades planificadas sin retrasos.

4.4 Evaluar el nivel de satisfacción de los agricultores con respecto a los resultados que brinda el aplicativo móvil a la hora de diagnosticar la enfermedad y formular el tratamiento adecuado que debe seguir en su cultivo de tomate

Con el propósito de evaluar el nivel de satisfacción de los agricultores con respecto al uso de la aplicación móvil, se diseñó un instrumento de medición tipo escala Likert de cinco niveles (Apéndice C). Este instrumento permitió medir la aceptación y efectividad del sistema en términos de usabilidad, precisión del diagnóstico, claridad de las recomendaciones, relevancia de la información climática, confiabilidad general del aplicativo y satisfacción general del usuario.

Antes de que los agricultores completaran el instrumento de medición, se realizó una sesión virtual en la que se presentó el aplicativo móvil de manera detallada, es decir se hicieron demostraciones sobre el proceso de captura de imágenes, análisis e interpretación de los diagnósticos generados por la aplicación, además, se respondieron algunas inquietudes que se tenían en ese momento, con el fin de esclarecer lo mayor posibles dudas, y dar a entender de manera adecuada el correcto funcionamiento de la aplicación móvil (ver Apéndice D). Debido a que no todos los agricultores pudieron asistir a la reunión que se planificó, se realizó un video explicativo para ayudar en el aprendizaje del uso del aplicativo. Este proceso de adaptación, se realizó durante una semana y media, en la que a medida que los agricultores le daban uso a la aplicación, se iban adatando a las funcionalidades existentes en dicho aplicativo, todo esto con el fin, de que cuando diligenciaran el cuestionario, estuvieran completamente familiarizados con la herramienta.

Después de la etapa de familiarización, se llevó a cabo la aplicación del instrumento de medición mediante Google Forms, el cual se aplicó al 23% de la población de agricultores de tomate de las zonas rurales de Llano del pozo, San Javier y el campanario, los cuales dieron su valoración con respecto a los ítems mencionados anteriormente, logrando así una muestra representativa de las respuestas de los agricultores que utilizaron el sistema en sus cultivos.

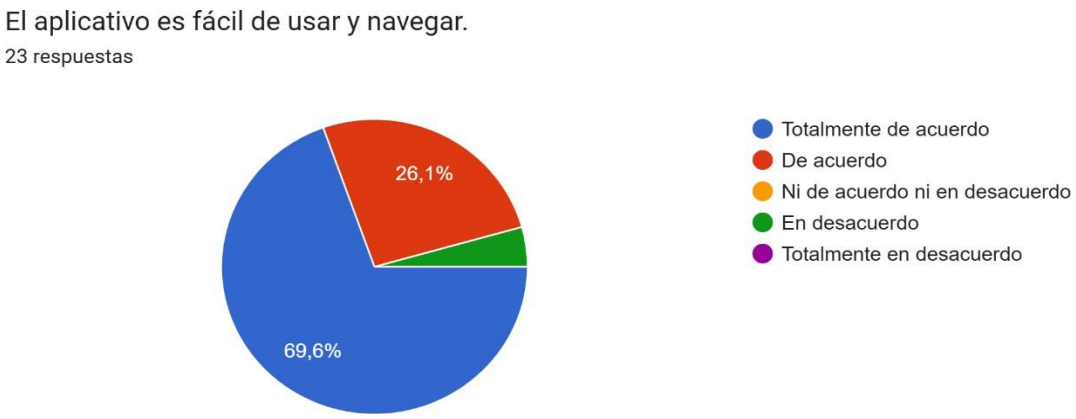
A continuación, se presentan los resultados de la evaluación en el nivel de satisfacción de los usuarios con respecto al uso del aplicativo:

4.4.1 Facilidad de uso y navegación

La mayoría de los usuarios (69.6%) indicaron estar "Totalmente de acuerdo" en que el aplicativo es fácil de usar y navegar, mientras que un 26.1% estuvo "De acuerdo", y solo un pequeño porcentaje (4%) expresó desacuerdo. Esto sugiere que la interfaz es intuitiva y facilita la experiencia del usuario.

Figura 59

Facilidad de uso y navegación



4.4.1.1 Interfaz clara y organizada. Un 73.9% de los usuarios afirmó estar "Totalmente de acuerdo" en que la interfaz es clara y bien estructurada, seguido de un 26.1% que estuvo "De acuerdo".

Figura 60

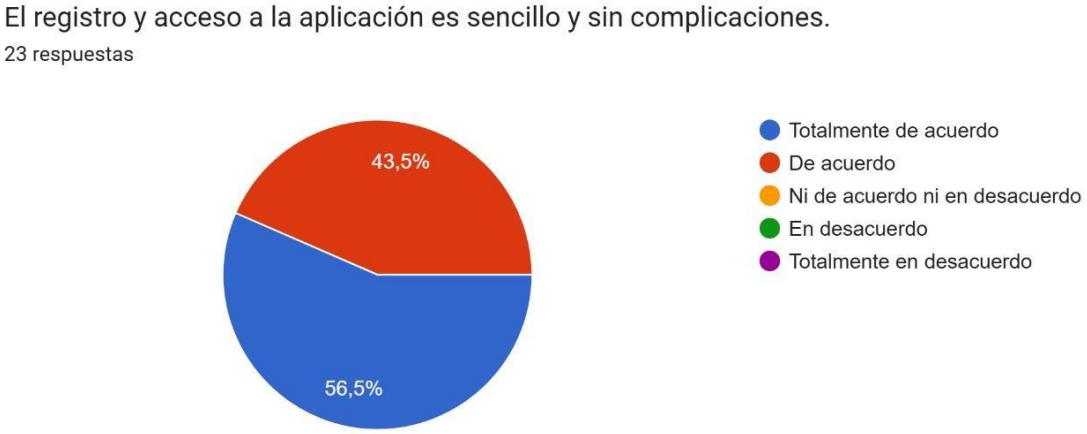
Interfaz clara y organizada



4.4.1.2 Registro y acceso a la aplicación. El 56.5% de los usuarios consideró que el registro y acceso al sistema es sencillo y sin complicaciones, mientras que el 43.5% estuvo "De acuerdo.

Figura 61

Registro y acceso a la aplicación



4.4.1.3 Uso de la cámara para capturar imágenes. El 65.2% de los usuarios estuvo "Totalmente de acuerdo" en que la funcionalidad de la cámara es fácil de utilizar, y un 34.8% lo consideró "De acuerdo". Esto evidencia que la integración de la cámara en la aplicación es intuitiva y cumple con las expectativas del usuario.

Figura 62

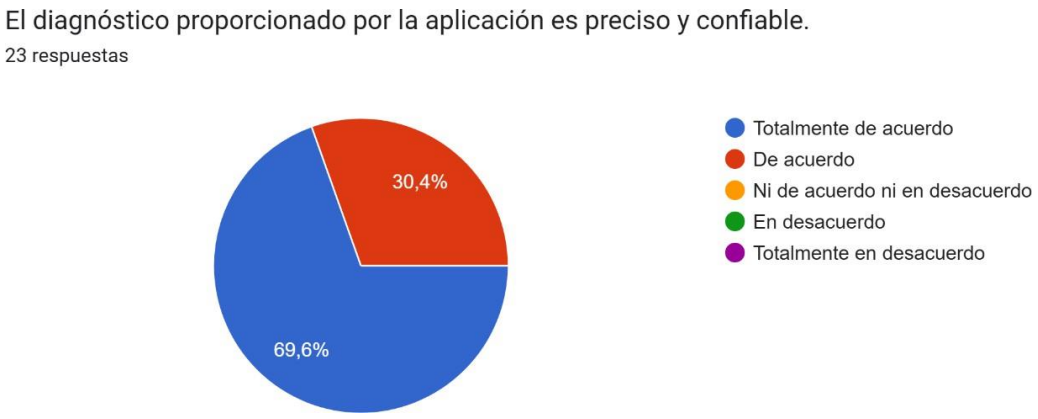
Uso de la cámara para capturar imágenes



4.4.1.4 Precisión del diagnóstico. Una gran mayoría (69.6%) manifestó estar "Totalmente de acuerdo" en que el diagnóstico proporcionado por la aplicación es preciso y confiable, mientras que un 30.4% estuvo "De acuerdo". Esto indica un alto nivel de confianza en la capacidad de la inteligencia artificial para la detección de enfermedades.

Figura 63

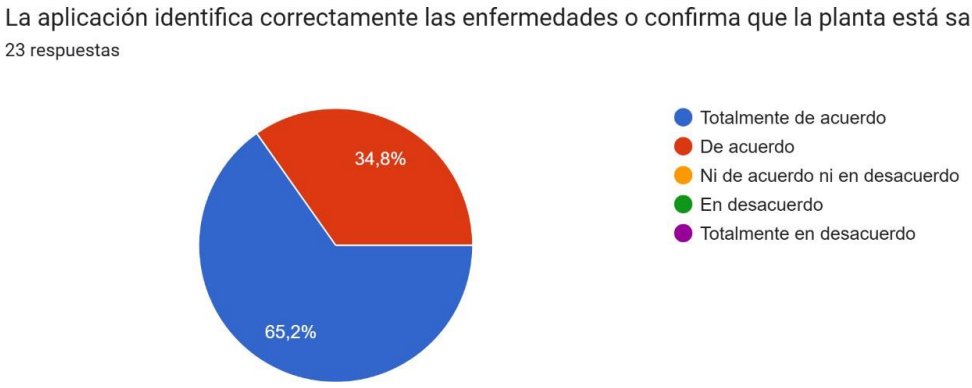
Precisión del diagnóstico



4.4.1.5 Identificación correcta de enfermedades. Un 65.2% de los usuarios expresó estar "Totalmente de acuerdo" en que la aplicación identifica correctamente las enfermedades o confirma si la planta está sana, con un 34.8% adicional en la categoría "De acuerdo". Esto respalda la efectividad del modelo de redes neuronales implementado.

Figura 64

Identificación correcta de enfermedades



4.4.1.6 Utilidad de la imagen de referencia. El 65.2% de los encuestados consideró que la imagen de referencia ayuda a entender mejor la enfermedad detectada, mientras que el 34.8% estuvo "De acuerdo". Esto confirma que la inclusión de imágenes de referencia complementa la experiencia del diagnóstico.

Figura 65

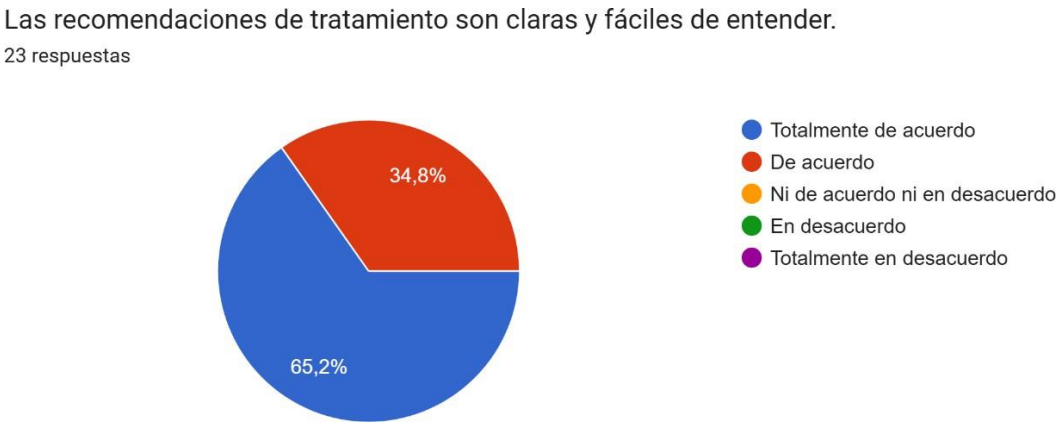
Utilidad de la imagen de referencia



4.4.1.7 Claridad en las recomendaciones de tratamiento. El 65.2% de los usuarios manifestó estar "Totalmente de acuerdo" con la claridad de las recomendaciones de tratamiento, seguido por un 34.8% que estuvo "De acuerdo". Esto indica que la información brindada para el manejo de enfermedades es comprensible para los agricultores.

Figura 66

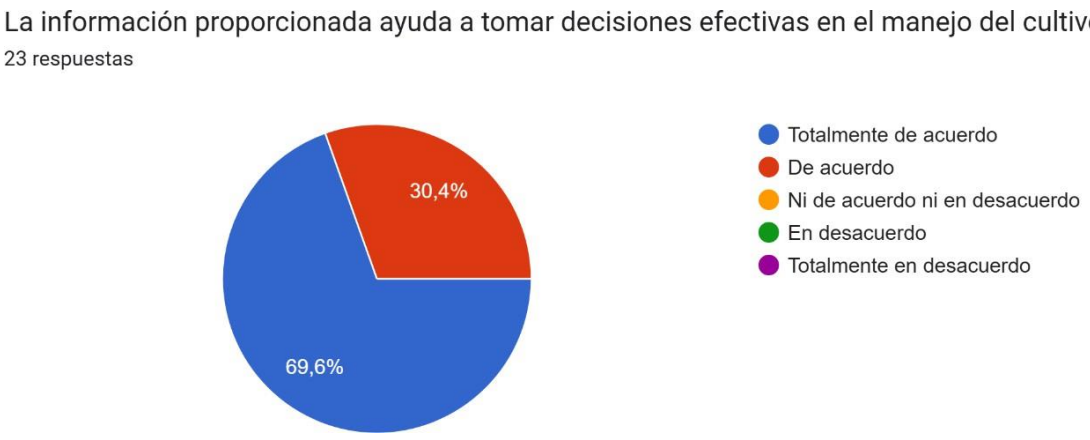
Claridad en las recomendaciones de tratamiento



4.4.1.8 Utilidad de la información proporcionada. Un 69.6% de los encuestados consideró que la información brindada por la aplicación ayuda a tomar decisiones efectivas en el manejo del cultivo, además un 30.4% indicó que estaban "De acuerdo". Esto indica que los agricultores encuentran valor en los datos generados por la aplicación.

Figura 67

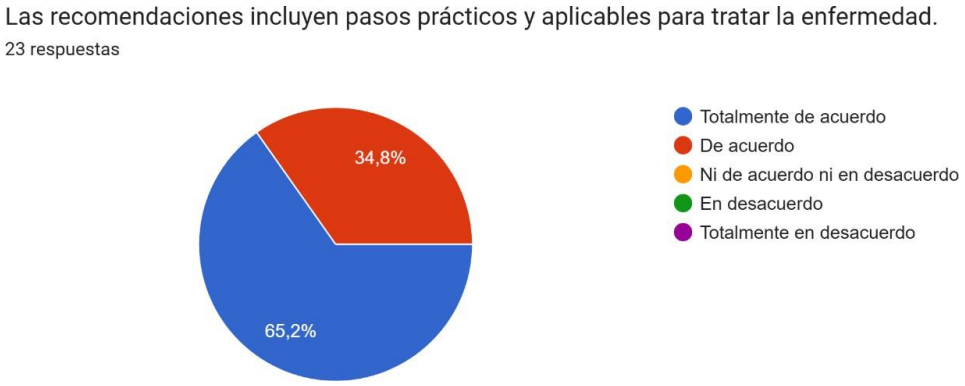
Utilidad de la información proporcionada



4.4.1.9 Aplicabilidad de los pasos recomendados. Un 65.2% estuvo "Totalmente de acuerdo" en que los pasos recomendados para tratar las enfermedades son prácticos y aplicables, mientras que el 34.8% estuvo "De acuerdo". Este resultado muestra que las recomendaciones son implementables en el campo.

Figura 68

Aplicabilidad de los pasos recomendados



4.4.1.10 Información climática como herramienta de planificación. El 69.6% de los usuarios manifestó que la información climática incluida en la aplicación es útil para la planificación del cultivo, con un 30.4% adicional "De acuerdo". Esto confirma que la integración de datos climáticos es relevante para la toma de decisiones.

Figura 69

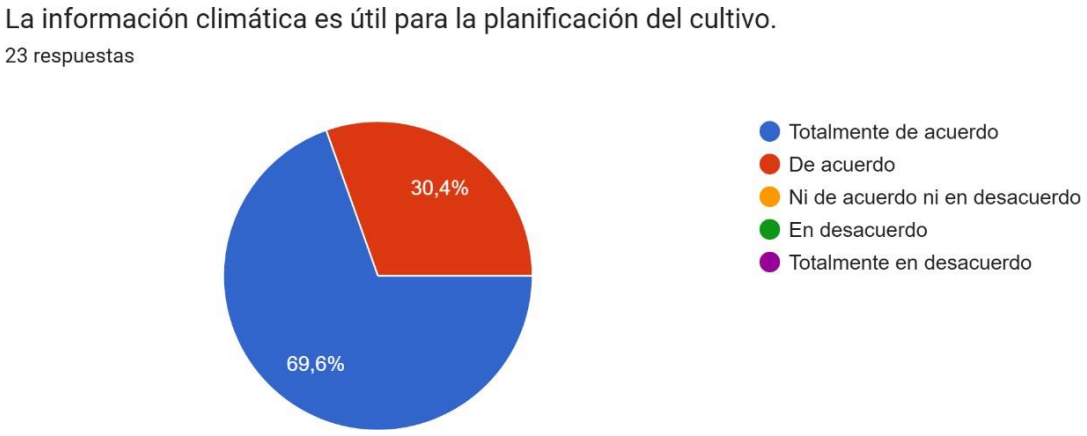
Información climática como herramienta de planificación



4.4.1.11 Precisión de la predicción del clima. Un 69.6% de los encuestados expresó estar "Totalmente de acuerdo" con la precisión de la predicción del clima, mientras que el 30.4% estuvo "De acuerdo". Esto indica que la aplicación logra brindar información climática confiable.

Figura 70

Precisión de la predicción del clima



4.4.1.12 Estabilidad del sistema. La aplicación funciona sin interrupciones o errores frecuentes según el 65.2% de los encuestados que estuvieron "Totalmente de acuerdo", mientras que un 34.8% estuvo "De acuerdo". Un bajo porcentaje expresó desacuerdo, lo que sugiere que la estabilidad del sistema es adecuada.

Figura 71

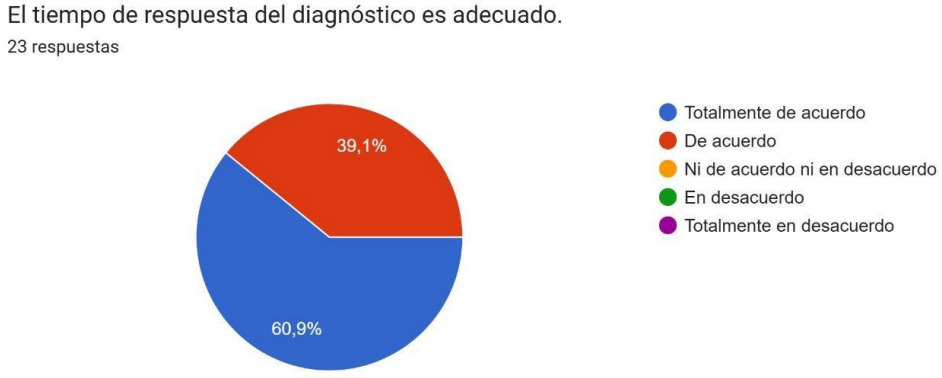
Estabilidad del sistema



4.4.1.13 Tiempo de respuesta del diagnóstico. Un 60.9% de los usuarios consideró que el tiempo de respuesta del diagnóstico es adecuado, mientras que otro 39.1% estuvo "De acuerdo". Esto indica que, aunque el rendimiento es bueno, podría optimizarse aún más.

Figura 72

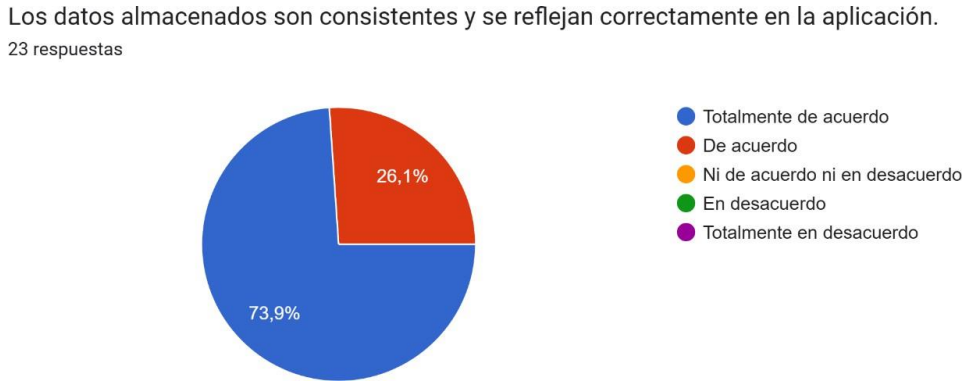
Tiempo de respuesta del diagnóstico



4.4.1.14 Consistencia de los datos almacenados. Un 73.9% indicó estar "Totalmente de acuerdo" en que los datos almacenados en la aplicación son consistentes y se reflejan correctamente, mientras que el 26.1% estuvo "De acuerdo". Esto confirma que la gestión de datos en la aplicación es confiable.

Figura 73

Consistencia de los datos almacenados



4.4.1.15 Satisfacción general con la aplicación. Un 73.9% de los encuestados indicó estar "Totalmente de acuerdo" en que están satisfechos con la aplicación, con un 26.1% adicional en la categoría "De acuerdo". Esto indica una alta aceptación de la herramienta.

Figura 74

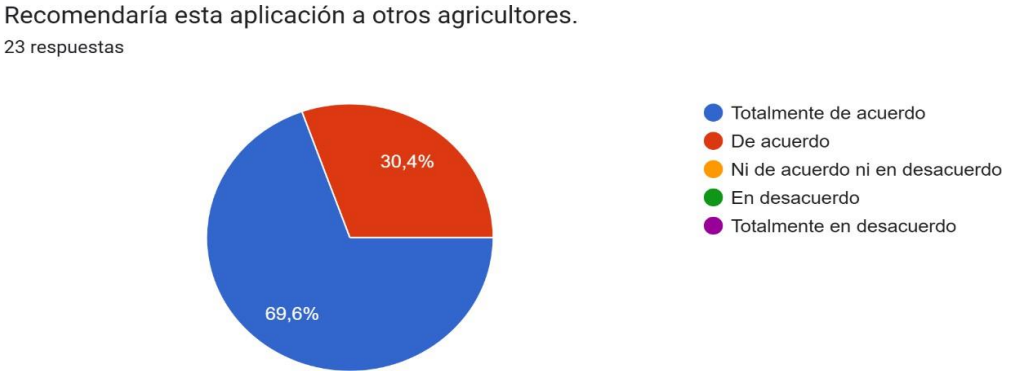
Satisfacción general con la aplicación



4.4.1.16 Recomendación a otros agricultores. Finalmente, un 69.6% de los usuarios afirmó que recomendaría la aplicación a otros agricultores, con un 30.4% "De acuerdo". Este resultado es un fuerte indicador de la percepción positiva del aplicativo.

Figura 75

Recomendaría esta aplicación a otros agricultores



Teniendo en cuenta los resultados obtenidos en el anterior instrumento de medición, se puede observar un alto grado de aceptación del aplicativo móvil por parte del 23% de la

población de agricultores de la zona rural de Llano del Pozo, San Javier y El Campanario. Se observa que la mayoría de los encuestados consideran que la interfaz es clara, la información climática es relevante y el diagnóstico proporcionado es preciso y confiable, lo que evidencia la efectividad del sistema que permite la detección de enfermedades en los cultivos de tomate.

Por último, se realizó un análisis de consistencia interna utilizando el Alfa de Cronbach, con el fin de validar la confiabilidad del instrumento de medición. Este análisis permitió comprobar la coherencia y estabilidad de las respuestas obtenidas, garantizando que el cuestionario aplicado fuera confiable para medir la percepción de los agricultores. A continuación, se presentan los resultados de este análisis, que ofrecen una evaluación cuantitativa de la fiabilidad del instrumento.

Tabla 23

Alfa de Cronbach

	ITEMS - CANTIDAD DE PREGUNTAS																	
ENCUESTADOS	**1**	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**	**11**	**12**	**13**	**14**	**15**	**16**	**17**	**SUMA**
E1	5	5	4	5	5	5	5	5	5	5	5	4	4	4	5	5	5	**81**
E2	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	**68**
E3	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	**68**
E4	2	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	**66**
E5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	**85**
E6	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	**85**
E7	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	**85**
E8	5	5	5	4	4	4	5	5	5	5	5	5	5	5	5	5	5	**82**
E9	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	**85**
E10	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	**85**
E11	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	**68**
E12	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	**85**
E13	5	5	4	5	5	5	5	5	5	5	5	5	5	5	5	5	5	**84**
E14	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	**85**
E15	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	**85**
E16	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	**85**
E17	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	**85**
E18	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	**68**
E19	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	**85**
E20	5	4	4	5	5	5	4	4	4	4	4	4	4	4	5	4	4	**73**
E21	4	5	4	4	5	4	5	4	4	5	5	4	5	5	4	5	4	**76**
E22	5	5	5	4	5	4	4	4	5	4	4	5	5	4	5	5	5	**78**
E23	4	5	4	5	4	5	4	5	5	4	5	5	4	4	5	5	5	**78**
VARIANZA	**0,499**	**0,193**	**0,246**	**0,227**	**0,212**	**0,227**	**0,227**	**0,227**	**0,212**	**0,227**	**0,212**	**0,227**	**0,227**	**0,238**	**0,193**	**0,193**	**0,212**	
SUMATORIA DE VARIANZAS	**3,996**																	
VARIANZA DE LA SUMA DE LOS ÍTEMS	**49,183**																	

Teniendo en cuenta los datos anteriores, se realiza el respectivo cálculo, mediando la fórmula de fórmula del Alfa de Cronbach, la cual se usó para medir la confiabilidad del instrumento de medición aplicado.

$$\alpha = \frac{K}{K-1}\left[1 - \frac{\sum S_i^{\,2}}{S_T^{\,2}}\right]$$

Dando como resultado un 0.98 de coeficiente de confiabilidad del cuestionario.

α:	Coeficiente de confiabilidad del cuestionario	**0,98**
k:	Número de ítems del instrumento	17
$\sum_{i=1}^{k} S_i^2$:	Sumatoria de las varianzas de los ítems.	3,996
S_t^2:	Varianza total del instrumento.	49,183

RANGO	CONFIABILIDAD	
0.53 a menos	Confiabilidad nula	
0.54 a 0.59	Confiabilidad baja	
0.60 a 0.65	Confiable	
0.66 a 0.71	Muy confiable	
0.72 a 0.99	Excelente confiabilidad	0,98 Nuestro instrumento es de excelente confiabilidad
1	Confiabilidad perfecta	

El análisis del coeficiente de confiabilidad del cuestionario, que se calculó usando el Alfa de Cronbach, dio un valor de 0.98. Esto sugiere que el instrumento de medición tiene una excelente confiabilidad. Este resultado confirma que las preguntas de la encuesta tienen una alta consistencia interna, lo que asegura que los datos recopilados son fiables. La suma de las varianzas de los ítems, junto con la varianza total del instrumento, respalda la estabilidad de las respuestas obtenidas. Esto permite validar que el cuestionario es adecuado para evaluar cómo perciben los agricultores el uso del aplicativo móvil. Con base a los resultados, se puede afirmar que las mediciones garantizan la calidad de los datos para futuras interpretaciones y análisis.

5. Generación de conocimiento

A continuación, se muestran los certificados como ponente a diferentes eventos nacionales e internacionales, eventos de semilleros y maratones de programación.

5.1 Participación en eventos como ponente

5.1.1 Participación como ponente en la feria de proyectos de aula año 2020

En la feria de proyectos de proyectos de aula del año 2020, se logró obtener el tercer puesto en la categoría Junior.

Figura 76

Certificado de participación de Yeison Danuil Ascanio en la feria de proyectos de aula 2020



Figura 77

Certificado de participación de Josue Campo en la feria de proyectos de aula 2020



5.1.2 Participación como ponente en la feria de proyectos de aula año 2023-1

En la feria de proyectos de aula del primer semestre del año 2023, se logró obtener el segundo puesto en la categoría senior.

Figura 78

Certificado de participación de Yeison Ascanio en la feria de proyectos de aula 2023-1



Figura 79

Certificado de participación de Josue Campo en la feria de proyectos de aula 2023-1



5.1.3 Participación como ponente en la feria de proyectos de aula año 2023-2

En la feria de proyectos de aula del segundo semestre del año 2023, se logró obtener el primer puesto en la categoría experto.

Figura 80

Certificado de participación de Yeison Ascanio y Josue Campo en la feria de proyectos de aula 2023-2



5.1.4 Encuentro de Semilleros de Investigación ENSI 2021

Yeison Ascanio participó como ponente en este evento, en el cual expuso un proyecto desarrollado en el semillero de investigación GPROS de la universidad Francisco de Paula Santander Seccional Ocaña.

Figura 81

Certificado de participación de Yeison Ascanio en el ENSI 2021



5.1.5 Encuentro Regional de Semilleros de Investigación REDCOLSI 2022

Yeison Ascanio participó como ponente en este evento, en el cual expuso un proyecto desarrollado en el semillero de investigación GPROS de la universidad Francisco de Paula Santander Seccional Ocaña.

Figura 82

Certificado de participación de Yeison Ascanio en el REDCOLSI 2022

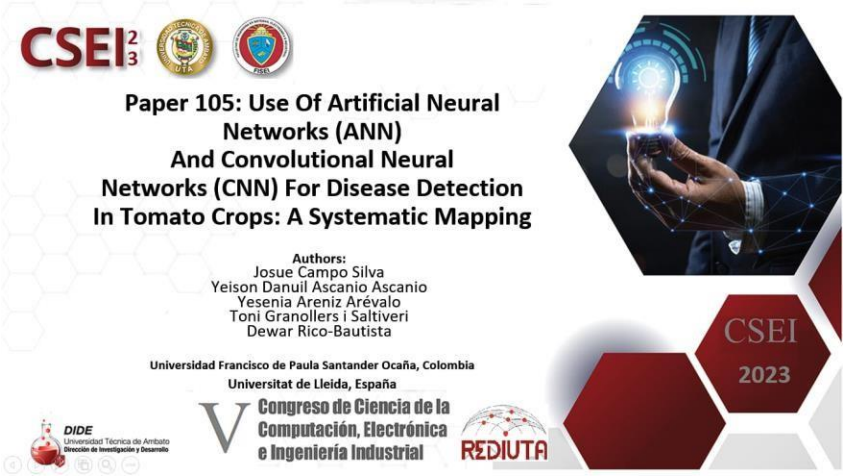


5.1.6 Congreso de Ciencia de la Computación, Electrónica e Ingeniería Industrial

Se participó como ponentes en el evento, mismo que permitió la publicación del artículo titulado “Uso de Redes neuronales artificiales (ANN) y Redes neuronales convolucionales (CNN) para la detección de enfermedades en cultivos de tomates producidos en ambientes controlados: Un mapeo sistemático”.

Figura 83

Certificado de participación en el CSEI 23



5.2 Certificados en maratones de programación

5.2.1 Maratón de programación 2020

Yeison Ascanio participó en “The 2020 ICPC South America-North Finals” en la que obtuvo mención de honor.

Figura 84

Certificado de participación en The 2020 ICPC South America-North Finals



5.2.2 Maratón de programación 2021

Se participó en la XXXIV Maratón Nacional de Programación ACIS REDIS en la ciudad de Bucaramanga, Santander.

Figura 85

Certificado de participación de Yeison Ascanio en la Maratón de programación 2021



Figura 86

Certificado de participación de Josue Campo en la Maratón de programación 2021



5.2.3 Maratón de programación 2022

Se participó en The 2022 ICPC Colombia - XXXVI Maraton Nacional de Programacion ACIS REDIS en la ciudad de Bucaramanga, Santander.

Figura 87

Certificado de participación de Yeison Ascanio en la Maratón de programación 2022



Figura 88

Certificado de participación de Josue Campo en la Maratón de programación 2022



5.2.4 Maratón de programación Expotecnología

Se participó y se obtuvo el primer puesto en la VI Maratón de Programación en el marco de la ejecución de la EXPOTECNOLOGÍA 2021, organizada por la Fundación Universitaria Antonio Arévalo – UNITECNAR, de la ciudad de Cartagena.

Figura 89

Certificado de participación de Yeison Ascanio en la Expotecnología 2021



Figura 90

Certificado de participación de Josue



6. Conclusiones

El análisis del estado del arte ha permitido fundamentar el desarrollo de TAIGRO una aplicación móvil para la detección y clasificación de enfermedades en el cultivo de tomate por medio de redes neuronales convolucionales (CNN). La investigación realizada ha permitido abordar este estudio desde una perspectiva reciente y actualizada. Además, las bases teóricas fueron de gran relevancia para determinar la elección y uso del modelo EfficienteNetB7, el cual logra altos resultados de precisión sin comprometer los recursos computacionales disponibles.

El diseño de la arquitectura de TAIGRO, ha sido un proceso fundamental mediante el cual los procesos a seguir tanto por el aplicativo, como por el equipo de desarrollo fueron correctamente definidos. Lo anteriormente mencionado, permitió que la organización en los flujos de trabajo destacara totalmente en el proyecto. Así mismo, la implicación de los usuarios finales en la retroalimentación de los diseños realizados fue un enfoque bastante acertado, debido al alto porcentaje de satisfacción de los usuarios, en cuanto a la amigabilidad visual del aplicativo.

El proceso de desarrollo del sistema basado en conocimiento que permita la correcta detección e identificación de enfermedades que afectan al cultivo de tomate, ha sido finalizado exitosamente, pues los resultados arrojados demuestran que se alcanzó una precisión del 98.5% en entrenamiento y 95.4% en validación, lo que confirma la capacidad del sistema para clasificar correctamente las enfermedades. Además, el análisis con la matriz de confusión, el mapa de difusión de las características y la gráfica de pérdida y precisión por épocas permitió visualizar la

estabilidad y confiabilidad del modelo en distintos escenarios. Estos resultados confirman que la herramienta desarrollada puede ser utilizada en entornos reales sin comprometer su desempeño.

Por otra parte, el sistema no solo brinda una detección precisa a los agricultores de la enfermedad que tienen las hojas de tomate, sino que también les permite visualizar recomendaciones de como erradicar la enfermedad detectada. Esto contribuye directamente a la toma de decisiones informadas y ayuda a los agricultores a tomar medidas que permitan controlar la expansión de enfermedades en sus cultivos.

En cuanto al nivel de satisfacción evaluado en el 23% de las zonas rurales de Llano del pozo, San Javier y El Campanario, se pudo determinar que un alto número de agricultores se encontraron satisfechos con los resultados arrojados por el aplicativo, aunque también se obtuvo un pequeño porcentaje de agricultores a los que les resultó difícil la navegación por el aplicativo. Lo anteriormente mencionado, evidencia márgenes de mejora para trabajos fututos. Así mismo, la necesidad de seguir implementando proyectos en el sector agrícola, con el fin de buscar un mayor grado de familiaridad con las herramientas tecnológicas.

Por último, este trabajo fue fundamental para entender que, a través de las redes neuronales convolucionales, se pueden realizar detecciones e identificaciones precisas de las diversas enfermedades que atacan los cultivos de tomates.

7. Recomendaciones y trabajos futuros

Para facilitar el uso del aplicativo en áreas con conectividad limitada, se propone la creación de un modo offline, lo que permitirá a los agricultores utilizar la herramienta sin depender de una conexión a internet constante.

Además, es esencial ampliar el conjunto de datos de entrenamiento, incluyendo más enfermedades y extendiendo la detección a otros cultivos. Esto ayudará a mejorar la precisión del diagnóstico y a aumentar la aplicabilidad del sistema en diversas regiones agrícolas, beneficiando a un mayor número de agricultores.

También, es esencial tener en cuenta los resultados obtenidos en el instrumento de medición para evaluar la satisfacción de uso, en el que se obtiene un bajo número de personas a las que le resulta de difícil uso el aplicativo, esto con el fin de subsanar este pequeño porcentaje y que el sistema sea de fácil uso para todos los agricultores.

Finalmente, es esencial incorporar una funcionalidad que permita guardar un historial de las enfermedades detectadas, esto para brindarle al agricultor la posibilidad de visualizar aquellas enfermedades que ya detectó con antelación, sin necesidad de estar enviando constantemente la misma foto.

Referencias

Akbar Hidayatuloh, M. N. (2021). *Identification of Tomato Plant Diseases by Leaf Image Using Squeezenet Model.* https://ieeexplore.ieee.org/document/8696087

Al-Fedaghi, S. (Julio de 2021). *Beyond SDLC: Process Modeling and Documentation Using Thinging Machines.* file:///C:/Users/casca/Downloads/Beyond_SDLC_Process_Modeling_and_Documentation_Usi.pdf

Allende. (2020). *Manual de cultivo del tomate al aire libre Capítulo 1. Importancia Y Consideraciones Del Cultivo De Tomate.* https://es.slideshare.net/slideshow/manual-de-tomate-invernadero/137362044

Altalak, M. U. (2022). *A Hybrid Approach for the Detection and Classification of Tomato Leaf Diseases. Applied Sciences (Switzerland*. https://doi.org/10.3390/app12168182

Anshul Bathia, A. C. (2024). *Hybrid SVM-LR Classifier for Powdery Mildew Disease Prediction in Tomato Plant.* https://ieeexplore.ieee.org/document/9071202

Antonio Torralba & Elexei A. Efros. (2011). *Unbiased look at dataset bias.* https://ieeexplore.ieee.org/document/5995347

Avila Perez, G. A. (2022). *Entrenamiento de redes neuronales para la identificación de plagas en cultivos de café.* http://repository.pedagogica.edu.co/handle/20.500.12209/18306

Baser, P. S. (2023). *TomConv: An Improved CNN Model for Diagnosis of Diseases in Tomato Plant Leaves.* https://www.sciencedirect.com/science/article/pii/S1877050923001606?via%3Dihub

Chang Xu, J. D. (Junio de 2022). *Tomato disease and pest diagnosis method based on the Stacking of prescription data.* https://www.sciencedirect.com/science/article/abs/pii/S0168169922003143?via%3Dihub

Chen, H.-C. W.-W.-E. (2022). *AlexNet Convolutional Neural Network for Disease Detection and Classification of Tomato Leaf.* https://www.mdpi.com/2079-9292/11/6/951

Chen, J.-W. L.-J.-J.-L.-Y.-P. (2021). *A smartphone-based application for scale pest detection using multiple-object detection methods. Electronics (Switzerland).* https://doi.org/10.3390/electron

Chen, S. H. (Noviembre de 2022). *A surface defect detection system for golden diamond pineapple based on CycleGAN and YOLOv4.* https://www.sciencedirect.com/science/article/pii/S1319157822002452?via%3Dihub

Congreso de Colombia. (2024). *Proyecto de Ley 059-23 Inteligencia artificial.* https://consultorsalud.com/wp-content/uploads/2023/08/PL-059-23-Inteligencia-artificial.pdf

Dane. (2025). *Encuesta nacional agropecuaria (ENA).* https://www.dane.gov.co/index.php/estadisticas-por-tema/agropecuario/encuesta-nacional-agropecuaria-ena

David Ireri, E. B. (2021). *A computer vision system for defect discrimination and grading in tomatoes using machine learning and image processing.* https://www.sciencedirect.com/science/article/pii/S2589721719300194?via%3Dihub

Dbaexperts.tech. (01 de Septiembre de 2023). *Marco legal y regulaciones en torno al uso de la inteligencia artificial y el Big Data.* https://dbaexperts.tech/wp/inteligencia-

artificial/marco-legal-y-regulaciones-en-torno-al-uso-de-la-inteligencia-artificial-y-el-big-data/

Decognet, V. B.-C. (2009). *Rapid Change in the Genetic Diversity of Botrytis cinerea Populations After the Introduction of Strains in a Tomato Glasshouse.* https://apsjournals.apsnet.org/doi/10.1094/PHYTO-99-2-0185

Esri Colombia. (01 de Septiembre de 2021). *Veredas de Colombia*. https://datosabiertos.esri.co/datasets/esri-colombia::veredas-de-colombia/explore?filters=eyJOT01CUkVfVkVSIjpbIkVMIFBPWk8iLCJDQU1QQU5BUklPIiwiU0FOIEpBVklFUiJdfQ%3D%3D&location=7.995885%2C-73.208147%2C13.57&style=NOMB_MPIO

Fernández Benassati & Elsa Estévez. (2004). *Utilización de Casos de Uso durante el Proceso de.* http://sedici.unlp.edu.ar/bitstream/handle/10915/21299/Documento_completo.pdf?sequence=1&isAllowed=y

Gattu Anwesh. (Enero de 2024). *Real Time Facial Expression Recognition using.* https://esource.dbs.ie/server/api/core/bitstreams/76f14d6d-c90d-4a66-9d8a-8fe25a75440e/content

Giorgini, B. &. (2012). *EnfermedadesdeTomate Enfermedades de Tomate.* https://www.argentina.gob.ar/inta

Goufeng Yang, G. C. (2024). *Self-Supervised Collaborative Multi-Network for Fine-Grained Visual Categorization of Tomato Diseases.* https://ieeexplore.ieee.org/document/9264241

Hepzibah Elizabeth David, K. R. (2021). *Tomato Leaf Disease Detection Using Hybrid CNN-RNN Model.* https://ebooks.iospress.nl/doi/10.3233/APC210108

Hong, H. L. (2020). *Tomato Disease Detection and Classification by Deep Learning*. https://ieeexplore.ieee.org/document/9196295

Hong, H., Lin, J., & Huang, F. (2023). *Tomato Disease Detection and Classification by Deep Learning*. https://doi.org/10.1109/ICBAIE49996.2020.00012

Ideam. (2024). *Boletín agroclimático Departamento Norte de Santander*. https://ideam.gov.co/sites/default/files/prensa/boletines/boletin_agroclimatico_norte_de_santander_marzo_2024.pdf

Jaramillo Noreña, J. E. (2012). *Factores climáticos y su influencia en la producción de t1 709.9 ETBT/F10 12 Tf*

https://revistas.sena.edu.co/index.php/inf_tec/article/view/Comparacion-de-redes-neuronales-convolucionales-RNC-para-la-dete

Le, M. T. (2019). *EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks.* https://proceedings.mlr.press/v97/tan19a.html

Lehr, J. K. (2023). *Image-based recognition of surgical instruments by means of convolutional neural networks.* https://link.springer.com/article/10.1007/s11548-023-02885-3

Louchene, B. &. (2023). *Low-cost convolutional neural network for tomato plant diseases classifiation.* https://ijai.iaescore.com/index.php/IJAI/article/view/22192

M.P. Islam, K. H. (Diciembre de 2022). *Performance prediction of tomato leaf disease by a series of parallel convolutional neural networks.* https://www.sciencedirect.com/science/article/pii/S2772375522000193?via%3Dihub

Maeda-Gutiérrez, V. G.-T.-C.-P.-T.-R.-G.-Q.-O. (2020). *Comparison of Convolutional Neural Network Architectures for Classification of Tomato Plant Diseases.* https://www.mdpi.com/2076-3417/10/4/1245

Maha Altalak, M. A. (2022). *A Hybrid Approach for the Detection and Classification of Tomato Leaf Diseases.* https://www.mdpi.com/2076-3417/12/16/8182

Manas Wakchaure, B. P. (Diciembre de 2023). *Application of AI techniques and robotics in agriculture: A review.* https://www.sciencedirect.com/science/article/pii/S2667318523000016?via%3Dihub

MARD. (2020). *Cadena de las Hortalizas. Dirección de Cadenas Agrícolas y Forestales.* https://sioc.minagricultura.gov.co/Hortalizas/Documentos/2020-06-30%20Cifras%20sectoriales.pdf

Martín, J. D. (27 de Febrero de 2020). *Sistema de monitoreo para invernadero "Del huerto" mediante el protocolo de.* https://repository.usta.edu.co/server/api/core/bitstreams/408d9bf1-1723-44ae-9570-f9b902673166/content

Mim, T. T. (2019). *Leaves Diseases Detection of Tomato Using Image Processing.* https://ieeexplore.ieee.org/document/9117437

MinAgricultura. (18 de Octubre de 2018). *Corte Constitucional ratifica ley de innovación para el campo colombiano.* https://www.minagricultura.gov.co/noticias/Paginas/Corte-Constitucional-ratifica-ley-de-innovacion.aspx

Minagricultura. (2021). https://www.minagricultura.gov.co/noticias/Paginas/MinAgricultura-pone-al-servicio-plataforma-digital-.aspx

Mingxing Tan, Q. L. (2019). *EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks.* https://proceedings.mlr.press/v97/tan19a.html

Ministerio de comercio industria y turismo. (2023). Perfiles Económicos Departamentales Departamento de Norte de Santander. Colombia Potencia de La Vida, Perfiles económicos departamentales, 47. mincit.gov.co/CMSPages/GetFile.aspx?guid=343b884d-95de-4e64-8f0f-f76334a7dd74

Mintic Colombia. (13 de Noviembre de 2019). *CONPES de transformación digital promoverá la competitividad del país y la eficiencia del sector público.* https://www.mintic.gov.co/portal/inicio/Sala-de-prensa/Noticias/107147:CONPES-de-transformacion-digital-promovera-la-competitividad-del-pais-y-la-eficiencia-del-sector-publico

Mishra, N. J. (2023). *A Comparative Study of ResNet50, EfficientNetB7, InceptionV3, VGG16 models in Crop and Weed classification.* https://ieeexplore.ieee.org/document/10166032

Mohammad Amimul Ihsan Aquil, W. H. (2023). *Evaluation of scratch and pre-trained convolutional neural networks for the classification of Tomato plant diseases.* https://ijai.iaescore.com/index.php/IJAI/article/view/20703

Mohit Agarwal, A. A. (2020). *ToLeD: Tomato Leaf Disease Detection using Convolution Neural Network.* https://www.sciencedirect.com/science/article/pii/S1877050920306906?via%3Dihub

Naman Mishra, I. J. (2023). *A comparative study of ResNet50, EfficientNetB7, InceptionV3, VGG16 models on crop and weed classification. In 2023 4th International Conference on Intelligent Engineering and Management (ICIEM).* https://ieeexplore.ieee.org/document/10166032

Nirmala V, G. B. (2003). *Hybrid Deep Learning Method for Diagnosis of Cucurbita Leaf Diseases. Computer Systems Science and Engineering*. https://doi.org/10.32604/csse.2023.027512

Portafolio. (09 de Septiembre de 2020). El 17% del total de la fuerza laboral del país trabaja en el campo. págs. https://www.portafolio.co/economia/el-panorama-de-la-agricultura-en-colombia-en-su-dia-internacional-de-la-agricultura-544437.

Prabha, R.Kennedy, J. S., Vanitha, G., Sathiah, N., & Priya, M. B. (2022). Android application development for identifying maize infested with fall armyworms with Tamil Nadu Agricultural University Integrated proposed pest management (TNAU IPM) capsules. Journal of Applied and Natural Science, 14(SI), 138–144. https://doi.org/10.31018/jans.v14iSI.3599

Procolombia. (2021). *Cadena de Agroalimentos.* https://www.camara.gov.co/sites/default/files/2021-08/ANEXO%201%20MINCOMERCIO%20-%20%20Productos_potencial_exportador_agroindustrial_Colombia.pdf

Producción y consumo responsables - La Agenda 2030 en Colombia - Objetivos de Desarrollo Sostenible. (n.d.). Producción Y Consumo Responsables - La Agenda 2030 En Colombia - Objetivos De Desarrollo Sostenible. https://ods.dnp.gov.co/es/objetivos/produccion-y-consumo-responsables

Raman, C. &. (2024). *Early Blight Identification in Tomato Leaves using Deep Learning.* https://ieeexplore.ieee.org/document/9077010

Rezk, N. G., Attia, A.-F., El-Rashidy, M. A., El-Sayed, A., & Hemdan, E. E.-D. (2022). An Efficient Plant Disease Recognition System Using Hybrid Convolutional Neural Networks (CNNs) and Conditional Random Fields (CRFs) for Smart IoT Applications in Agriculture. International Journal of Computational Intelligence Systems, 15(1). https://doi.org/10.1007/s44196-022-00129-x

Robert de Luna, E. D. (2019). *Automated Image Capturing System for Deep Learning-based Tomato Plant Leaf Disease Detection and Recognition.* https://ieeexplore.ieee.org/document/8650088

Roberto Sampieri, C. F. (2014). *METODOLOGÍA DE LA INVESTIGACIÓN.* https://www.uv.mx/personal/cbustamante/files/2011/06/metodologia-de-la-investigaci%C3%83%C2%B3n_sampieri.pdf

Sanida, T. S. (2023). *A Lightweight CNN Model for Tomato Crop Diseases on Heterogeneous Embedded System.* Obtenido de https://ieeexplore.ieee.org/document/10176582

Siedliska, A. B. (Mayo de 2018). *Detection of fungal infections in strawberry fruit by VNIR/SWIR hyperspectral imaging.* https://www.sciencedirect.com/science/article/abs/pii/S0925521417308888?via%3Dihub

Suarez Baron, M. J. (2022). *Supervised Learning-Based Image Classification for the Detection of Late Blight in Potato Crops.* https://www.mdpi.com/2076-3417/12/18/9371

Sun, Y. G. (Enero de 2017). *Hyperspectral reflectance imaging combined with chemometrics and successive projections algorithm for chilling injury classification in peaches.* https://www.sciencedirect.com/science/article/abs/pii/S0023643816306004?via%3Dihub

Tridibesh Satpathy. (2017). *A Guide to the SCRUM BODY OF KNOWLEDGE (SBOK Guide).* https://drive.google.com/file/d/1JoMDWeYX-RxBrlL381C3XEQH03NeKxh0/view

Unesco. (2024). *Ética de la inteligencia artificial.* https://www.unesco.org/es/artificial-intelligence/recommendation-ethics

Wang, Q. Q. (2019). *Computational Intelligence and Neuroscience*. Obtenido de Identification of Tomato Disease Types and Detection of Infected Areas Based on Deep Convolutional Neural Networks and Object Detection Techniques. https://onlinelibrary.wiley.com/doi/10.1155/2019/9142753

Zhang, X. S. (Diciembre de 2021). *Hyperspectral detection of salted sea cucumber adulteration using different spectral preprocessing techniques and SVM method.* https://www.sciencedirect.com/science/article/abs/pii/S0023643821014481?via%3Dihub

Zhuang Liu & Kaiming He. (03 de Marzo de 2024). *A Decade's Battle on Dataset Bias: Are We There Yet?*. https://arxiv.org/abs/2403.08632

Apéndice

Apéndice A. Encuesta realizada a agricultores

El objetivo de este instrumento es identificar las enfermedades que más afectan a los cultivos de tomate en las zonas rurales de Llano del Pozo, San Javier y El Campanario.

A continuación, se le presentarán una serie de imágenes, sobre las cuales, usted debe indicar el grado de frecuencia con que ha encontrado estas enfermedades en sus cultivos de tomate.

Figura 91

Encuesta realizada a agricultores

¿Con qué frecuencia observa usted la siguiente enfermedad en su cultivo de



- Muy Frecuentemente
- Frecuentemente
- Ocasionalmente
- Raramente
- Nunca

¿Con qué frecuencia observa usted la siguiente enfermedad en su cultivo de tomate?



- ◯ Muy Frecuentemente
- ◯ Frecuentemente
- ◯ Ocasionalmente
- ◯ Raramente
- ◯ Nunca

¿Con qué frecuencia observa usted la siguiente enfermedad en su cultivo de tomate?



- ☐ Muy Frecuentemente
- ☐ Frecuentemente
- ☐ Ocasionalmente
- ☐ Raramente
- ☐ Nunca

¿Con qué frecuencia observa usted la siguiente enfermedad en su cultivo de tomate?



- ◯ Muy Frecuentemente
- ◯ Frecuentemente
- ◯ Ocasionalmente
- ◯ Raramente
- ◯ Nunca

¿Con qué frecuencia observa usted la siguiente enfermedad en su cultivo de tomate?



- ◯ Muy Frecuentemente
- ◯ Frecuentemente
- ◯ Ocasionalmente
- ◯ Raramente
- ◯ Nunca

¿Con qué frecuencia observa usted la siguiente enfermedad en su cultivo de tomate?



- ◯ Muy Frecuentemente
- ◯ Frecuentemente
- ◯ Ocasionalmente
- ◯ Raramente
- ◯ Nunca

¿Con qué frecuencia observa usted la siguiente enfermedad en su cultivo de tomate?



- ◯ Muy Frecuentemente
- ◯ Frecuentemente
- ◯ Ocasionalmente
- ◯ Raramente
- ◯ Nunca

¿Con qué frecuencia observa usted la siguiente enfermedad en su cultivo de tomate?



- ◯ Muy Frecuentemente
- ◯ Frecuentemente
- ◯ Ocasionalmente
- ◯ Raramente
- ◯ Nunca

¿Con qué frecuencia observa usted la siguiente enfermedad en su cultivo de tomate?



- ◯ Muy Frecuentemente
- ◯ Frecuentemente
- ◯ Ocasionalmente
- ◯ Raramente
- ◯ Nunca

¿Con qué frecuencia observa usted la siguiente enfermedad en su cultivo de tomate?



- ☐ Muy Frecuentemente
- ☐ Frecuentemente
- ☐ Ocasionalmente
- ☐ Raramente
- ☐ Nunca

¿Con qué frecuencia observa usted la siguiente enfermedad en su cultivo de tomate?



- ◯ Muy Frecuentemente
- ◯ Frecuentemente
- ◯ Ocasionalmente
- ◯ Raramente
- ◯ Nunca

¿Con qué frecuencia observa usted la siguiente enfermedad en su cultivo de tomate?



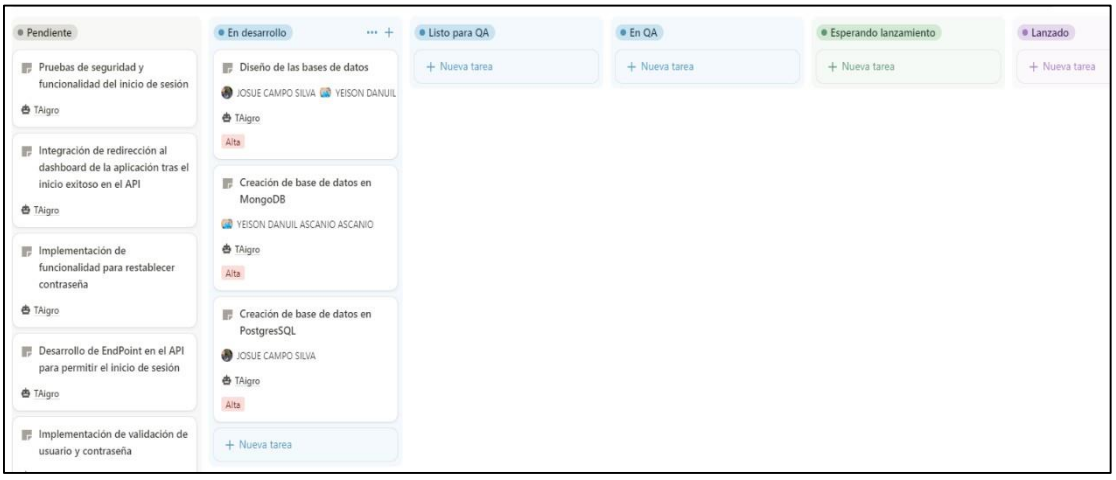
- ◯ Muy Frecuentemente
- ◯ Frecuentemente
- ◯ Ocasionalmente
- ◯ Raramente
- ◯ Nunca

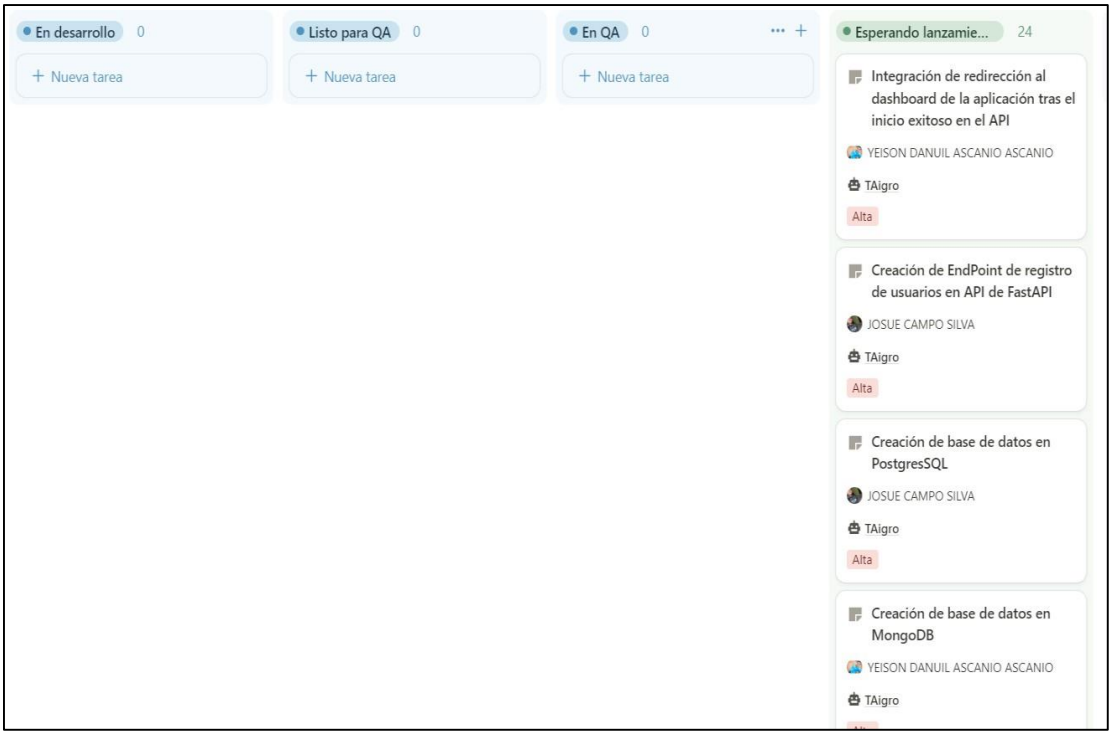
Apéndice B. Uso de la herramienta de Notion para la gestión del proyecto

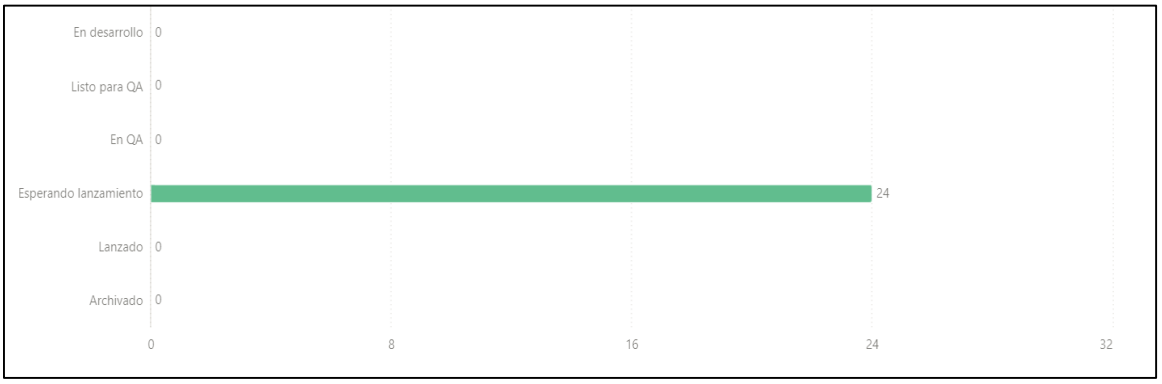
Sprint 1

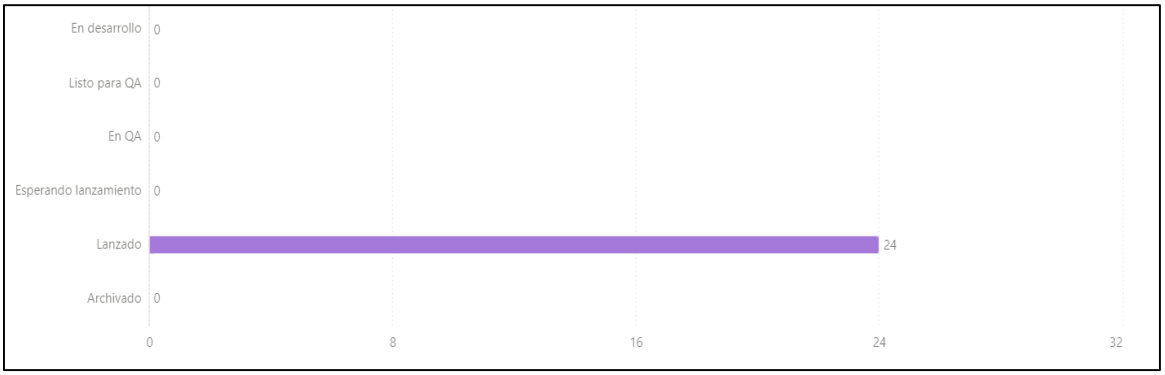
Figura 92

Uso de la herramienta de Notion para la gestión del proyecto- Sprint 1





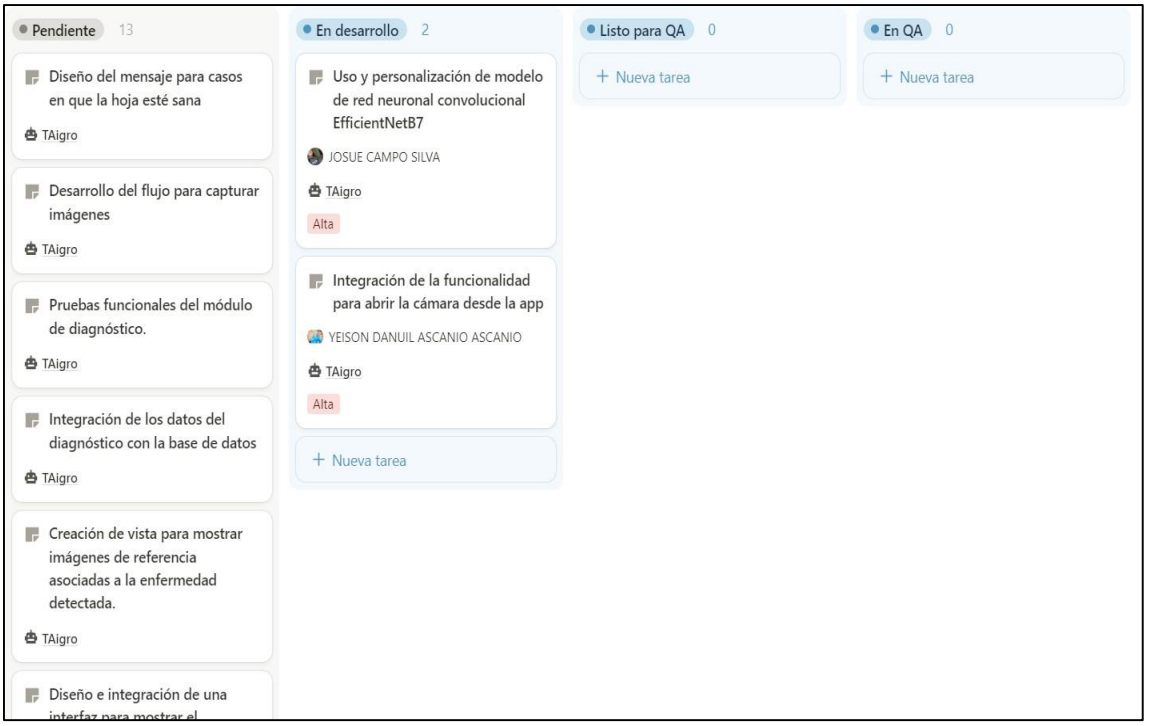

En desarrollo
0
Listo para QA
0
En QA
0
Esperando lanzamiento
24
Lanzado
0
Archivado
0
0
8
16
24
32


En desarrollo
0
Listo para QA
0
En QA
0
Esperando lanzamiento
0
Lanzado
24
Archivado
0
0
8
16
24
32

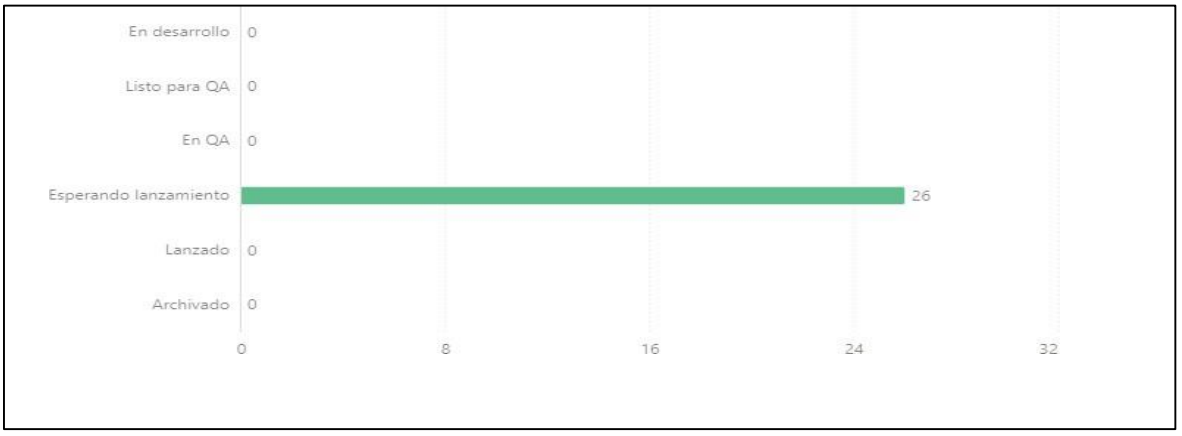
Sprint 2

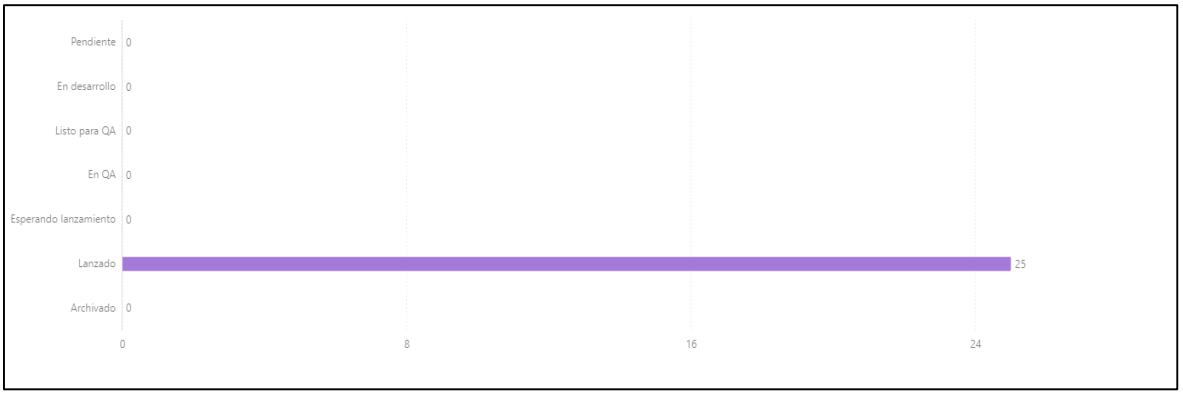
Figura 93

Uso de la herramienta de Notion para la gestión del proyecto- Sprint 2




Pendiente 0
+ Nueva tarea
En desarrollo 0
+ Nueva tarea
Listo para QA 0
+ Nueva tarea
En QA 0
+ Nueva tarea
Esperando lanzamie... 26
Integración de la funcionalidad para abrir la cámara desde la app
YEISON DANUIL ASCANIO ASCANIO
TAigro
Alta
Uso y personalización de modelo de red neuronal convolucional EfficientNetB7
JOSUE CAMPO SILVA
TAigro
Alta
Desarrollo del flujo para capturar imágenes
YEISON DANUIL ASCANIO ASCANIO
TAigro
Alta
Implementación de la lógica para el diagnóstico de la enfermedad
JOSUE CAMPO SILVA
TAigro
Alta
Entrenamiento del modelo de CNN
JOSUE CAMPO SILVA
TAigro
Alta


En desarrollo 0
Listo para QA 0
En QA 0
Esperando lanzamiento 26
Lanzado 0
Archivado 0
0
8
16
24
32


Pendiente 0
En desarrollo 0
Listo para QA 0
En QA 0
Esperando lanzamiento 0
Lanzado 25
Archivado 0
0
8
16
24

Apéndice C. Product Backlog Refinado

Tabla 24

Product Backlog Refinado

ID Historia	Rol (Como)	Funcionalidad (Quiero)	Razón (Para)	Criterios de Aceptación	Prioridad	Estimación
ST-01-1	Agricultor	Registrar mi información personal.	Tener un perfil personalizado que permita el acceso a funcionalidades del sistema.	La información ingresada debe almacenarse correctamente en la base de datos. Debe haber validación de campos obligatorios. Notificación de éxito al guardar los datos. En caso de éxito, enviar código de activación de la cuenta por correo electrónico. Mensaje de error en caso de datos incompletos.	Alta	8
ST-01-2	Agricultor	Iniciar sesión en la aplicación.	Acceder de manera segura a mis datos y funcionalidades del sistema.	Validación de usuario y contraseña. Mensaje de error si las credenciales son incorrectas o el usuario no está registrado. Redirigir al usuario al dashboard al iniciar sesión correctamente.	Alta	6

ST-01-3	Agricultor	Consultar mi información registrada.	Revisar mis datos o actualizarlos si es necesario.	Mostrar los datos almacenados de manera clara y organizada. Garantizar que los datos mostrados sean consistentes con la base de datos.	Media	6
ST-01-4	Agricultor	Actualizar mi información.	Mantener mis datos correctos y actualizados.	Los datos deben reflejarse inmediatamente después de actualizarlos. Validación de campos antes de guardar cambios. Mensaje de confirmación al actualizar exitosamente. Mensaje de error en caso de fallo en la conexión o datos no válidos.	Alta	6
ST-01-5	Agricultor	Tomar imágenes de las hojas de tomate desde el dispositivo móvil.	Realizar un diagnóstico de la enfermedad del cultivo.	La cámara del dispositivo debe abrirse correctamente desde la aplicación. Mensaje de espera mientras se procesa la imagen. Mostrar un mensaje claro si no se puede procesar la imagen. Permitir retomar la foto en caso de que no se haya procesado correctamente.	Alta	8

ST-01-6	Agricultor	Visualizar la enfermedad detectada en la hoja.	Conocer el estado de salud del cultivo y tomar medidas necesarias.	Mostrar el diagnóstico con el nombre y descripción de la enfermedad o indicar que está sana. Proporcionar una imagen de referencia asociada a la enfermedad detectada.	Alta	6
ST-01-7	Agricultor	Ver las acciones recomendadas para erradicar la enfermedad.	Implementar las medidas correctivas y evitar la propagación de la enfermedad.	Mostrar una lista de recomendaciones claras y detalladas, basadas en la enfermedad detectada.	Alta	8
ST-01-8	Agricultor	Consultar información climática.	Adaptar mis decisiones agrícolas en función de las condiciones climáticas.	Visualizar datos climáticos precisos y actualizados en tiempo real. Permitir visualizar predicciones del clima en un número determinado de días futuros.	Media	6

Apéndice D. Sprint Backlog

Tabla 25

Sprint Backlog

Historia	Item	Tarea	Tiempo total estimado (Horas)	Responsable	Prioridad (1-10)
ST-01-1	1	Diseño de las bases de datos	8	Yeison Danuil, Josué Campo	1
	2	Creación de base de datos en PostgresSQL	4	Josué Campo	2
	3	Creación de base de datos en MongoDB	4	Yeison Danuil	3
	4	Desarrollo de la interfaz de registro de usuario en el aplicativo móvil	16	Yeison Danuil	4
	5	Implementar validación de campos obligatorios	4	Yeison Danuil	5
	6	Creación de EndPoint de registro de usuarios en API de FastAPI	16	Josué Campo	6
	7	Creación de lógica de envío de correos	8	Josué Campo	7
	8	Desarrollo de función de envíos de códigos de activación de la cuenta por medio de correo	6	Josué Campo	8
	9	Conexión del front del aplicativo móvil con el API	6	Yeison Danuil	9
	10	Pruebas de integración entre el aplicativo y el API	8	Yeison Danuil, Josué Campo	10
ST-01-2	1	Diseño de la pantalla de inicio de sesión	16	Yeison Danuil	1
	2	Implementación de validación de usuario y contraseña	6	Yeison Danuil	2
	3	Desarrollo de EndPoint en el API para permitir el inicio de sesión	10	Josué Campo	3
	4	Integración de redirección al dashboard de la aplicación tras el inicio exitoso en el API	4	Yeison Danuil	5
	5	Pruebas de seguridad y funcionalidad del inicio de sesión	8	Yeison Danuil, Josué Campo	6

ST-01-3	1	Desarrollo del endpoint en API de FastAPI para consulta de datos	8	Josué Campo	1
	2	Desarrollo de la interfaz de visualización	14	Yeison Danuil	2
	3	Conexión del front del aplicativo móvil con el backend a través del API	4	Yeison Danuil	3
	4	Pruebas de usabilidad de la interfaz para consulta de datos	8	Yeison Danuil, Josué Campo	4
ST-01-4	1	Diseño del formulario de actualización de datos	6	Yeison Danuil	1
	2	Implementación del formulario en la app	4	Yeison Danuil	2
	3	Validación de los campos en el formulario	2	Yeison Danuil	3
	4	Creación del endpoint de actualización de datos en la API	6	Josué Campo	4
	5	Pruebas de actualización de datos en la base de datos	4	Yeison Danuil, Josué Campo	5
ST-01-5	1	Integración de la funcionalidad para abrir la cámara desde la app	4	Yeison Danuil	1
	2	Desarrollo del flujo para capturar imágenes	8	Yeison Danuil	2
	3	Diseño e implementación del mensaje de espera mientras se procesa la imagen	6	Yeison Danuil	3
	4	Uso y personalización de modelo de red neuronal convolucional EfficientNetB7	6	Josué Campo	4
	5	Entrenamiento del modelo de CNN	12	Josué Campo	5
	6	Implementación del procesamiento de imágenes usando el modelo entrenado	6	Yeison Danuil, Josué Campo	6
	7	Diseño e implementación del mensaje de espera mientras se procesa la imagen	2	Yeison Danuil	7
	8	Implementación de la funcionalidad para retomar la foto	6	Yeison Danuil	8
	9	Pruebas funcionales del módulo de captura y procesamiento	8	Yeison Danuil, Josué Campo	9
ST-01-6	1	Implementación de la lógica para el diagnóstico de la enfermedad	6	Josué Campo	1

	2	Diseño e integración de una interfaz para mostrar el diagnóstico	12	Yeison Danuil	2
	3	Creación de vista para mostrar imágenes de referencia asociadas a la enfermedad detectada.	6	Yeison Danuil	3
	4	Integración de los datos del diagnóstico con la base de datos	4	Yeison Danuil	4
	5	Diseño del mensaje para casos en que la hoja esté sana	2	Yeison Danuil	5
	6	Pruebas funcionales del módulo de diagnóstico.	8	Yeison Danuil, Josué Campo	6
ST-01-7	1	Investigación y recopilación de recomendaciones específicas para cada enfermedad detectada	4	Yeison Danuil, Josué Campo	1
	2	Diseño e integración de una interfaz para mostrar las recomendaciones	6	Yeison Danuil	2
	3	Creación de EndPoint para visualizar las recomendaciones por enfermedad	6	Josué Campo	3
	4	Integración de las recomendaciones entre la interfaz y la base de datos	4	Yeison Danuil	5
	5	Pruebas funcionales de las recomendaciones	6	Yeison Danuil, Josué Campo	6
ST-01-8	1	Investigación y selección de API climática confiable	2	Josué Campo	1
	2	Implementación de conexión a la API climática	4	Josué Campo	2
	3	Desarrollo de interfaz para mostrar información climática	8	Yeison Danuil	3
	4	Implementación de funcionalidad para predicciones climáticas	6	Yeison Danuil	4
	5	Manejo de errores en la conexión con la API	2	Yeison Danuil	5
	6	Pruebas de la funcionalidad de consulta de datos climáticos	8	Yeison Danuil, Josué Campo	6

Apéndice E. Evidencia de reuniones con los Agricultores de las zonas rurales y usabilidad del aplicativo

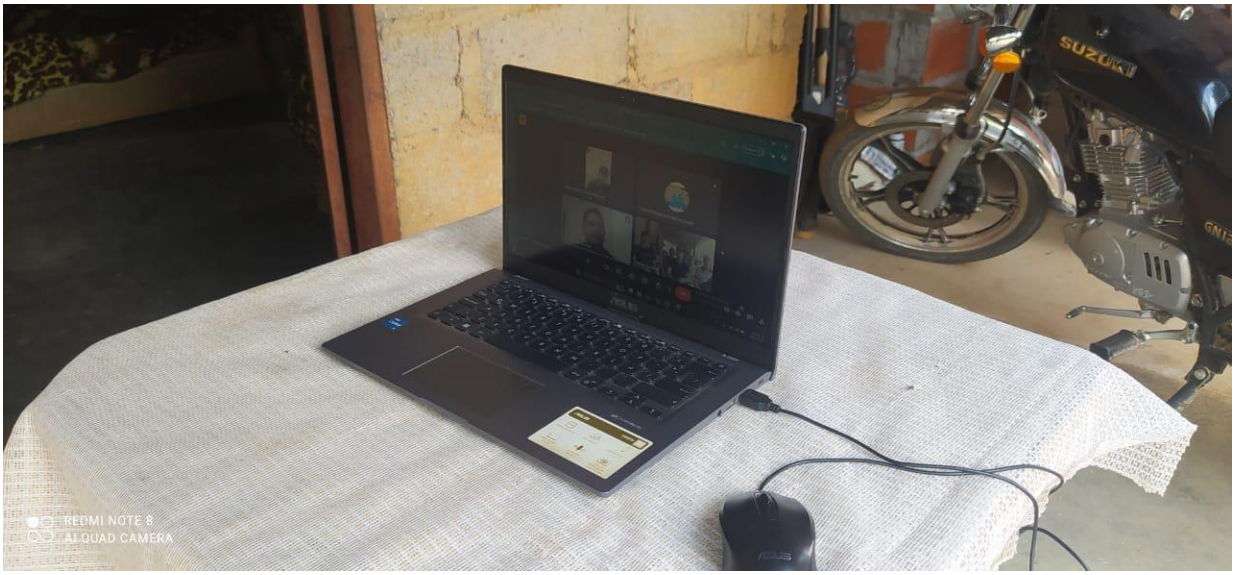
Figura 94

Evidencia de reuniones con los Agricultores de las zonas rurales y usabilidad del aplicativo






REDMI NOTE 8
AI QUAD CAMERA


SUZUKI
REDMI NOTE 8
AI QUAD CAMERA







