



UNIVERSIDAD TÉCNICA DEL NORTE
FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS
CARRERA DE INGENIERÍA EN ELECTRÓNICA Y REDES
DE COMUNICACIÓN

“DISEÑO DE UN SISTEMA DE VISIÓN ARTIFICIAL MEDIANTE UNA PLATAFORMA USANDO UN DRONE PARA IDENTIFICAR LA PLAGA LANCHA (PHYTOPHTHORA INFESTANS) EN CAMPOS AGRÍCOLAS DE TOMATE RIÑÓN EN ROMERILLO BAJO.”

TRABAJO DE GRADO PREVIO A LA OBTENCIÓN DEL TÍTULO DE
INGENIERO EN ELECTRÓNICA Y REDES DE COMUNICACIÓN

AUTOR: LUGO NOBOA DAVID JONATHAN

DIRECTOR: M_sC. CARLOS ALBERTO VÁSQUEZ AYALA

Ibarra – Ecuador

2021



UNIVERSIDAD TÉCNICA DEL NORTE

BIBLIOTECA UNIVERSITARIA

AUTORIZACIÓN DE USO Y PUBLICACIÓN A FAVOR DE LA UNIVERSIDAD TÉCNICA DEL NORTE

1. IDENTIFICACIÓN DE LA OBRA

En cumplimiento del Art 144 de la Ley de Educación Superior, hago la entrega del presente trabajo a la Universidad Técnica del Norte para que sea publicado en el Repositorio Digital Institucional, para lo cual pongo a disposición la siguiente información:

DATOS DEL CONTACTO			
CÉDULA DE IDENTIDAD	1003909536		
APELLIDOS Y NOMBRES:	Lugo Noboa David Jonathan		
DIRECCIÓN:	Cañar 2-80 y Av. 13 de abril		
E-MAIL:	djlugon@utn.edu.ec		
TELÉFONO FIJO:	N.A.	TELÉFONO MÓVIL:	0996110927
DATOS DE LA OBRA			
TÍTULO:	DISEÑO DE UN SISTEMA DE VISIÓN ARTIFICIAL MEDIANTE UNA PLATAFORMA USANDO UN DRONE PARA IDENTIFICAR LA PLAGA LANCHA (PHYTOPHTHORA INFESTANS) EN CAMPOS AGRÍCOLAS DE TOMATE RIÑÓN EN ROMERILLO BAJO		
AUTOR:	Lugo Noboa David Jonathan		
FECHA:DD/MM/AAAA	31/08/2021		
PROGRAMA:	<input checked="" type="checkbox"/>	PREGRADO	<input type="checkbox"/> POSGRADO
TÍTULO POR EL QUE OPTA:	Ingeniería en Electrónica y Redes de Comunicación		
ASESOR/DIRECTOR	MsC. Carlos Alberto Vásquez Ayala		

CONSTANCIAS

El autor manifiesta que la obra objeto de la presente autorización es original y se la desarrolló, sin violar derechos de autor de terceros, por lo tanto, la obra es original y que es el titular de los derechos patrimoniales, por lo que asume la responsabilidad sobre el contenido de esta y saldrá en defensa de la Universidad en caso de reclamación por parte de terceros.

Ibarra, a los 31 días del mes de agosto de 2021

EL AUTOR:



.....

Sr. Lugo Noboa David Jonathan

CI: 1003909536



UNIVERSIDAD TÉCNICA DEL NORTE
FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS
INGENIERÍA EN ELECTRÓNICA Y REDES DE COMUNICACIÓN

CERTIFICACIÓN

**MsC. CARLOS ALBERTO VÁSQUEZ AYALA, DIRECTOR DEL
PRESENTE TRABAJO DE TITULACIÓN**

CERTIFICA:

Que, el presente trabajo de Titulación “DISEÑO DE UN SISTEMA DE VISIÓN ARTIFICIAL MEDIANTE UNA PLATAFORMA USANDO UN DRONE PARA IDENTIFICAR LA PLAGA LANCHA (PHYTOPHTHORA INFESTANS) EN CAMPOS AGRÍCOLAS DE TOMATE RIÑÓN EN ROMERILLO BAJO”, ha sido desarrollado por el señor Lugo Noboa David Jonathan bajo mi supervisión

Es todo en cuanto puedo certificar en honor de la verdad.

**CARLOS ALBERTO
VASQUEZ AYALA** Firmado digitalmente por
CARLOS ALBERTO VASQUEZ
AYALA
Fecha: 2021.08.06 12:14:59
-05'00'

.....
MsC. Carlos Vásquez

C.I.

DIRECTOR



UNIVERSIDAD TÉCNICA DEL NORTE

FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

DEDICATORIA

Dedicado con todo mi amor hacia Dios en primera instancia, luego a mis padres, familia y seres queridos que siempre me dieron su apoyo y ánimo para culminar el proyecto, siempre estaré agradecido por su paciencia, cariño y sobre todo su grande amor. Nunca es tarde para luchar en esta carrera de la vida, todo es posible a medida que tú lo creas.



UNIVERSIDAD TÉCNICA DEL NORTE

FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS

AGRADECIMIENTO

El éxito se ve reflejado a medida que nosotros creemos. Mi agradecimiento es para Dios que ha estado conmigo en mi camino, dentro de este caminar también doy gracias a mis padres por creer en mí y darme su apoyo, enseñarme valores y sobre todo nunca rendirse para cumplir mis sueños. Ese amor recibido, la dedicación y su paciencia son un regalo hermoso que ha marcado mi vida. En efecto, mis hermanos y seres queridos son personas importantes que han sido otro pilar fundamental para llegar a culminar esta meta, por tal razón se refleja mi felicidad en el desarrollo de cada parte y punto de este proyecto.

RESUMEN

El presente trabajo realiza un estudio de la detección e identificación de enfermedades en las hojas de tomate riñón a través del diseño de un sistema de visión artificial mediante una plataforma usando un drone para proporcionar el desarrollo de una aplicación de alertas hacia el agricultor.

El sistema propuesto se fundamenta en un detector de enfermedades mediante redes neuronales artificiales convolucionales con el módulo dnn de OpenCV que se basa en un enfoque híbrido entre yoloV3 y Darknet-53. En efecto, hace uso de la adquisición de datos con técnicas de vuelo autónomo, el nodo de comunicación que sirve de puente entre los datos de telemetría y detección con la base de datos y la plataforma web. Además, se integra la fase de base de datos que fomenta la administración de los datos para hacer su correcto proceso. Finalmente se encuentra la plataforma web que consta con autenticación y nos muestra las alertas que el usuario puede realizar medidas de manejo integrado para la prevención del cultivo.

Este documento denota el estudio realizado para diseñar un entrenamiento acorde a la arquitectura de la red con los conjuntos de los datos de las muestras de la enfermedad y para la fase de validación realiza un proceso con el fin de la identificación de la enfermedad, y así, conseguir un modelo de entrenamiento eficiente para la problemática planteada.

ABSTRACT

This paper is a study of the detection and identification of diseases in kidney tomato leaves through the design of an artificial vision system using a drone platform to provide the development of an application of alerts to the farmer.

The proposed system is based on a disease detector using convolutional artificial neural networks with the OpenCV dnn module that is based on a hybrid approach between yoloV3 and Darknet-53. Indeed it makes use of data acquisition with autonomous flight techniques, the communication node bridging telemetry and detection data with the database and the web platform. In addition, it integrates the database phase that promotes the administration of the data to make its correct processing. Finally there is the web platform that consists with authentication and shows us the alerts that the user can perform integrated management measures for the prevention of the crop.

This paper denotes the study carried out to design a training according to the architecture of the network with the data sets of the disease samples and for the validation phase it performs a process in order to identify the disease, and thus, achieve an efficient training model for the problem posed.

Contenido

1.	CAPITULO I. EL PROBLEMA	12
1.1.	Problema	12
1.2.	Objetivos	14
1.2.1.	Objetivo General.....	14
1.2.2.	Objetivos Específicos	14
1.3.	Alcance	15
1.4.	Justificación	17
2.	CAPITULO II. MARCO REFERENCIAL	19
2.1.	Agricultura	19
2.1.1.	Agricultura de precisión	19
2.1.2.	Cultivo del tomate riñón	22
2.1.2.	Preparación del suelo.....	24
2.1.3.	Manejo del cultivo	26
2.1.4.	Plagas y enfermedades del tomate.....	27
2.1.5.	Herramientas de adquisición de datos	38
2.1.6.	Tecnología de transmisión.....	45
2.2.	Visión Artificial	47
2.2.1.	Reconocimiento automático de objetos	48
2.2.2.	Etapas de detección de objetos de una imagen.....	49
2.3.	Aprendizaje Automático (Machine Learning)	51
2.3.1.	Técnicas de aprendizaje.....	51
2.4.	Aprendizaje Profundo (Deep learning).....	55
2.4.1.	Arquitecturas	57
2.4.2.	Redes Neuronales Convolucionales (CNN)	59
3.	CAPÍTULO III. METODOLOGÍA.....	65
	Desarrollo Experimental.....	65
3.1.	Análisis de la Situación Actual	65
3.1.1.	Análisis de los resultados.	67
3.2.	Introducción al desarrollo del proyecto	68
3.2.1.	Propósito del sistema	68
3.2.2.	Ámbito del Sistema	69
3.2.3.	Características de los beneficiarios.....	69

3.3.	Requerimientos del proyecto	69
3.3.1.	Construcción de Atributos de los requerimientos	70
3.3.2.	Requerimientos de <i>Stakeholders</i>	70
3.3.3.	Requerimientos del Sistema	73
3.3.4.	Requerimientos De Arquitectura	76
3.4.	Recursos	79
3.4.1.	Recursos económicos	79
3.4.2.	Recursos tecnológicos	79
3.5.	Elección de hardware y software	80
3.5.1.	Elección de Hardware.....	80
3.5.2.	Elección del Software	82
3.5.3.	Elementos seleccionados para elaboración del proyecto.....	88
4.	CAPÍTULO IV: PROPUESTA	91
4.1.	Sistema Propuesto.....	91
4.1.1.	Descripción General del Proyecto	91
4.1.2.	Adquisición de Datos	94
4.1.3.	Nodo de comunicación	105
4.1.4.	Página Web.....	106
4.1.5.	Plataforma de almacenamiento en la nube	113
4.1.6.	Base de Datos	115
4.1.7.	Modelo de entrenamiento	117
4.1.8.	Proceso de Entrenamiento	121
4.1.9.	Validación.....	124
4.1.10.	Grados de severidad de <i>phytophthora infestans</i>	125
4.1.11.	Métricas de eficiencia.....	126
4.1.12.	Integración del sistema	127
5.	CAPITULO V: ANÁLISIS E INTERPRETACIÓN DE RESULTADOS	130
5.1.	Resultados	130
5.1.1.	Resultados de entrenamiento	130
5.1.2.	Resultados de Validación	131
5.2.	Eficiencia del sistema	131
5.2.1.	Análisis cualitativo	132
5.2.2.	Análisis cuantitativo	140

5.2.3.	Gráfica Precisión-Recall.....	141
6.	CONCLUSIONES.....	143
7.	RECOMENDACIONES	145
8.	BIBLIOGRAFÍA.....	147
9.	ANEXOS.....	152

1. CAPITULO I. EL PROBLEMA

1.1.Problema

La agricultura en Ecuador es una de las actividades que genera sustentabilidad al país, ciertamente, Imbabura representa un rubro importante dentro de la producción agrícola, Sobre los años, mucho del esfuerzo empleado en el trabajo agrícola dependía solamente de la fuerza humana, luego capturada por la fuerza bruta, y seguida hasta entonces a la actualidad por la confianza sobre desarrollos mecánicos como tractores a vapor o combustible acoplados con implementos mecánicos. No obstante, durante la última década, las prácticas tradicionales en la industria agrícola han dado el siguiente paso hacia el uso de la tecnología con el propósito de hacer de este sector primario de la economía no solo una actividad más rentable, si no también más sustentable, eficiente, segura y amigable con el ambiente, donde el rubro promedio de tomate riñón aumentó un 2% en 2017, ubicándose en 15.25 USD/cartón de 25 lb. (Ministerio de Agricultura y Ganadería, 2017)

En este contexto, Imbabura posee más del 30% de su población económicamente activa (PEA) está integrada. (Ruiz, 2015) Muchas de las veces el producto no se puede comercializar por la mala calidad, dentro de este enfoque la bacteria *Phytophthora* infestans es producida por la humedad relativa alta (mayor de 90%) y temperaturas entre 10-25° C, su manera de propagación se debe a lluvias, vientos, riegos por aspersion y rocíos. Su desarrollo trabaja en algunas fases, desde un inicio aparecen manchas irregulares de aspectos aceitoso, seguidamente se necrosan e invaden todo el foliolo, en una tercera fase alrededor de la zona afectada se observa un pequeño margen en presencia de humedad y aparece un fieltro blancuzco poco visible en el envés, y termina de color blancuzca la hoja, además, su propagación es de manera aérea en la planta y en cualquier parte de desarrollo,

consecuentemente afecta a los frutos inmaduros, manifestándose como grandes manchas pardas, vítreas, de superficie y contorno irregular, que cubre la mitad del producto (syngenta, 2018), en efecto, no es utilizado para comercializarse, y así obtener una inestabilidad económica para el agricultor.

Los campos agrícolas ofrecen diferentes características debido a su condición estructural y funcional; entre ellos: cultivo de baja cobertura espacial como hortalizas, verduras, etc, para la sociedad, además busca vincularse con el comercio en general. Dentro de este contexto, existe una problemática tanto económica y comercial, al no obtener un buen producto, el comerciante no puede vender, y a su vez genera pérdidas tanto para el agricultor y el comerciante. Por este motivo los agricultores con daños en su cultivo no siempre tienen acceso al conocimiento para combatir la plaga, debido que está en manos de expertos y consultores, pero no en el campo. En nuestra situación, el factor más importante es la baja temperatura, a la cual está expuesto el cultivo, al estar ubicado en la parroquia Imbaya del Cantón Antonio Ante donde el rango de temperatura fluctúa entre los 12 y 20 °C a 3200 msnm¹ en zonas altas. Con estas condiciones, se considera la planta de tomate riñón termo periódica porque su crecimiento esta directamente relacionado con el cambio de temperatura, es decir que a una temperatura constante el crecimiento es óptimo pero si la temperatura es variables el crecimiento del cultivo tendrá efectos de retardo en su desarrollo. (Oñate Valdivieso, 2012)

En efecto, el cultivo al estar expuesto a estas condiciones es propenso a contagiarse con la bacteria *Phytophthora infestans* por lo tanto produce que la hoja este con manchas irregulares de tipo aceitoso (syngenta, 2018), y se afecta el crecimiento del tomate,

¹ Metros sobre el nivel del mar.

consecuentemente no le deja asimilar los microorganismos del suelo y químicos, por lo que podría generar pérdidas en la producción del cultivo.

Por lo antes expuesto, este trabajo de investigación busca alertar al usuario para disminuir el proceso de propagación de la enfermedad, de este modo permite tener un conocimiento fidedigno sobre el tipo de enfermedad, sobre todo, es oportuno diseñar una nueva solución para satisfacer la necesidad a través de un sistema de visión artificial mediante un dron.

1.2.Objetivos

1.2.1. Objetivo General

Diseñar un sistema de visión artificial mediante una plataforma con el dron para identificar la plaga lancha (*Phytophthora infestans*) en campos agrícolas de tomate riñón.

1.2.2. Objetivos Específicos

- Realizar una revisión sistemática de la literatura sobre el tipo de plagas y el procedimiento de discretización mediante visión artificial.
- Determinar la situación actual del cultivo con respecto a las plagas para elaborar un esquema de adquisición y procesamiento de imágenes.
- Implementar el esquema propuesto que interactúe con la cámara del dron para visualizar los resultados e identificación de la plaga lancha (*Phytophthora infestans*).
- Realizar pruebas de funcionamiento del sistema para monitorear el cultivo de tomate riñón en los campos agrícolas.

1.3.Alcance

En la siguiente propuesta del proyecto se hace referencia al desarrollo de un sistema de visión artificial mediante un drone que permita monitorear el cultivo de tomate riñón para identificar la plaga *Phytophthora infestans* en campos agrícolas; de esta manera el agricultor pueda obtener un mejor producto para su comercialización.

Para iniciar el proyecto se realizará un estudio bibliográfico con el fin de establecer bases teóricas en las que se sustente el proyecto a desarrollarse en cuanto se refiere al tipo de plagas existentes en la provincia de Imbabura y el procedimiento de discretización de imágenes mediante visión artificial.

En primera instancia se determinará los requerimientos del usuario con respecto a la situación actual del cultivo en el tomate riñón, para aquello se efectuará encuestas con el dueño y trabajadores de este, y así, obtener las necesidades a las cuales el cultivo tiene ciertas limitaciones, de este modo es más susceptible para contagiarse con esta bacteria. De las encuestas se podrá recabar información más acertada desde la perspectiva del usuario en base a sus opiniones y experiencias de la vida cotidiana para el desarrollo idóneo del prototipo. Una vez obtenidos los requerimientos del usuario, se procede a realizar los requerimientos del sistema que se enfocan en las funciones que realiza el proyecto y requerimientos de arquitectura en donde se detallan los requerimientos de hardware y software.

Posteriormente para la elección de software y hardware en el desarrollo del presente proyecto se propone la utilización de benchmark para la parte de hardware y la norma IEEE 29148 para elección del Software. El estándar contiene disposiciones para los procesos y los

productos relacionados con la ingeniería, así como los requisitos para los sistemas, productos de software y servicios. En este contexto utilizaremos un drone, se considera el estudio de mercado, funcionalidad al momento de planear el vuelo y la compatibilidad con la plataforma; Para la elección del software se determinará un sistema de comprobación que realizará la ubicación mediante una plataforma, se empleará la plataforma para el reconocimiento y clasificación de las muestras, otro para pilotaje al tomar en cuenta las características del drone, además para la selección del algoritmo se desarrollará un análisis comparativo de acuerdo a los parámetros y estrategias para saber cuál es el adecuado y efectivo de acuerdo al hardware.

El siguiente paso y el más importante es el funcionamiento del sistema, en este sentido, se lo realizará 3 días antes del proceso de fumigación llevado a cabo cada 8 días, (Aldas, 2018) otro factor sería la ubicación de acuerdo a las coordenadas de la toma de datos, seguido de esto el drone realiza el vuelo de acuerdo a la ruta programada en la plataforma del mismo, otra punto será el vuelo no programado que se lo efectuará cuando se necesite tomar datos extras para corroborar las muestras obtenidas en casos diferentes a la ubicación, efectuándose de acuerdo al valor de tiempo de toma de datos mediante el estudio, se utiliza los parámetros como ubicación, luz, tamaño de pixeles, color; estas son enviadas a través de la tecnología de comunicación inalámbrica hacia la base de datos de la plataforma, consecuentemente estos datos para ser discretizados necesitan de herramientas que permitan codificarlos mediante técnicas de segmentación, clasificadores y matching, que al pasar por un método que rinda mejor de acuerdo al número de atributos, luego esta información es procesada por el algoritmo de procesamiento de imágenes, de tal forma genera matrices que contienen los resultados referentes a la detección de bordes y características como color, texturas y morfología a partir de cada frame capturado, este proceso se considera algunas

restricciones y así poder identificar qué tipo de plaga de acuerdo a su estructura. Luego se validará los resultados para comprobar el rendimiento del sistema y luego subirlos a una plataforma web que informa al agricultor.

Finalmente se comprobará el correcto funcionamiento de acuerdo a pruebas del sistema, es necesario una prueba del vuelo del dron, seguido otra para la transmisión de datos, esto será una parte importante para que los datos sean procesados, además, se realizará una prueba de discretización de las imágenes en tiempo real para diferentes casos, es decir, cuando la muestra se encuentre sana y enferma, de acuerdo a esos resultados es necesario una prueba para ver si los datos son exactos y tomar medidas necesarias.

1.4. Justificación

El cultivo de tomate riñón un producto dentro de la mesa del Ecuador, además, forma parte de la canasta básica familiar y de gran valor para la agricultura del país. Según la Organización de las Naciones Unidas para la Alimentación y Agricultura (FAO), la producción en el año 2015 se incrementó un 4% respecto al año 2013 de tomate riñón en el Ecuador. Por otra parte, el Ministerio de Agricultura y ganadería, la producción nacional decreció respecto al año 2014, que pasa de 71,831 (t) a 68,355 (t), esta disminución se debe a la producción que influyó en las exportaciones, ya que bajaron en 99% respecto al 2014. (MAG, 2016).

Según el objetivo 3 que tiene Plan Nacional del Buen Vivir se contempla que se debe mejorar la calidad de vida de la población en la que se menciona “Que los derechos para mejorar la calidad de vida se incluyen el acceso al agua y a la alimentación (art. 12) a vivir en un ambiente sano (art. 14) a un habitar seguro y saludable.... (art. 30)” (Secretaría Nacional de Planificación y Desarrollo, 2013). Y como punto importante, el PNBV en lo

que se refiere a salud, busca mediante la profundización de esfuerzos en políticas de prevención y generación de un ambiente saludable. (Secretaría Nacional de Planificación y Desarrollo, 2013)

Ante la importancia de este cultivo en la sierra, es necesario generar nuevos conocimientos y soluciones a los problemas que existen en la producción. En los últimos años se han desarrollado diferentes tipos de plásticos para cultivos protegidos con el fin de modificar el espectro de la luz solar unas veces filtrándola o también intensificándola. Son conocidos como plásticos foto selectivos y al bloquear la radiación UV tienen la capacidad de alterar el comportamiento de insectos, puesto que existen especies que necesitan de radiación UV para orientarse y cumplir con sus funciones biológicas. Por otro lado, alterar el espectro solar dentro del invernadero también causa efectos sobre ciertas especies de hongos, ya que las esporas necesitan radiación UV para desarrollarse. (Andrade, 2015)

En la actualidad, el control de plagas y enfermedades en cultivos protegidos enfrenta algunas dificultades debido al incremento de estos cultivos manejados de forma intensiva y al surgimiento de nuevas especies de patógenos más agresivas. A esto se le suma la disminución de la eficacia de algunos productos químicos debido a un mal manejo y abuso de estos. Existen otros métodos que pueden contribuir al control de plagas, ya sean físicos o culturales que son muy útiles al momento de manejar los cultivos bajo invernadero. Las nuevas tecnologías que existen para los cultivos protegidos traen beneficios sobre el control de plagas. Se ha comprobado que la luz UV (UV-a y UV-b) es vital para insectos; al utilizar polietileno foto selectivo como material de cubierta se afecta a la visión de los insectos y además se logra alterar sus hábitos alimenticios y reproductivos (Buenahora, Álvez, & Galván, 2003).

2. CAPITULO II. MARCO REFERENCIAL

2.1.Agricultura

2.1.1. Agricultura de precisión

La estimación de la industria agrícola en los últimos años se ha centrado en la predicción precisa e inofensiva para aumentar la producción de alimentos y satisfacer la demanda mundial debido a la expansión demográfica esperada para 2050 (según la FAO), se espera específicamente la sostenibilidad ambiental y la producción económica mediante el uso de tecnología. En general, estas expectativas se han cumplido con las operaciones manuales de la maquinaria agrícola tradicional; sin embargo, los desarrollos actuales impulsan actividades hacia el manejo de tareas de alta precisión en el trabajo agrícola, que mejoran el rendimiento con insumos modernos, fertilizantes eficientes y agroquímicos más seguros.

2.1.1.1. Definición

Son los métodos o técnicas compuesta por estrategias para recolectar datos mediante herramientas tecnológicas usadas por el sector agrícola desarrollado, en función de la optimización de los recursos según las diferentes necesidades del agrónomo. Como expresa Bongiovanni, Chartuni, Best, & Roel (2006): “Es un conjunto de técnicas orientado a optimizar el uso de los insumos agrícolas en función de la cuantificación de la variabilidad espacial y temporal de la producción agrícola” (p. 15). Por lo que este método de agricultura es apto y beneficioso para el análisis cuantitativo del rendimiento de insumos en áreas agrícolas, que reduce así el impacto en el medio ambiente y, consecuentemente disminuye los costos de la producción agrícola.

El pragmatismo² que ofrece la tecnología de AP (agricultura de precisión) se encuentra en la capacidad de distribuir diferentes dosis según la necesidad, con relación a los puntos o áreas de coordenadas georreferenciadas³ y previamente conocidas.

2.1.1.2. Fases de AP

Para poder aplicar el concepto de AP se debe considerar la variabilidad espacial y la variabilidad temporal donde se expresan las diferencias de producción en un mismo terreno y en una misma cosecha; y en un mismo terreno, pero en diferentes cosechas, respectivamente. Además, incluye un proceso en desarrollo de las tareas que su objetivo es superar los cuellos de botella y así generar nuevas estrategias para conseguir un resultado que favorezcan a la creación de procesos de eficiencia en la producción agrícola.

Como expresa los autores (Ochoa et al., 2012): en referencia al análisis cuantitativo de estos dos tipos de variabilidad integra algunas fases aplicadas en la AP; dicho proceso inicia con la recolección de datos, al utilizar algunas herramientas tecnológicas, tales como: Sistemas de Posicionamiento Global (GPS), Sistemas de Información Geográfica (SIG), percepción remota, tecnologías de dosis variable (sensores, controladores) y análisis de datos georreferenciados que permiten obtener datos en cualquier etapa del cultivo. Sin embargo, las mejores prácticas se basan a partir de una base de datos previamente ingresada en un mapa para llevar a cabo la acción, además, utiliza dispositivos en tiempo real, como los sensores.

² Tendencia a conceder primacía al valor práctico de las cosas sobre cualquier otro valor.

³ Localizar geográficamente, a través de referencias de latitud y longitud, el punto de recolección de datos de campo.

Por otra parte, se encuentra la fase de procesamiento e interpretación de la información que analiza los datos recolectados mediante software estadísticos, redes neuronales y sistemas expertos, de tal forma se obtiene resultados sostenibles para la administración del cultivo.

De este modo para optimizar los recursos se realiza la fase de aplicación de insumos mediante mecanismos como: dosis variable, sistema de control y sistemas de guiado automático, en efecto, genera estabilidad económica en la producción agrícola.

Finalmente, la evaluación y seguimiento es una fase importante debido a los resultados alcanzados, ciertamente se obtienen beneficios para el agricultor donde los procesos son óptimos, mediante monitoreo de rendimiento, y otras herramientas. A continuación, la figura 1 muestra el ciclo de las fases de agricultura de precisión.

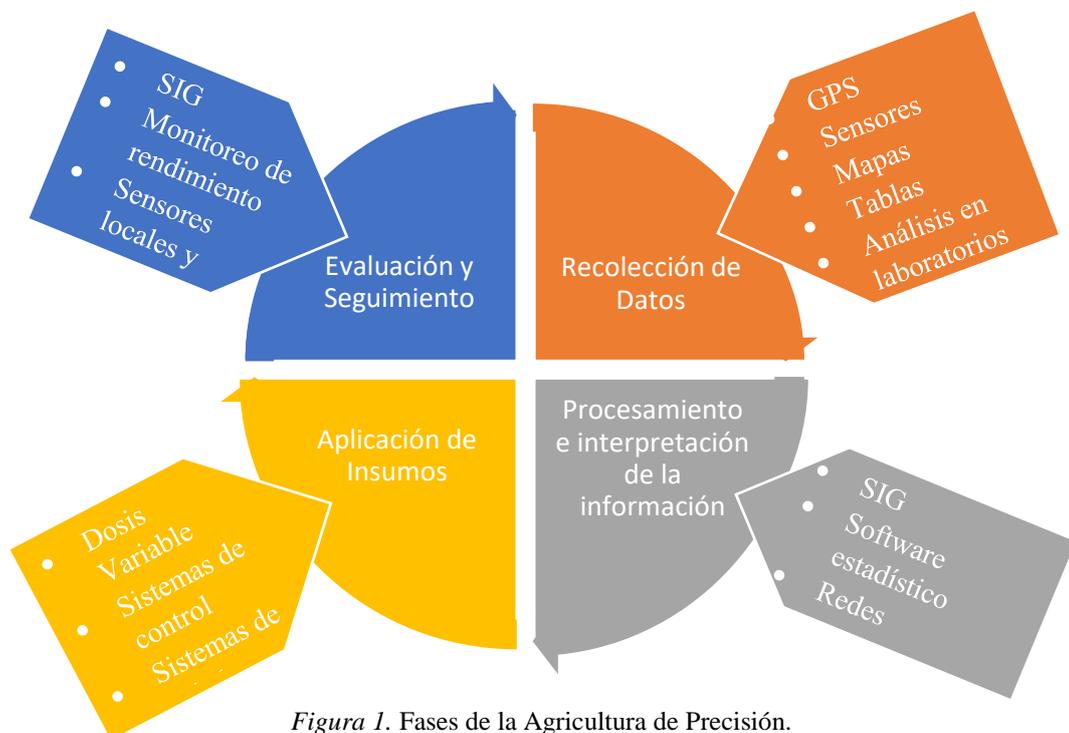


Figura 1. Fases de la Agricultura de Precisión.

Fuente:(Ochoa et al., 2012)

2.1.2. Cultivo del tomate riñón

En relación con el proceso de cultivo, se debe hacer un análisis con respecto al suelo, los factores que integran el índice de microelementos, el desarrollo de plagas concurrentes en el área, la tasa de producción, el estado de la geografía, sin embargo, se han presentado una variedad de enfoques para la agricultura sostenible, como mecanismos de prevención para mejorar el rendimiento al integrar técnicas de manejo como: el enraizamiento de las plantas, deshierbe, aporque, cambios en el surco, fertilización, riego frecuente, aplicación de fertilizantes o fertilizantes de medida coalescente están incluidos.

2.1.2.1. Condiciones climáticas

El cultivo de tomate riñón necesita varias exigencias de microclima para obtener óptimos resultados para el efecto interviene la temperatura y humedad relativa, y fundamentalmente mantener el estado sanitario del cultivo. Como expresa Pichisaca (2003): “Estos factores experimentan amplias variaciones de una zona a otra, por la altitud en que se encuentran, el cultivo, el microclima presente en la zona, la nubosidad, etc.” (p.11). Por lo cual es importante considerar factores que influyen en el campo agrícola sobre la temperatura mediante riego, la calidad de la semilla y los agroquímicos que se van a administrar.

2.1.2.2. Temperatura

Este es uno de los factores más predominantes en el desarrollo del cultivo, debido al trabajo infatigable que realiza la fotosíntesis, puesto que puede beneficiar o perjudicar a la planta de acuerdo con el nivel de temperatura óptimo como se muestra en la tabla 1. Por lo tanto, la velocidad de crecimiento es óptima cuando las condiciones del medio ambiente son idóneas, estas variaciones de temperaturas como manifiesta Pichisaca (2003): “la

temperatura diaria favorece a los procesos fisiológicos como la germinación de semillas, el alargamiento de tallos, la floración, la fructificación y la precocidad” (p.11). Cabe señalar que influye en la asimilación de alimentos, no obstante, las temperaturas en las noches permiten un crecimiento mayor debido al balance hídrico.

Tabla 1. Temperaturas críticas para el cultivo del tomate riñón

Descripción		Temperatura
Se huela la planta		-2°C
Desarrollo normal de la planta		18-25°C
Mayor desarrollo de la planta		21-24°C
Germinación óptima		25-30°C
Temperaturas óptimas		
Desarrollo	Diurna	23-26°C
	Nocturna	13-16°C
Floración	Diurna	23-26°C
	Nocturna	15-18°C
Maduración		15-22°C

Nota. Fuente: (Allende et al., 2017)

El rango de temperatura registrada en la parroquia Imbaya de Antonio Ante se encuentra a una altura de 3200 msnm⁴, fluctúa entre los 12 y 20 °C en zonas altas, con esas condiciones se considera la planta de tomate riñón termo periódica, porque su crecimiento varía con la temperatura en relación con temperatura variable que con temperatura constante. (Oñate Valdivieso, 2012)

⁴ Metros sobre el nivel del mar.

2.1.2.3.Humedad del aire

La humedad relativa debe ser mayor al 50% debido a que la planta expulsa agua en forma de vapor hacia la atmósfera y así, favorece a su crecimiento. Por otro lado, exagerar en su distribución reduce la absorción del agua y sus nutrientes, lo óptimo sería valores entre 60% y 80%. Además, si los valores se encuentran por encima, es favorable para las plagas y enfermedades consecuentemente reducen el rendimiento e incrementan costos de operación. (Allende et al., 2017)

2.1.2.4.Viento

Este factor es importante de notar ya que cumple la función de regulador de la temperatura y humedad relativa, al expulsar los excesos de humedad, además, interviene en la polinización⁵ y oxigenación de la plantación. (Jaramillo, 2015)

2.1.2. Preparación del suelo

En este aspecto las condiciones del suelo no son tan exigentes, pero su desarrollo es mejor aprovechado en suelos de textura franco-arcilloso-arenoso y arcilloso-arenoso, debido a los compuestos orgánicos. En este contexto, pueden ser desde ligeramente ácidos 5.8 de pH hasta ligeramente alcalinos con 6,5 de pH. No obstante, el cultivo en campos agrícolas soporta mejor las condiciones de salinidad, como en el suelo y agua, pero es sensible a la presencia de charcos. (Meza et al., 2013)

⁵ La polinización es el proceso de transporte del polen de una flor (A) hacia otra flor (B).

Para mejores prácticas recomienda Jaramillo (2015): "Por lo menos 15 días antes del trasplante, es necesario arar, cruzar y nivelar el suelo, para dejarlo suelto, mullido, libre de terrones, y facilitar la realización de camas para el cultivo" (p. 21). También es conveniente utilizar cascarilla de arroz o cascajo⁶, con la finalidad de mejorar el suelo para la correcta asimilación de nutrientes.

Seguidamente pasa a una etapa de surcado, el cual se realiza al abrir una abertura de 5 a 10 cm de profundidad, como muestra la figura 2, donde se ubica la materia orgánica descompuesta de 2000 a 6000 Kg por 1000m² y el fertilizante de base depende del análisis del suelo. Es importante la preparación de las camas para incorporar la técnica del acolchado, la distancia de estas es considerado de acuerdo con el manejo del agricultor, pero se recomienda que deben tener 0,6m de ancho por 0,15m de altura, y así se consigue un manejo adecuado del cultivo y de esta manera aumenta la productividad. Se recomienda recubrir con una lámina de plástico para controlar las malas hierbas y reducir la evaporación del agua.(Jaramillo, 2015)



Figura 2. Construcción de camas para el cultivo.

Fuente: (Jaramillo, 2015)

⁶ Fragmentos de piedra y de otros materiales parecidos que pueden quebrarse.

2.1.3. Manejo del cultivo

El autor López Martín, (2017) indica que previo al crecimiento de las plantas de tomate riñón se debe considerar algunas de las fases, la primera que cuente con un sistema de riego artesanal de forma estable y continuo en dosis administradas de acuerdo con el ambiente, en ese sentido, se encuentra algunas de las actividades derivadas como la fertilización foliar rudimentaria, la cual sirve para suministrar los nutrientes a las plantas en dosis correctas de alta solubilidad y así mejora la capacidad de crecimiento.

La segunda de fase consiste en realizar la extracción de malas hierbas para mejorar la productividad. Otra de estas es la poda de las ramificaciones del tallo y hojas, que son motivo de pérdida de nutrientes al ser mal distribuidos hacía las ramificaciones en lugar de ser aprovechados netamente por el tallo principal.

Dentro de otra fase consta el tutorado, la cual es una parte fundamental, funciona cuando el cultivo está en un período de un mes, la planta necesita un eje que soporte el peso del tomate, por lo tanto, se realiza la instalación del tutorado con la tensión de alambres y pilares cada cierta distancia, de esa manera en un futuro el peso será homogéneo y así resulta conllevar el peso de los frutos en los soportes principales.

Por otra parte Allende et al., (2017) expresan que la planta de tomate riñón al encontrarse en un período entre los dos y tres meses se debe abonar de nuevo para que los frutos asimilen los nutrientes equitativamente por toda la planta, en el transcurso de crecimiento se realiza el proceso de fertilización rudimentaria en dosis homogéneas, para culminar este proceso el fruto comienza a madurar y se empieza a cosechar de manera esporádica de acuerdo a como madure el fruto.

2.1.4. Plagas y enfermedades del tomate

En la actualidad, el manejo de los cultivos se realiza en base a nuevas técnicas, en ese sentido el control de las plagas y enfermedades ha tenido algunas dificultades con nuevas especies patógenas, causadas por varios agentes entre los que se puede señalar hongos, bacterias, virus e insectos.(Jaramillo, 2015) Por otro lado, en el desarrollo del cultivo no está libre de virus, plagas y enfermedades, de acuerdo con las condiciones del suelo y el clima que no son las idóneas, lo que permite la proliferación de estos, donde el cultivo se ve afectado en gran medida desde edades tempranas. Esto se puede atribuir al hecho de que se estima el follaje de la planta, sin embargo, al considerar su fisiología de la planta, se evalúan las técnicas para determinar los índices morfológicos para saber si la planta está enferma.

2.1.4.1. Plagas comunes del tomate

Algunas de las plagas que se pueden señalar son producidas por condiciones edafoclimáticas⁷ los cuales son idóneos para su desarrollo presentadas a temperaturas superiores a 25°C entre las plagas más comunes como muestra la tabla 2, además, se puede visualizar las evidencias en la figura 3 de los diferentes tipos de plagas (Agrocalidad, 2015), (Jaramillo, 2015):

⁷ Perteneciente o relativo al suelo y al clima.

Tabla 2. Manejo de las principales plagas.

Plaga	Distribución,	Daño en la planta	Manejo integrado de la Plaga
Mosca blanca (Bemisia tabaci / Trialeurodes vaporariorum)	Afecta diversos cultivos. Los ataques son mayores en la época seca.	Afecta la planta desde la germinación hasta la cosecha y transmite virus. Los daños directos son amarillamiento, debilitamiento de la planta y caída de las hojas. (hojas terminales enroscadas, moteados cuando el ataque es significativo).	Hacer semilleros en ambiente protegido, realizar la limpieza de arvenses (escobilla). Para las plagas se pueden emplear sales potásicas de ácidos grasos.
Áfidos o pulgones (Myzus persicae (Sulzer))	Es cosmopolita y polífago, causa daño en cultivos hortícolas como tomate, además, puede sobrevivir a temperaturas muy bajas, pero a 6 ° C se inmovilizan.	Causa daños directos, como deformaciones y abolladuras en las hojas de la zona de crecimiento. Los adultos y las ninfas extraen la savia elaborada, lo que ocasiona el debilitamiento general de la planta, un retraso en el crecimiento y el amarillamiento del follaje.	Usar mallas anti insectos en las aberturas laterales, las cenitales y las puertas de los invernaderos, evitar roturas en los plásticos, proteger los primeros estados vegetativos de las plantas, realizar la rotación de cultivos, hacer uso racional de los insecticidas.

Minador de la hoja, Liriomyza trifolii (Diptera: Agromyzidae)	Es muy polífaga ⁸ , con más de 120 hospederos. Ocasiona daños en los cultivos hortícolas de berenjena, calabacín y tomate.	Las larvas se desarrollan en el interior de las hojas, esto causa galerías o minas. Se alimentan primero de hojas viejas, que se secan y caen. Los daños iniciales al follaje se presentan como puntos similares a la cabeza de un alfiler.	Colocar mallas anti insectos y plástico en las aberturas laterales, eliminar malezas, eliminar las hojas de las zonas bajas de la planta en ataques severos, distanciar en el tiempo la realización de la nueva plantación.
Nematodo de las agallas (Meloidogyne arenaria, M. incognita, M. javanica)	Tiene una amplia distribución, por sobreponerse a las condiciones ambientales desfavorables y al grado de parasitismo en la planta.	El cultivo de tomate es muy susceptible al ataque por nematodos fitoparásitos. Los primeros síntomas superficiales se presentan como atrofia, marchitamiento y una apariencia descolorida de la planta en general. En las raíces produce abultamientos o agallas por la transformación de los tejidos, los cuales son fácilmente visibles.	Usar variedades resistentes en combinación con prácticas culturales que reducen las poblaciones de nematodos, hacer una buena preparación del suelo, una rotación de cultivos, una aplicación de abonos verdes y la solarización previa a la siembra.

Nota. Fuente: (López Martín, 2017) (Infoagro Systems S. L., 2016)

⁸ Que se alimenta de varios huéspedes.



A



B



C



D

Figura 3. A, B. Mosca blanca en el follaje y Moscas adultas en las hojas. C, D. Nemátodos en el cultivo y Minador en la hoja.

Fuente: (López Martín, 2017) (Meza et al., 2013).

2.1.4.2. Enfermedades del tomate

Generalmente estas enfermedades son causadas por hongos, bacterias y virus. Las condiciones a las cuales se desarrollan de una manera exponencial dependen de altas temperaturas, humedad relativa del 80%; de esta forma, el tiempo ponderado de contagio no es inmediato, pero empieza con algunos síntomas en partes de las plantas.

Por consiguiente, se muestran tablas que señalan la distribución, síntomas y manejo integrado y las figuras de evidencias de cada tipo de enfermedad. Entre las más importantes

se identifica en la tabla 3 sobre las enfermedades producidas por hongos y su fisiología se muestra en la figura 4. (Jaramillo, 2015)

Tabla 3. Manejo de las principales enfermedades producidas por hongos.

Enfermedad	Distribución, hospederos,	Síntomas	Manejo integrado de la Enfermedad
Tizón tardío o apagón (Phytophthora infestans)	Está distribuido en todo el mundo y los hospederos son las solanáceas. Se ve favorecido por humedades relativas superiores a 90 % y temperaturas entre 10 °C y 25 °C.	Destruye el follaje, los tallos y los frutos de la planta en cualquier etapa de su crecimiento. Las lesiones son necróticas y pueden ser extensivas, son de color café y delimitadas por las nervaduras y con un halo clorótico a su alrededor.	Hacer lomillos altos para evitar el empozamiento, usar genotipos con resistencia, hacer rotación de cultivos, eliminar los residuos vegetales del cultivo, las plantas voluntarias y las malezas.
Tizón temprano o bajera (Alternaria sp, A. solani. A. lycopersici)	Se dispersa por acción del viento, la lluvia, el salpique de la lluvia y restos de plantas enfermas. Sobrevive en el suelo y en residuos de cosechas por más de un año.	Afecta cualquier etapa del desarrollo de la planta, al ser más frecuente en la fructificación. Causa daños severos y forma un chancro negro en el tallo a ras del suelo, afecta las hojas, los tallos, los frutos y los pecíolos.	Hacer control de arvenses, eliminar los residuos de cosecha, aplicar riego por goteo y en la mañana, favorecer la aireación de las plantas, usar semillas o plántulas sanas y desinfectadas.

Mildiu polvoso o cenicilla (Leveillula taurica, Erysiphe orontii y Oídium lycopersicum)	Es capaz de desarrollarse en rangos de 10 °C a 35 °C, con un óptimo de 27 °C y una humedad relativa entre 52 % y 75 %.	Afecta el follaje de la planta e inicia con pequeñas manchas de color café amarillento en el haz de las hojas, que se vuelven necróticas en el centro y se puede mirar un micelio de color blanco en el envés.	Eliminar las arvenses y los restos de residuos del cultivo, usar variedades resistentes y trasplantes sanos. Bajo un manejo integrado de plagas se pueden emplear fungicidas.
Cladosporiosis o Moho de la hoja (Fulvia fulva conocido anteriormente como Cladosporium fulvum)	Tiene una amplia distribución, por sobreponerse a las condiciones ambientales desfavorables y al grado de parasitismo en la planta.	Las lesiones son de color verde o amarillento en el envés de las hojas más viejas y se desarrollan masas de las estructuras del hongo de color verde olivo a café, similares al terciopelo.	Procurar una buena circulación del aire y reducir la humedad relativa en menos del 85%, utilizar variedades resistentes, hacer un manejo integrado de plagas.
Antracnosis o podredumbre negra (Colletotrichum coccodes, C. dematium, C. gloesporioides y otras especies.	El hongo puede permanecer varios días debajo la cutícula y la epidermis y al producirse bajas temperaturas de 20 °C a 24 °C.	Producen manchas en las hojas y los frutos similares a quemaduras de sol. La infección puede ocurrir en las frutas, los tallos, las hojas y las raíces.	Evitar el riego por aspersion y que los frutos permanezcan en el suelo; utilizar un programa de aplicación de fungicidas en el desarrollo.

Nota. Fuente: (López Martín, 2017) (Infoagro Systems S. L., 2016)



A



B



C



D



E



F

Figura 4. Síntomas de enfermedades fúngicas. A, B. Apagón en hojas y frutos (*P. infestans*). C, D. Moho de hoja y Tizón Temprano. E, F. Antracnosis y Oidium en la hoja de tomate riñón.

Fuente: (López Martín, 2017) (Meza et al., 2013).

Además, atacan al cultivo enfermedades causadas por bacterias que su condición es difícil de tratar, en ese aspecto se recomienda prevenir una infección bacteriana. Entre las más importantes se identifica en la tabla 4 sobre las enfermedades producidas por bacterias y su fisiología se muestra en la figura 5. (Jaramillo, 2015)

Tabla 4. Manejo de las principales enfermedades bacterianas

Enfermedad	Distribución, hospederos,	Síntomas	Manejo integrado de la enfermedad
Maya o mancha bacterial (Ralstonia solanacearum)	Afecta cultivos como tomate, chile dulce y papa. Se propaga por agua de riego, tierra contaminada, plantas enfermas y residuos vegetales.	Se presenta en tejidos conductores del agua y bloquea los conductos, la planta se queda sin agua donde los frutos siguen unidos a la planta ya muertos.	Utilizar cultivares con resistencia a la bacteria y plántulas libres de la enfermedad, elaboración de drenajes en la plantación.
Peca bacteriana/ Pringue bacterial	Es una bacteria aeróbica facultativa, se distribuye por todo el mundo.	Ataca todas las partes aéreas de la planta, hojas, tallos, pecíolos y flores, esto provoca manchas redondeadas en las hojas.	Evitar agua libre sobre las plantas y favorecer la ventilación, eliminar plantas y frutos enfermos.
Pudrición suave bacterial/ Necrosis de la médula (Pectobacterium carotovorum)	Es una bacteria peptolítica de regiones tropicales, que afecta hortalizas (lechuga, papa, pepino, tomate).	Afecta plantas jóvenes, que presentan hojas de color amarillo y el daño inicia en la base del tallo.	Eliminar plantas y frutos enfermos, utilizar semillas sanas, desinfectar materiales y equipo de trabajo a nivel preventivo.

Nota. Fuente: (López Martín, 2017) (Infoagro Systems S. L., 2016)

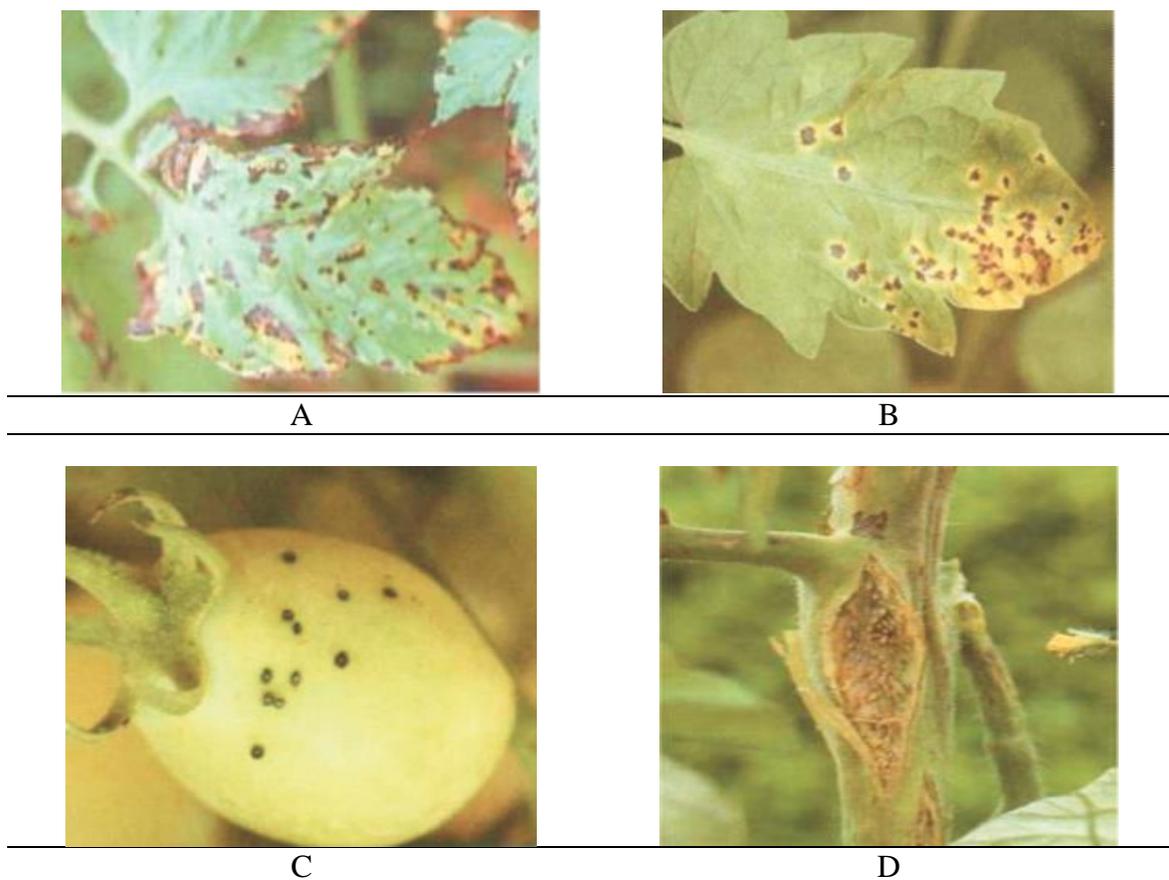


Figura 5. A, B. Mancha bacterial y peca bacterial C, D. Peca bacterial en fruto y necrosis.

Fuente: (López Martín, 2017) (Meza et al., 2013).

En el cultivo es significativo las enfermedades causadas por virus, dan relación que producen grandes daños, su control es difícil y en corto tiempo llegan a perder la plantación. Entre las más considerables se encuentran en la tabla 5 sobre las enfermedades producidas por virus y su fisiología se muestra en la figura 6. (Jaramillo, 2015)

Tabla 5. Manejo de las principales enfermedades virales.

Enfermedad	Distribución, hospederos,	Síntomas	Manejo integrado de la Enfermedad.
Virus del mosaico del tomate (ToMV)	Provoca daños en cultivos de tomate en ambientes protegidos y a campo abierto.	Tienen alteraciones en la forma y el color de los folíolos, moteados verde claro y oscuro.	Usar variedades con resistencia, destruir las plantas con síntomas de la enfermedad.

Virus del torrado del tomate (ToTV)	Infecta a otras especies de la familia de las solanáceas, es muy agresivo y causa pérdidas cuantiosas.	Causa necrosis y presenta manchas necróticas rodeadas por un área verde claro o amarillo que empieza en la base de los folíolos. La infección produce una severa necrosis de las hojas y los frutos, lo que tiene graves consecuencias económicas.	Sembrar variedades resistentes, controlar los vectores del virus, colocar trampas amarillas para reducir las poblaciones de insectos, colocar doble malla en los cenitales y las puertas de los invernaderos.
-------------------------------------	--	--	---

Nota. Fuente: (López Martín, 2017) (Infoagro Systems S. L., 2016)



A



B

Figura 6. A, B. Virus del mosaico del tomate y virus del torrado del tomate.

Fuente: (R. P. García, 2015)(INIA, 2014)

2.1.4.3. Tizón tardío (Phytophthora infestans)

Esta propiamente se evidencia en el follaje, como muestran los síntomas en la figura 7, por consiguiente, indican el comportamiento de esta enfermedad, como expresa (Meza et al., 2013): “se manifiesta a través de grandes manchas húmedas con centros secos y pardos, las cuales están rodeadas por un margen claro que se desarrolla en el envés” (p. 44), estos rasgos se presentan particularmente en la hoja, ya que en ese sentido son indicios de la presencia de esta plaga.

En efecto, las condiciones a las cuales se produce su infección (Meza et al., 2013), son en temperaturas cercanas de 20°C y una humedad relativa sobre 75%. Por lo tanto se debe considerar las condiciones edafoclimáticas las cuales son ideales para su desarrollo, relativamente la formación de esporangios considera (Meza et al., 2013) que el 91 a 100% de humedad relativa y una temperatura de 22 a 26°C.

Finalmente, es una de las enfermedades más peligrosas del tomate riñón que podría resultar la pérdida del cultivo, en ese sentido, podría verse propagado por todas las partes de la planta sin un correcto control (Jaramillo, 2015), sin embargo, el desarrollo de este tipo de plagas se identifica en relación al contacto directo con la lluvia, debido que liberan las zoosporas en el agua, presente sobre las superficies foliares, que facilitan así la dispersión del patógeno e incremento de la enfermedad. (Cardona et al., 2016)



Figura 7. Planta de tomate riñón con la enfermedad *Phytophthora infestans*.

Fuente: Terreno del Propietario

2.1.4.4. Manejo integrado de la enfermedad tizón tardío (*Phytophthora infestans*)

Como una de las buenas prácticas lo que se debe hacer es retirar los restos vegetales al final del cultivo, para que no se quede enfermedades de cultivos anteriores, por lo tanto, como medidas de precaución en primera instancia se debe considerar antes de la plantación, realizar un estudio de variedades resistentes para posteriores afectaciones, además, una fumigación con componentes propiamente para su eliminación, monitoreo periódico fitosanitario del cultivo, fertilización balanceada, preparación del suelo, desinfección de herramientas, recolección de frutos enfermos, entre otras. (Agrocalidad, 2015)

2.1.5. Herramientas de adquisición de datos

Para conseguir el objetivo es necesario conocer algunas herramientas que permiten la interacción del sistema con el usuario, en ese contexto, se detallan las herramientas idóneas que permiten capturar la imagen y a su vez transmitirla, por esta razón se consideran las prestaciones de cada una de estas.

2.1.5.1. Dispositivo de captura

En la actualidad, se ha identificado muchas herramientas que han sido de gran ayuda para obtener más información de una fotografía, en ese contexto, un sistema de visión artificial necesita de una cámara con grandes prestaciones que permiten abstraer diferentes aplicaciones en diferentes campos, de este modo, se utiliza la cámara del dron con la finalidad de inspección, monitorización, mapeo, agricultura de precisión e ingeniería civil, a continuación, en la tabla 6 se describe algunos de los drones utilizados para el desarrollo del proyecto.

Tabla 6. Clasificación de los drones según la aplicación.

APLICACIÓN	NOMBRE	CARÁCTERÍSTICAS	FOTO
	Yamaha RMAX	Es un helicóptero no tripulado cuya función principal en la agricultura es la fumigación, sobre todo en cultivos como el trigo y arroz.	
AGRICULTURA Y MONITOREO	DJI Agras MG-1	Según especifica DJI en las características de este dron el sistema de propulsión del MG-1 permite que su carga llegue a ser de hasta 10 kg de líquido de fertilizantes, se compone de un spray capaz de adaptar la cantidad que expulsa.	

Figura 8. Helicóptero Yamaha

Fuente: (Sato, 2003)

Figura 9. DJI Agras MG-1

Fuente: (DJI, 2016)

	Ebee SQ	<p>La empresa francesa Parrot. Es uno de los drones más eficaces en su campo debido su autonomía, es decir, a la cantidad de hectáreas que es capaz de cubrir en un mismo vuelo.</p>	 <p>Figura 10. Ebee SQ Fuente: (SENSEFLY, 2019)</p>
	DJI mavic 2 zoom	<p>Tiene grandes prestaciones con una cámara con sensor CMOS de 1" que permite hacer fotos de 12 megapíxeles, grabar videos 4K, admite zoom óptico 2x. Además, cuenta con un GPS y un sistema de visión para los obstáculos, con una duración de vuelo de 31 minutos.</p>	 <p>Figura 11. DJI zoom 2 Fuente: (DJI, 2018)</p>
VIGILANCIA	Skunk Riot Control Copter	<p>Manejar grandes masas como manifestaciones, sin poner en riesgo la vida de los ciudadanos o agentes de seguridad. La empresa describe el sistema de seguridad.</p>	 <p>Figura 12. Drone Octocopter Fuente: (DJI, 2018)</p>

SERVICIOS	Drone Octocoper y de la marca Dji	Es uno de los drones que permite tener enfoques de medicina, Mensajería y utilizados para la fotografía.	 <p data-bbox="1053 470 1434 553">Figura 13. Shunk Riot Copter Fuente: (Bradford, 2015)</p>
-----------	-----------------------------------	--	---

Nota. Fuente: (Mart & Gonz, 2018)

2.1.5.2. Planificación de misiones

Con respecto a la planificación de misiones, tenemos las condiciones idóneas para obtener una recopilación adecuada de los datos, es decir, el aumento de la resolución de la imagen (volar más bajo y lento) de este modo se consigue mejores prestaciones al volar y procesar los datos. (Energy et al., 2016)

2.1.5.2.1. Altitud del vuelo

Dentro de este marco se define la altitud en función del tamaño de las plantas y el tipo de datos que se dese obtener, en efecto, se relaciona al hecho de la teledetección en la resolución. Por lo que, se integra una definición de la distancia de la muestra de tierra (GSD) señalado como un eje en el desarrollo de la agricultura de precisión. Como expresa Energy et al., (2016): “GSD se define como la dimensión lineal de un píxel proyectado sobre el suelo, medido en pulgadas o centímetros. Para mediciones de precisión de la vegetación, el GSD del sistema debe ser más pequeño que las plantas que se miden.” en este contexto, si los pixeles son más grandes que una planta individual se tendrá como resultado, que la planta se unirá con el suelo desnudo circundante y así limitar la identificación, conteo y medición con precisión de las plantas.

Seguidamente existe una herramienta funcional como son las calculadoras de vuelo que vienen añadidas a las plataformas de planificación de vuelo, ya que el GSD conseguido por su sistema SLANTRANGE definida como una función en base al sensor que se ocupa en relación a su altitud, donde los mapas de población se vuelan entre 20 y 40 metros de altitud que utilizan sensores 2p o 3p, y entre 10 y 20 metros sensor 1p, de este modo en la tabla 7, se establece una referencia entre GSD y la altitud de vuelo.(Energy et al., 2016)

Tabla 7. Distancia de muestra de suelo (GSD) en función de la altitud sobre el suelo

Altitud (m)	25	30	35	45	60	90	120
1p- GSD (m)	0.019	0.023	0.026	0.034	0.045	0.068	0.090
2p,3p- GSD (m)	0.010	0.012	0.014	0.018	0.024	0.036	0.048

Nota. Fuente: (Energy et al., 2016)

2.1.5.2.2. Contabilidad del viento

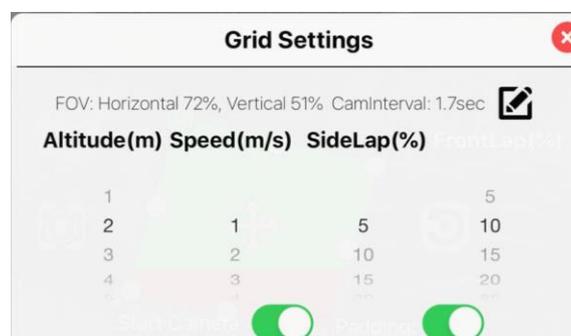
Debe señalarse al viento como un factor poco significativo, pero no despreciable, es decir que en condiciones de viento en ráfaga y turbulencias pueden que causar daños al UAV y así reducir la calidad de los datos. En este marco, se debe diseñar un plan de vuelo adaptable a estas condiciones de tal manera que las patas de vuelo sean de viento cruzado (90 grados a la dirección predominante del viento) para mantener la estabilidad sin presentar cambios excesivos como son: calidad de datos en las patas de vuelo adyacente relacionado a las diferencias en el tono de la aeronave, la distancia de desenfoque y la superposición del aérea a lo largo de la pista.(Energy et al., 2016)

2.1.5.2.3. Iluminación

Los sistemas SLANTRANGE cuentan con un diseño que permite compensar los cambios de iluminación a lo largo de un solo vuelo y de vuelo a vuelo, en ese sentido esta compensación permite abstraer muestras. El sensor mide la luz ambiental y ajusta el tiempo de exposición en cada fotograma en función de la condición de iluminación medida. Desde luego hay varios escenarios en condiciones brillantes el tiempo de exposición es bajo y en condiciones más oscuras (cielo nublado), el tiempo es mayor, y produce que las imágenes se desenfocan con mayor facilidad. (Energy et al., 2016)

2.1.5.3. Formas de monitoreo del cultivo

En adición con el plan de vuelo del drone es importante conocer la zona a la cual se va a monitorear, de este modo se define y guarda el plan de vuelo, luego se almacena los datos del mapa en la memoria cache del móvil. En efecto, la trayectoria está definida por varios puntos de ruta (waypoints) para crear un plan de vuelo; estos permiten definir ciertos parámetros como se muestra en la figura 14, en cada una de las trayectorias de acuerdo con las condiciones inherentes del proyecto. Algunas de las rutas usadas en aplicaciones de agricultura de precisión son de forma rectangular y poligonal. (Energy et al., 2016)



	Altitude(m)	Speed(m/s)	SideLap(%)	FrontLap(%)
1				5
2	1		5	10
3	2		10	15
4	3		15	20

Figura 14. Parámetros de puntos de ruta (waypoints).

Fuente: (Energy et al., 2016)

2.1.5.3.1. Ruta de forma rectangular

La estructura de forma rectangular es homogénea tanto en el solape frontal (FrontLap) y solape lateral (SideLap) conformada por cada esquina como se evidencia en la figura 15, esta permite adaptar los parámetros de velocidad, altura, intervalo de cámara. Al terminar la ejecución de la trayectoria de acuerdo con el número de puntos, que son generados por los parámetros regresa al lugar de origen. Además, puede grabar videos en resoluciones considerables. (Energy et al., 2016)

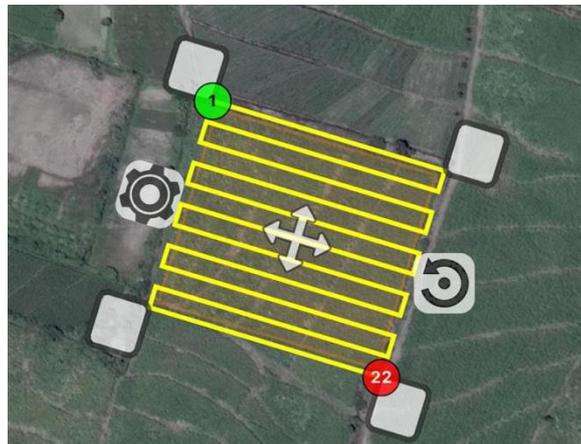


Figura 15. Ruta de forma rectangular

Fuente: Aplicación Flight Plan en el terreno.

2.1.5.3.2. Ruta de forma poligonal

Esta forma es aplicable en superficies irregulares para poder determinar la trayectoria de acuerdo con las líneas del cultivo para determinar el número de puntos de ruta (waypoints) en los vértices del área como muestra la figura 16, además, esta forma permite ser ideal en casos de estudio de acuerdo con el área de estudio.

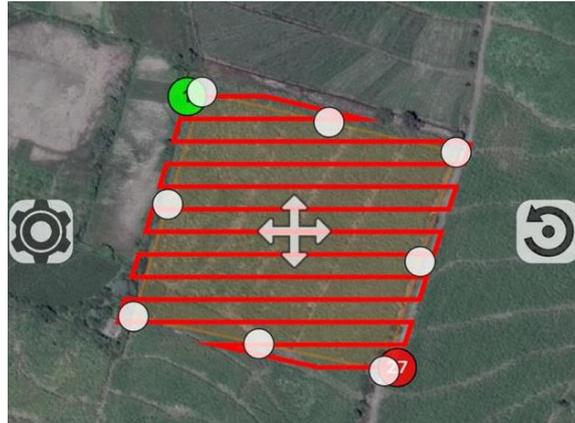


Figura 16. Ruta de forma poligonal

Fuente: Aplicación Flight Plan en el terreno.

2.1.6. Tecnología de transmisión

Dentro de este campo muchos de los servicios de streaming se transmiten mediante las redes inalámbricas de área local que tienen como funcionalidad el acceso inalámbrico en zonas con un rango típico de 100 metros. (Salazar, 2012) Actualmente, se implementa la tecnología Wi-Fi que permite tener fiabilidad de los datos como define el autor Belmonte, (2014):” su acrónimo de Wireless Fidelity (fiabilidad sin hilos), es una red de comunicaciones de datos y, por lo tanto, permite conectar servidores, PC, impresoras, etc., con la particularidad de alcanzarlo sin necesidad de cableado.” Se consigue injerencia en el manejo de algunos estándares IEEE 802.11 para aplicaciones que brindan este servicio, además, nunca son configurados de manera cerrada que permite mejorar en lo posible. En cuanto a la transferencia utilizan bandas de frecuencia de 2.4GHz y 5GHz de mucha utilidad por sus conexiones persistentes y de baja latencia.

2.1.6.1. Funcionamiento de Wi-Fi (Wireless Fidelity)

Para las transmisiones de información se implementa un modelo de referencia en base al modelo OSI, ese contexto la norma 802.11 maneja una arquitectura en la capa física y capa de enlace como se muestra en la figura 17.

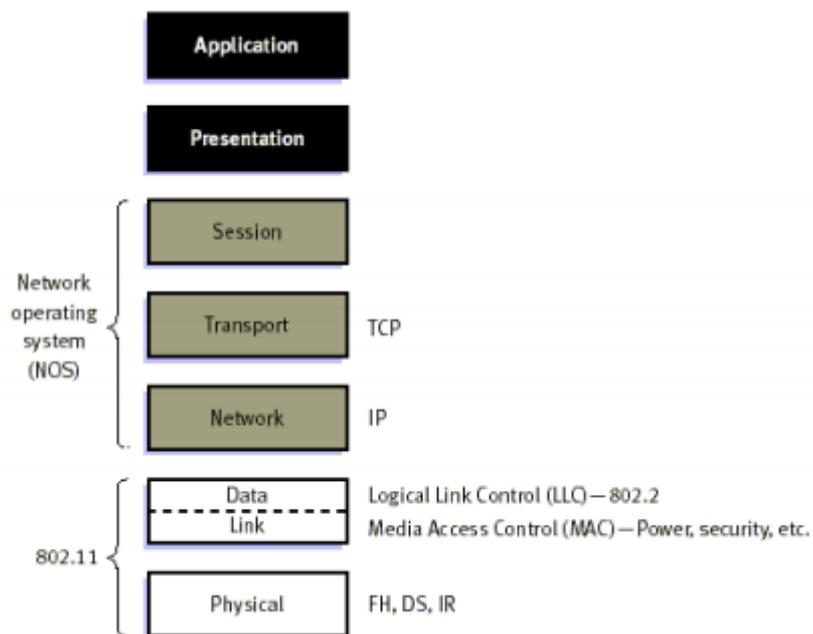


Figura 17. Modelo OSI y Familia IEEE 802.11

Fuente: (Wheelers Lane Technology College, 2016)

En relación con el estándar IEEE 802.11 se relaciona algunas características que son esenciales para la dinámica dentro de la banda de frecuencia, cobertura, modulación como se muestra en la tabla 8.

Tabla 8. Comparación entre normas IEEE 802.11 a,b y g

Estándares Wireless			
Estándar	802.11b	802.11a	802.11g
Velocidad	Hasta 11Mbps	Hasta 54 Mbps	Hasta 54 Mbps
Canales solapados	no 3	8	3
Banda de Frecuencia	2.4-2.497 GHz	5.15-5.35GHz 5.425-5.675GHz 5.725-5.875GHz	2.4-2.497GHz
Costo	Barato	Relativamente caro	Relativamente barato

Cobertura	Buena cobertura, 100m en interior y 300 a 400m en exterior, con buena conectividad con determinados obstáculos.	Cobertura baja, 50m. En interior y 150m en exterior con mala conectividad con obstáculos.	Buena cobertura, 100m en interior y 300 a 400m en exterior, con buena conectividad con determinados obstáculos.
Acceso Público	El número de HotSpots crece exponencialmente	Ninguno	Compatible con los HotSpots actuales de 802.11b. El paso a 802.11b.
Compatibilidad	Compatible con 802.11 g y no compatible con 802.11a	Incompatible con 802.11b y g.	Compatible con 802.11b, no es compatible con 802.11a.
Modos de Datos	1,2,5.5,11 Mbps	6,9,12,18,24,36,48,54 Mbps	1,2,5.5,11 Mbps 6,9,12,18,34,36,48 Mbps
Modulación	CCK(DSSS)	OFDM	OFDM y CCK (DSSS)

Nota. Fuente: (Wheelers Lane Technology College, 2016)

2.2. Visión Artificial

Dentro de las aplicaciones de la inteligencia artificial se desarrolla esta técnica para adaptarse a las necesidades del ser humano, donde Nuñez, (2016) define como: "una rama de la inteligencia artificial cuyo propósito es diseñar sistemas informáticos capaces de "entender" los elementos y características de una escena o imagen del mundo real" (p. 9), al denotar estos sistemas se integra un proceso que permiten extraer información tanto numérica y simbólica a partir de una imagen.

Acerca de este proceso se identifica los campos fundamentales como muestra la figura 18 entre los cuales están la adquisición de imágenes, preprocesamiento de imágenes, segmentación y reconocimiento (Jiménez, 2015).

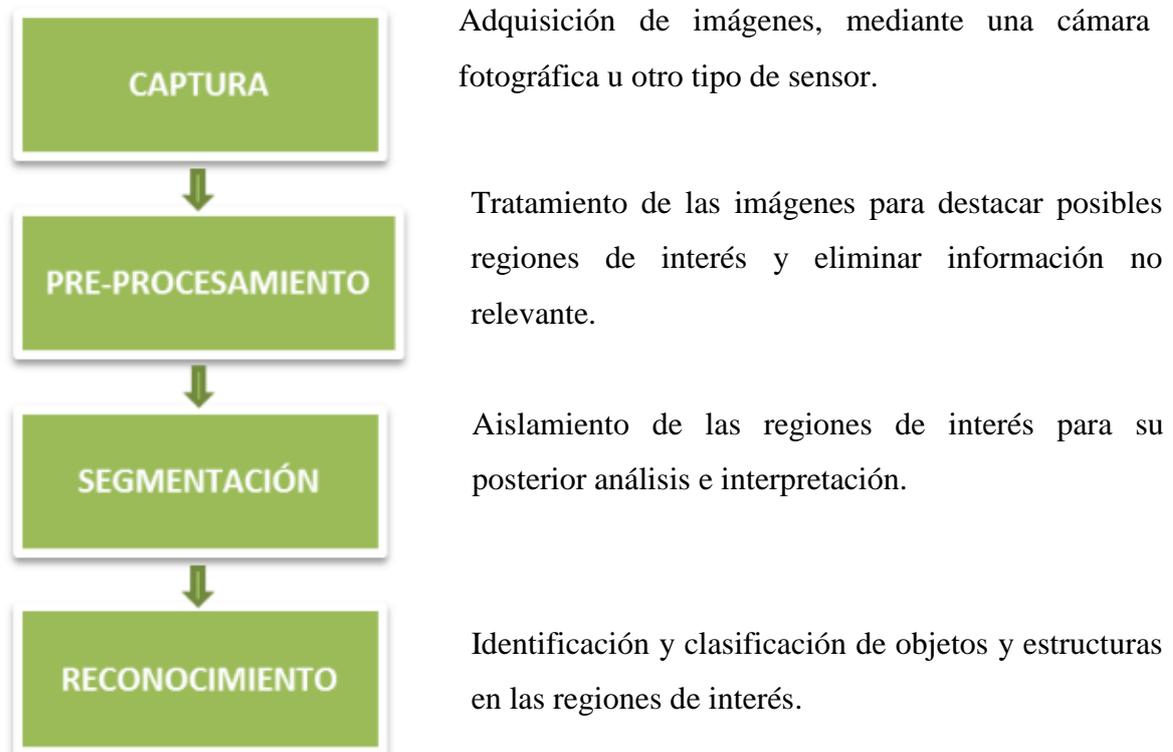


Figura 18. Sistema de visión artificial.

Fuente: (Nuñez, 2016)

2.2.1. Reconocimiento automático de objetos

El reconocimiento de objetos es una fase muy importante al tener muchas aplicaciones, ciertamente se relaciona con la detección de multitudes (Restrepo Cuestas et al., 2007), conteo de personas (Múnera Salazar & Andrés, 2012) e identidades (López Márquez, 2016). Principalmente esta técnica se vincula para facilitar y detectar áreas de interés en las imágenes, al considerar estos patrones permiten realizar procesos que tienen otras características de esta forma se consigue un funcionamiento óptimo. (Nuñez, 2016)

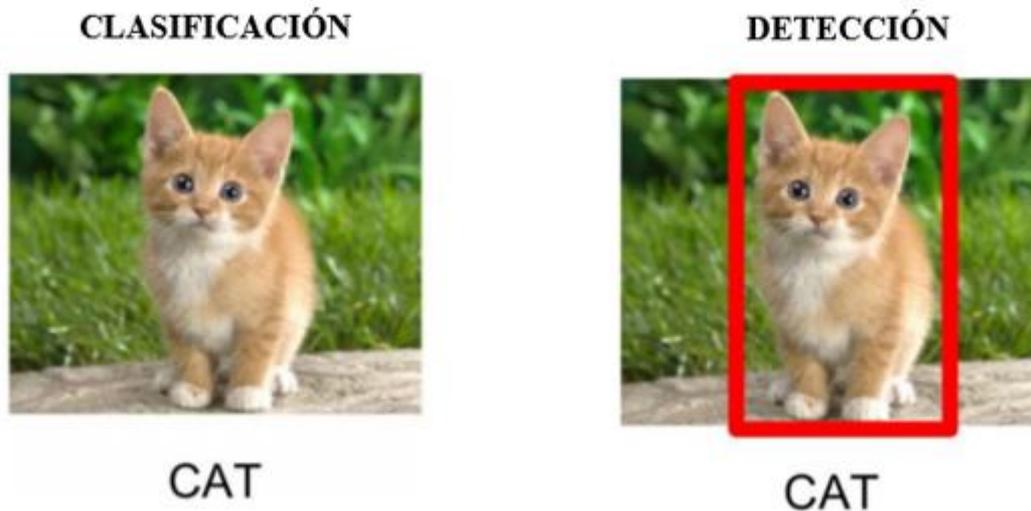


Figura 19.. Detección de Objetos.

Fuente: (Casado García & Heras Vicente, 2017)

En relación de la identificación de objetos se debe considerar si el sistema funciona al distinguir la presencia del perro en la etapa de clasificación de las imágenes y luego en la etapa de detección para saber cuál es el perro de acuerdo con las características propias tanto de morfología o comportamiento, como se muestra en la figura 19, por lo tanto, el sistema reconoce de acuerdo con la imagen ingresada.

2.2.2. Etapas de detección de objetos de una imagen

- *Adquisición de la imagen:* Para poder obtener una imagen con óptimas prestaciones el sistema debe estar integrado: cámara, digitalizador, iluminación. Es importante resaltar que esta fase permite localizar los elementos tanto como posición de la cámara, ruido eléctrico-óptico externo (Robots, 2009) y fundamentalmente la iluminación de la escena es crucial para corregir algún problema antes de implementar un algoritmo complejo. (José Antontio, 2006).

- *Preprocesamiento de las imágenes:* En esta fase se realiza el tratamiento de las imágenes debido a que sufren en niveles bajos los efectos de la degradación y aparece en forma de ruido, pérdida de definición y fidelidad (Robots, 2009), sirve para denotar algunas regiones o áreas de interés y eliminar la información que ya no es necesaria (José Antontio, 2006), al capturar la muestra se debe considerar algunos factores como el mejoramiento del contraste, reducción del ruido, normalización del brillo, transformación del espacio de color, entre otros (Pineda, 2018).
- *Segmentación:* consiste en poner una etiqueta a una imagen que tiene una gran limitación porque se debe considerar algunas condiciones que hacen una tarea compleja (Nuñez, 2016), donde implica aislar las regiones de interés para que en el transcurso del proceso sea mejor su análisis e interpretación, se genera una imagen binaria, donde los píxeles que son del objeto se denotan con un uno, en cambio los que no pertenecen se ubica un cero. (José Antontio, 2006) Es decir estos píxeles son considerados con partes de significado homogéneo en relación a características como el color (Jiménez, 2015), el movimiento (Robots, 2009), forma (Pineda, 2018), entre otros.
- *Reconocimiento del objeto:* Al ya definir esta técnica de clasificador, dentro de este proceso se identifica los objetos que se encuentran en la entrada, donde la imagen pasa por el clasificador y puede reconocer los objetos; y se obtiene un resultado a la salida el objeto de interés con una mejor precisión. Finalmente, el clasificador identifica el objeto de cualquiera de las entradas a la cual se encuentre en el funcionamiento del proceso (Pineda, 2018).

2.3. Aprendizaje Automático (Machine Learning)

Es una rama de la Inteligencia Artificial donde tiene como finalidad que el trabajo de las máquinas vaya de la mano de un software, como define Mohammed, Khan, & Bashie, (2016) como: “El aprendizaje automático es una consecuencia natural de la intersección de informática y estadística” (p. 5), de esa forma es de beneficio para poder explicar algunas tareas de los seres humanos mediante algoritmos que dan como resultado cerrar esta brecha de comprensión.

2.3.1. Técnicas de aprendizaje

Dentro del aprendizaje automático se identifica algunas técnicas que permiten de manera factible aprender algunos patrones para lograr el propósito. En la Figura 20 se muestra las técnicas de aprendizaje automático.

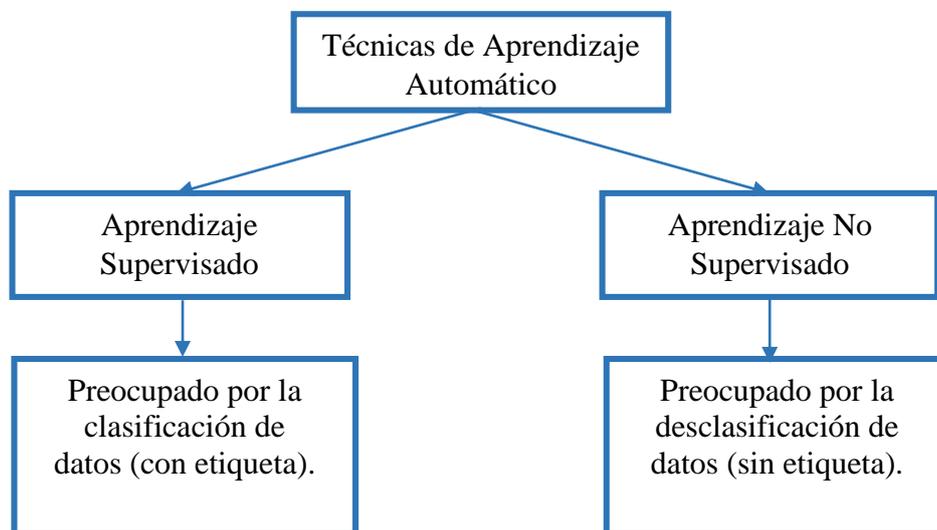


Figura 20. Diferentes técnicas de aprendizaje automático.

Fuente: (Matich Damián, 2011)

2.3.1.1. Aprendizaje Supervisado

La funcionalidad del aprendizaje supervisado resuelve en inferir desde los datos de entrada y salida, previamente clasificados, luego se entrena al algoritmo (Carlos & Pérez, 2018) mediante la modificación de los pesos de la sinapsis para tener un resultado óptimo (Pineda, 2018)

En relación con su definición se encuentra una clasificación en relación con el dominio de su salida, y se obtiene dos tipos de algoritmos como son:

- Clasificación: En relación con el resultado de sus muestras es de manera discreta. Es decir, una serie de eventos que pueden ser ciertos, como se muestra en la figura 21, como ejemplo: Predecir si estará despejado, nuboso o lloverá (Carlos & Pérez, 2018).

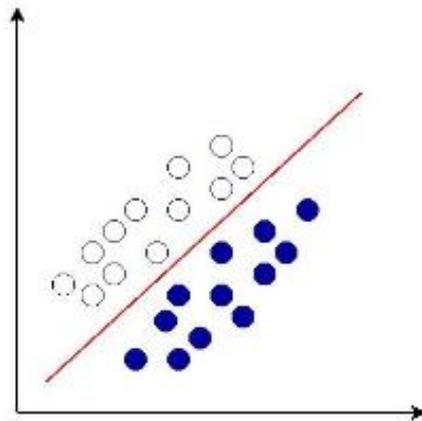


Figura 21. Clasificación lineal

Fuente: (Carlos & Pérez, 2018)

- Regresión: En cambio de esta manera se requiere si es un valor continuo. Todo evento que no tenga interrupciones, como se muestra en la figura 22, como ejemplo: El valor de venta de un inmueble.

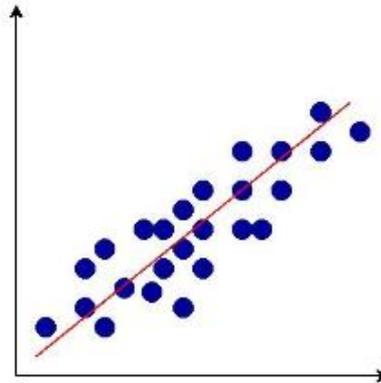


Figura 22. Regresión lineal

Fuente: (Carlos & Pérez, 2018)

Los algoritmos utilizados para aprendizaje supervisado se muestran en la tabla 9:

Tabla 9. Algoritmos de aprendizaje supervisado

Algoritmo	Descripción	Ventajas	Limitaciones
Máquina de vectores de soporte (SVM)	Usados para aprender sobre la clasificación de dos clases diferentes de puntos de entrada. Su funcionamiento radica en obtener información de los vectores de soporte para formar una frontera de decisión.	El entrenamiento es relativamente fácil. No hay óptimo local, como en las redes neuronales. Excelente funcionamiento en obtener información de los vectores de soporte para formar un clasificador y del error pueden ser controlado explícitamente.	Entrenamiento lento si hay entradas con demasiadas clases. Necesario metodologías eficientes para el funcionamiento de los parámetros de inicialización. (BETANCO URT, 2005)

KNN	<p>Su función reside en K-NN realiza las predicciones en base a la vecindad, al hacer predicciones en base a la referencia al número en los ejemplos más cercanos (depende de cada vecino, es decir, parecidos al que hay en el conjunto de datos) engloba la simplicidad de categorías (De-La-García-Cambronero & Hoz et al., 2019). Es muy tolerante al ruido. Su interpretabilidad es nula. (Gómez-Moreno, 2009)</p>
Árbol de decisión	<p>Su estructura es en forma de árbol, la cual permite realizar predicciones específicas, a problemas de datos en el árbol, podría mediante un conjunto de decisiones, y resultados de cada instancia de entrenamiento a la vez se genera un modelo predictivo. (Morales & Escalante, 2012). (Carlos & Pérez, 2012)</p>
Redes Neuronales	<p>Es una colección de nodos llamados neuronas artificiales, diferentes capas para los datos de entrada que recibe luego que tiene que procesar y enviar a otra neurona, al formar un nodo que ajusta el peso. (Carlos & Pérez, 2018). Dependemos mucho del hardware, ya que, según la arquitectura de la red neuronal, y el tamaño del conjunto de datos que se analiza se necesita mayor procesamiento para que el entrenamiento y detección no sean lentos</p>

Bayesianos	<p>Su funcionamiento Óptimo para predecir Necesita una gran cantidad está basado en el clases de datasets dede datos para hacer teorema de Bayes queprueba, funciona bien en estimaciones confiables de está relacionado a lapredicciones multiclase. la probabilidad de cada probabilidad se clase genera un modelo predictivo. Los más utilizados son: Naive Bayes, Gaussian Naive Bayes, Multinomial Naive Bayes, Bayesian Network (Carlos & Pérez, 2018)</p>
------------	--

Nota. Fuente: (Mart & Gonz, 2018)

2.4. Aprendizaje Profundo (Deep learning)

Dentro del campo de machine learning integra el aprendizaje profundo al verse relacionados a una serie de limitaciones al no poder procesar datos en su forma original, por lo cual permite que los modelos computacionales al componerse de múltiples capas aprendan datos con múltiples niveles de abstracción (LeCun et al., 2015), lo que implica que exige demasiada intervención humana para definir los patrones que la maquina debe localizar en la imagen. Esto lo soluciona el aprendizaje profundo o deep learning al determinar las característica destacadas de manera autónoma, y adecúa la información en bruto para que un clasificador pueda establecer la salida del sistema (Aguirre, 2019).

Para comprender sobre este tema, se debe conocer el concepto de redes neuronales artificiales que son un modelo computacional cuya unidad es la neurona artificial muy parecidos a las neuronas de los cerebros biológicos. Las partes fundamentales como se muestra en la figura 23 consiste en las entradas, pesos y el núcleo de la neurona que vendrían conformados por una función de activación y su valor de salida (Raúl E. López Briega, 2012).

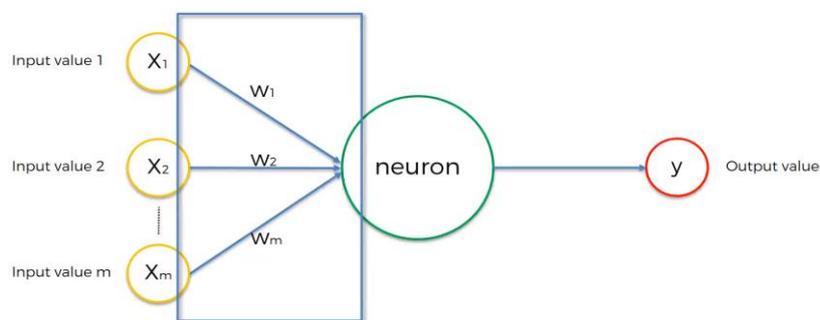


Figura 23. Estructura de una Neurona Artificial

Fuente: (Gonzalez Muñoz & Díaz Blanco, 2018)

El funcionamiento de la neurona es una suma ponderada de los valores que entran en ella, compara las cantidades con un valor umbral de prueba, y si es igual o lo supera envía un mensaje de activación a la salida. La ponderación de los valores de entrada depende de los pesos que se les asigne a las conexiones entre neuronas, estos pesos definirán con que intensidad cada variable de entrada afecta la neurona (Patterson & Gibson, 2017).

Ahora esta unidad al estar interconectada con otras neuronas forma una red constituida en tres capas básicas (esto puede variar al depender del caso) como muestra la figura 24. La capa de entrada o entrada global recibe los datos o variables del entorno externo, esta se encuentra conectada a la capa oculta la cual no tiene contacto con el exterior y cuyas neuronas pueden conectarse de distintas maneras en función de la topología de la red neuronal, esta se encarga de procesar y extraer características de los datos obtenidos de

la capa anterior (Matich Damián, 2011). A su vez la capa oculta se conecta a la capa de salida que determina el valor que se transfiere a las neuronas vinculadas (Borovkov, 2017).

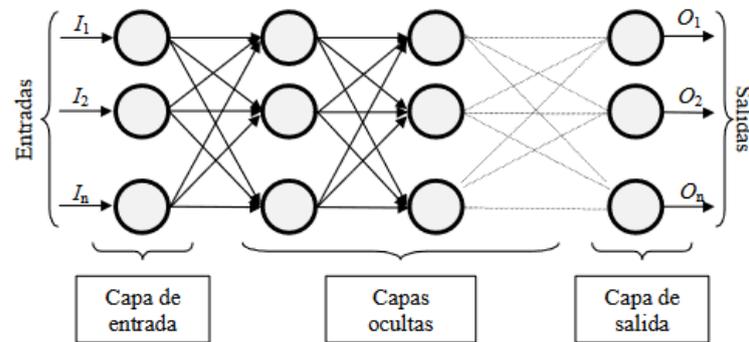


Figura 24. Red Neuronal totalmente conectada.

Fuente: (Matich Damián, 2011)

2.4.1. Arquitecturas

Debido a la existencia de múltiples escenarios por lo que una estructura y algoritmo no es definitiva para cada caso, se ha estudiado algunas estructuras y algoritmos que permitan desarrollar de una manera eficaz el proceso de entrenamiento y conseguir resultados óptimos. Además, al emplear el algoritmo más conveniente se integran las arquitecturas más comunes para crear modelos de aprendizaje profundo se mencionan a continuación:

- Redes neuronales convolucionales (CNN)

Es la arquitectura es muy usual por los beneficios de rapidez al entrenar la red, a su vez ayudan a entrenar redes profundas de muchas capas, por tal razón es uno de los primeros modelos de aprendizaje profundo, por lo general ha sido empleada para reconocimiento de objetos en imágenes.

Se debe agregar que las CNN usan tres ideas básicas: campos receptivos locales, pesos compartidos y agrupación (Neapolitan, 2018). Por lo que estas pueden aprender

características automáticamente de los datos de entrada, al eliminar la extracción manual de características. Su estructura se basa en el muestreo de una porción de la imagen, detectar sus características y a partir de ellas construir una representación (Goyal et al., 2018).

- Redes neuronales Recurrentes (RNN)

El funcionamiento de estas redes está basado en la retroalimentación entre todos los elementos que engloba la red. Una de las características fundamentales es que utiliza delays en sus salidas permitiéndoles más fácil su predicción. Además, la dificultad de este tipo de redes que son un poco complejas, porque su funcionamiento necesita de un algoritmo esencial, y a su vez pueden propagar los datos hacia delante en el tiempo consecuentemente produce eventos, especialmente se usan en aplicaciones como el reconocimiento de patrones secuenciales a causa de sus prestaciones(Oropeza, 2007). Las RNN solucionan este problema ya que pueden procesar secuencias independientemente de su tamaño e identifican la correlación que existe entre los elementos de esa secuencia(Liu et al., 2016). El concepto de una RNN es que permite preservar y compartir la información entre uno u otro instante de tiempo(Patel & Patel, 2018).

- Deep belief networks (DBN)

Este tipo de redes están conformadas por múltiples capas, para saber a la capa pertenece una neurona, se debe fijar el origen de la señal de los datos de la entrada y hacia donde se va, es decir su salida, es decir, recibir la señal por la entrada de otras neuronas conocidas como conexiones hacia adelante (Matich Damián, 2011). El entrenamiento de las DBN se puede dividir en dos fases: preentrenamiento no supervisado con muestras no etiquetadas y luego ajuste preciso supervisado con muestras etiquetadas(Patel & Patel,

2018). Las DBN son utilizadas en el área de reconocimiento de imágenes, recuperación de imágenes, comprensión de lenguajes naturales y predicción de fallas (Jones, 2017).

2.4.2. Redes Neuronales Convolucionales (CNN)

En la actualidad han ganado gran popularidad principalmente en el campo de reconocimiento de patrones en imágenes. Poseen una gran capacidad de solución de problemas de clasificación de imágenes, que aprende con un gran conjunto de bases de datos(Wu, 2017). Las CNN es una red multicapa jerárquica, esto permite extraer características en capas ocultas. Se conforman de 5 hasta 7 capas, son muy similares en su arquitectura a las redes neuronales ordinarias como el perceptrón multicapa que integra pesos y sesgos para aprender.(Raúl E. López Briega, 2012)

Las CNN reciben algunas entradas de las cuales se pueden extraer gradualmente características locales de los mapas de características de resolución alta, por lo que se puede combinar estas características con mapa de características de resolución baja, dentro de este funcionamiento se propaga hacia capas más profundas y son convenientes para aplicaciones cuyos datos tienen forma de matriz por ejemplo imágenes que evitan procedimientos adicionales (Cong & Xiao, 2014). Las CNN procesan imágenes por secciones con lo que se reduce la cantidad de parámetros requeridos en comparación con el procesamiento de una red neuronal artificial convencional es por ello que son utilizadas en aplicaciones de visión artificial(Vizcaya, 2018).

2.4.2.1. Capas de Convolución

Las CNN son arquitecturas con múltiples etapas de entrenamiento. Dentro de la estructura de las estas redes existen dos tipos de capas, las primeras cumplen la función de extracción de las características y las segundas están inmersas en el proceso de clasificación (A. B. S. García, 2018). La entrada y salida de cada etapa son grupos de matrices denominados mapas de características, los cuales representan una característica particular extraída en todas las ubicaciones de la entrada(imagen)(Lecun et al., 2010). Cada capa realiza la convolución del volumen de la entrada con una serie de filtros definidas como hiperparámetros de convolución. El funcionamiento de estos filtros actúa en el momento cuando se recorre a la imagen y se tiene un resultado con un valor específico, el cual reduce el tamaño de la imagen real llamados mapas de características de acuerdo con el número de filtros aplicados (A. B. S. García, 2018). Los hiperparámetros que integran el proceso de convolución son:

- Número de filtros (k): se define a una característica en concreto, debido a esto se aplican varios filtros para conseguir algunas características del objetivo.
- Tamaño del filtro (F): Depende del criterio del desarrollador esto se debe a las características del filtro y la velocidad de procesamiento.
- Stride (S): es usado para el tamaño del desplazamiento o recorrido de los filtros de las capas por los píxeles integrados en las imágenes.

La estructura de una red neuronal convolucional se visualiza en la figura 25:

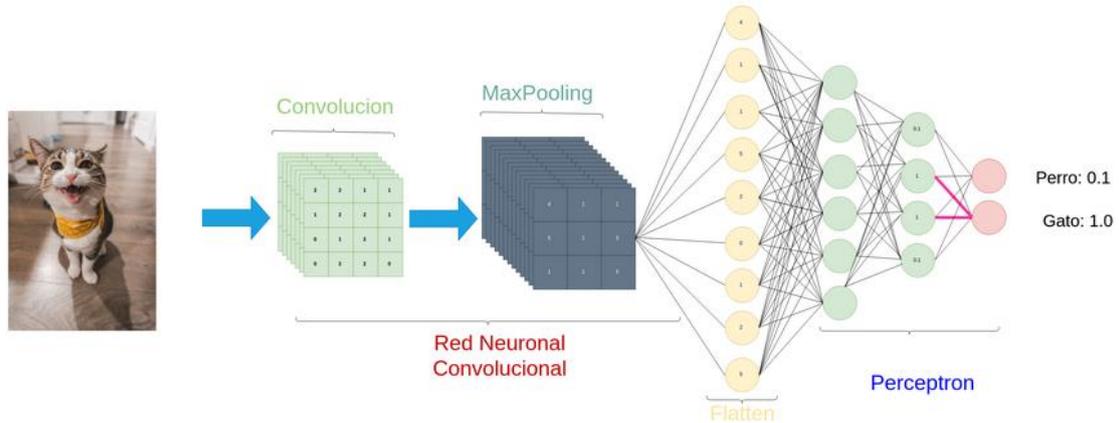


Figura 25. Estructura de una red neuronal convolucional.

Fuente: (Raúl E. López Briega, 2012)

2.4.2.1.1. Capa de entrada

En las capas de entrada es donde se ingresan y almacena los datos de la imagen en su estado original para procesarlos en la red. Estos datos de entrada especifican el ancho, alto y el número de canales que suelen ser tres, para los valores RGB de cada pixel (Patterson & Gibson, 2017).

2.4.2.1.2. Capa Convolucional

Esta capa tiene como finalidad la extracción de características de una imagen. Para ello realiza multiplicaciones elemento por elemento (producto punto) entre una submatriz de una matriz de entrada y un filtro (llamado también kernel o campo receptivo) cuyo tamaño es el mismo que el de la submatriz y siempre es más pequeño que el de la matriz de entrada. Luego se suman los valores obtenidos y el resultado es un mapa de características como salida (Cha et al., 2017). El kernel filtra datos de entrada para ciertos tipos de información y permite extraer la misma característica en cualquier parte de la entrada (Acuña, 2019); por

ejemplo un kernel de borde solo dejara pasar información del borde de una imagen(Patterson & Gibson, 2017), en relación a la operación de convolución se muestra en la figura 26:

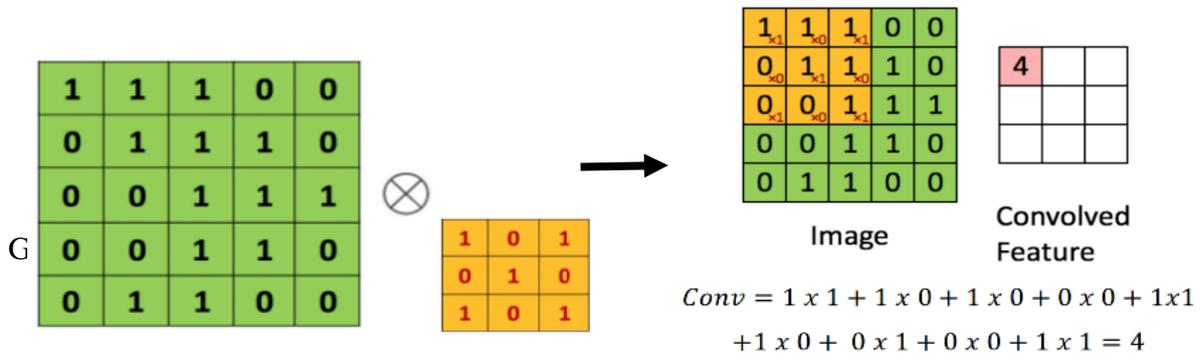


Figura 26. Operación de Convolución

Fuente: (Cicero, 2018)

2.4.2.1.3. Función de activación

Al finalizar la operación de convolución se obtiene como salida una función lineal. Si se quiere encadenar varias capas de neuronas cuyas salidas son funciones lineales, esto provoca que la red colapse hasta ser equivalente a tener únicamente una neurona, lo que impide que se pueda trabajar en una red multicapa. Para solucionar este problema y crear una estructura de red neuronal compleja se usan las funciones de activación para introducir la no linealidad a la ConvNet ya que la mayor parte de la información del mundo real, que se estima que la red aprenda, es de característica no lineal. (Enyinna et al., 2018) La función de activación típicamente usada en las CNN es la ReLU (Unidad de Rectificador Linear) y es igual a $f(x) = \max(0, x)$. Esta función reemplaza los valores negativos de entrada por cero, en efecto elimina la relación proporcional entre la entrada y la salida (Merchan et al., 2018) y reducir el número de activaciones producido por las salidas a 0 lo cual introduce velocidad y mejora la convergencia de la red debido a que solo las características activadas se transmitirán a la siguiente capa (Canziani et al., 2016). ReLU a diferencia de otras funciones de activación reduce el desvanecimiento de gradiente, el cual afecta al

entrenamiento de la red, pues los pesos se modifican de manera insignificante, lo cual hace que la red deje de aprender en las primeras capas de esta manera afecta al resto de la red. (Yang et al., 2018)

2.4.2.1.4. Capa de Pooling

Además de las capas convolucionales que se describieron anteriormente, está la capa de agrupación o pooling, la cual se encarga de simplificar la información en la salida de la capa convolucional, es decir reduce las dimensiones de los mapas de características con el fin de preservar únicamente las características más relevantes, reducir parámetros y por ende coste computacional (Nilsen, 2018), como muestra la figura 27. Cabe recalcar que en esta capa no existen parámetros que actualizar ya que su única función es la reducción de dimensiones. Los tipos más comunes de técnicas de agrupación son el max pooling y el average pooling. El max pooling es la forma común de operación de agrupación, que extrae submatrices de los mapas de características de entrada, genera el valor máximo en cada submatriz y descarta todos los demás valores. El average pooling calcula el valor promedio de cada submatriz del mapa de características (Wang & Yang, 2019).

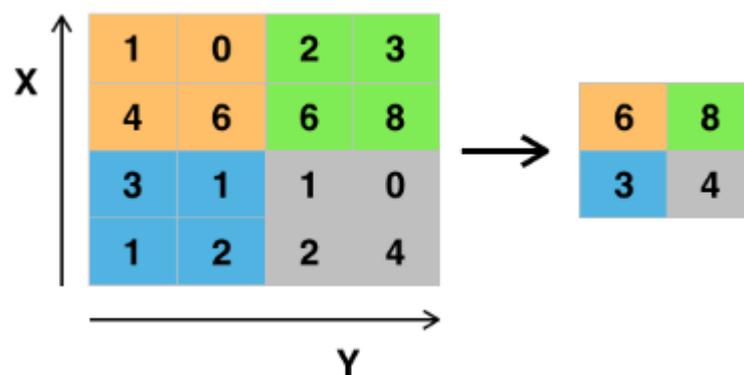


Figura 27. Ejemplo del funcionamiento de la capa de pool

Fuente: (Cicero, 2018)

La capa de pooling asegura que la red neuronal tenga una propiedad denominada invariancia espacial, lo cual quiere decir que a pesar de que exista distorsión, cambio de textura, iluminación, posición o rotación del objeto a detectar, la red neuronal deberá ser capaz de extraer las características dominantes de este independientemente de las transformaciones mencionada (Yamashita et al., 2018). Esto es esencial ya que los objetos son detectados sin importar su posición u orientación en la imagen.

2.4.2.1.5. Capa directamente conectada

Luego de una serie de capas convolucionales y de pooling, se extraen las características de más alto nivel las cuales se alimentan a las capas directamente conectadas, con el fin de realizar la tarea de clasificación según el conjunto de datos de entrenamiento. El número de nodos de salida de la capa directamente conectada es generalmente el mismo que el número de clases. Se utiliza la función softmax para la tarea de clasificación multiclase, esta función normaliza los valores de la salida de la última capa completamente conectada, a las probabilidades de cada clase objetivo, donde cada valor se encuentra entre 0 y 1 y la suma de estos valores es 1 (Yamashita et al., 2018).

Para que todas las capas funcionen en conjunto, se debe proceder al entrenamiento, que se resume en los siguientes pasos: Se asignan valores aleatorios a los parámetros o pesos de la red. Seguido de esto se utiliza un dataset de imágenes de entrenamiento para ingresarlas en el modelo. Se calcula el margen de error (loss function) de las probabilidades que se obtienen del modelo, luego se compara la salida computada con la salida deseada y finalmente se utiliza el método de propagación hacia atrás para calcular el error de gradiente de todos los pesos en la red y utilizar descenso de gradiente para modificar iterativamente estos valores y minimizar el error de salida (Merchan et al., 2018).

3. CAPÍTULO III. METODOLOGÍA

Desarrollo Experimental

El capítulo de desarrollo experimental presenta el análisis de la situación actual al incluir la tabulación de resultados de las encuestas aplicadas al dueño y trabajadores en campos agrícolas en la ubicación del anexo 4 y explica cómo estas ayudaron a resolver las preguntas planteadas para diseñar un sistema de visión artificial mediante una plataforma mediante un drone para identificar la enfermedad (*Phytophthora infestans*). A continuación, se realiza una descripción del sistema donde se señala sus beneficiarios y posibles limitaciones, también se presenta el análisis de requerimientos de *stakeholders*, arquitectura y de funciones.

3.1. Análisis de la Situación Actual

Mediante el análisis de la situación actual que busca recopilar información para responder las preguntas referentes al diseño del sistema y de esta manera sustentar el desarrollo del proyecto, la información se obtuvo de los beneficiarios directos que serían el dueño y trabajadores en el campo agrícola para determinar los requerimientos de usuario mediante encuestas. Sin embargo, el comportamiento de nuestra enfermedad a investigar como expresan los autores Martínez-Ruiz et al., (2016): "esta enfermedad tiene la capacidad de matar las plantas de tomate en dos semanas, incluso en una, cuando las condiciones climáticas son propicias en cualquier momento durante la estación de crecimiento de las plantas no se aplica ningún método de control", de esta manera es indispensable generar un monitoreo continuo para identificar la enfermedad *phytophthora infestans*, además, el autor (Silva, 2019) denota que el control fitosanitario debe realizarse entre 7 a 15 días en referencia con la incidencia de la plaga o enfermedad, del mismo modo, es importante recalcar que este

método integral permite que las enfermedades y plagas que existen en el ambiente no se desarrollen y así obtener mayor producción. A continuación, en la tabla 10 se explicará más a detalle esta información.

Tabla 10. Método y formato para levantamiento de información de la situación actual

SITUACIÓN ACTUAL	
Método:	Para el desarrollo del proyecto se propone un método de investigación descriptiva para la recolección de la información mediante una encuesta. Se ha seleccionado este método para conocer las ideas, y datos fundamentales acerca del diseño del sistema de visión artificial para identificar la plaga (<i>Phytophthora infestans</i>).
Formato:	La encuesta según su objetivo es de tipo analítica, como resultado es llegar a conocer las razones reales del desarrollo del cultivo e implementar el sistema de visión artificial. El tipo de preguntas fueron respuestas cerradas. Las preguntas de respuesta cerrada permiten mediante indicadores obtener la cuantificación y tabulación de resultados, estas fueron referidas al período para fumigar el cultivo, el estado de la hoja durante cada etapa, que etapa es la idónea para el contagio de la plaga, las medidas de precaución en el vuelo con respecto al tamaño de la planta y el tutoreo, por lo tanto se vuela a una altura prudencial donde la exista menos viento en el día; también tenemos preguntas para mostrar la información en una plataforma web tanto como seguridad, visualización y adquisición de resultados finales; por el cual se elige este tipo de preguntas para que el encuestado tenga la libertad de acuerdo con lo que pasa al diario. El formato de la encuesta aplicada se muestra en el anexo 2 de este trabajo.

Nota. Fuente: Levantamiento de información de encuestas.

3.1.1. Análisis de los resultados.

Una vez aplicada la encuesta a 4 trabajadores del campo agrícola de las cuales 3 son hombres y 1 mujer, se obtuvo resultados que permiten el desarrollo de este proyecto a continuación se indican las conclusiones derivadas de la tabulación de las encuestas como se establece en el anexo 3.

Las preguntas realizadas permiten adquirir los requerimientos del usuario para implementar en el sistema, de este modo, generar un plan estratégico con respecto a las necesidades del propietario. En relación con el período de fumigación se considera que debe ser cada 7 días por lo antes expuesto en los artículos. Por otro lado, se considera el estado de la hoja, que lleva una gran relación con el objetivo de nuestro proyecto, es decir, la etapa 1 (1-4 semanas) se muestra saludable en su mayoría, pero existe presencia de hojas enfermas, luego en la etapa 2 (5-8 semanas) se identifica hojas saludables, enfermas y potencialmente enfermas. También en la etapa 3 (9-12 semanas) ya existe la presencia de hojas marchitas, en este contexto, se registra en estados saludables, enfermos, potencialmente enfermas y marchitas. Posterior a la etapa 4 (13-16 semanas) empieza a encontrarse las hojas en su mayoría potencialmente enfermas y marchitas.

Particularmente el desarrollo de la enfermedad (*phytophthora infestans*) es más susceptible en la etapa 3 (9-12 semanas). En relación con el vuelo autónomo del dron se realiza de una manera automática, es decir, que no debe existir obstáculos en la ruta por lo tanto es indispensable que se tome medidas de precaución para no ocasionar daños en el desarrollo de la planta y tutoreo instalado, de esta forma se vuela a una altura prudencial de 2 a 3 metros.

En efecto, se considera las condiciones edafoclimáticas que hace referencia al viento por la estabilidad del drone, por tal razón la hora idónea para volar es a las 6 de la mañana en el cultivo sin limitaciones que resulta imágenes con mayores prestaciones de enfoque.

Finalmente, la manera en la que el usuario desea que se muestre la información de una manera organizada y clara en gráficos para obtener los resultados, en primera instancia, la seguridad cumple un rol importante para observar los datos, luego, la manera de generar un reporte o documento, de este modo se registra la información para identificar la plaga en una página web mediante colores en relación con zonas de interés. Respecto a esta necesidad se requiere alertar sobre posibles plagas para tomar medidas de prevención correctas a la necesidad.

3.2.Introducción al desarrollo del proyecto

El procesamiento de las imágenes se ha posicionado como una de las técnicas más remuneradas en relación con aplicaciones agrícolas para la identificación de enfermedades de manera efectiva, y así conseguir un resultado significativo en los factores de producción para un beneficio económico.

3.2.1. Propósito del sistema

La propuesta a desarrollar es detectar la enfermedad (*Phytophthora infestans*) en campos agrícolas, con la ayuda de un esquema de visión artificial que contribuya con el mejoramiento de las capacidades de un agricultor para realizar medidas preventivas en cultivos de tomate riñón. Esta información converge con una plataforma web para determinar la existencia de dicha enfermedad en los cultivos.

3.2.2. Ámbito del Sistema

El sistema de visión artificial puede identificar la enfermedad (*Phytophthora infestans*) en los campos agrícolas con un esquema de adquisición y procesamiento de imágenes a escala de laboratorio, lo que indica que sus pruebas servirán para futuras implementaciones dentro de las industrias o al integrar en invernaderos.

Cabe destacar que el sistema plantea ser de bajo costo, y con ello contribuir al ahorro económico del agricultor; bajo este concepto se mejorará la productividad del cultivo, gracias a la identificación de irregularidades y a la rápida intervención por parte del agricultor.

3.2.3. Características de los beneficiarios

Se consideran como beneficiarios al propietario y trabajadores, el sistema será desarrollado para cumplir su funcionamiento en el campo agrícola. El sistema propuesto cuenta con características amigables para el usuario, en este caso el agricultor podrá visualizar los resultados del sistema de una forma clara y entendible, debido a que se utiliza una plataforma web, en la cual el agricultor podrá ingresar un usuario y contraseña, y con ello acceder a la información de su cultivo.

Se espera que el usuario pueda interpretar esta información mediante la utilización de gráficas y tablas para que con ello realice una pronta respuesta para eliminar la enfermedad “*phytophthora infestans*” en el cultivo de tomate riñón.

3.3.Requerimientos del proyecto

Mediante el análisis de nuestro proyecto y la información adquirida para el prototipo se puede determinar los elementos necesarios y que cumplan con las necesidades presentadas.

Ponemos a una evaluación los requerimientos de usuario, requerimientos de sistema y requerimiento de arquitectura.

3.3.1. Construcción de Atributos de los requerimientos

La construcción de atributos se elabora en base a tres requerimientos que son: *stakeholders*, sistema y arquitectura; y cada requerimiento debe cumplir para ser verificable, de esta manera efectúe, mida y límite el objetivo del proyecto.

3.3.1.1. Nomenclatura de los Requerimientos para usarse

Cada uno de los requerimientos se llevan a cabo, es necesario identificarlos mediante una abreviatura que permita un mejor manejo de los datos. En la tabla 11 nos muestra las abreviaturas utilizadas.

Tabla 11. Abreviatura de los requerimientos

Requerimiento	Abreviatura
<i>Stakeholders</i>	StSR
Sistema	SySR
Arquitectura	SRSR

Fuente: Autoría.

3.3.2. Requerimientos de *Stakeholders*

La finalidad por la que se usa estos requerimientos es definir los requisitos del sistema en base a las necesidades del usuario en campos agrícolas. Para poder cumplir con las expectativas del propietario y los trabajadores, se debe garantizar el vínculo entre lo que esperan los clientes. En la tabla 12 se evaluarán los requerimientos operacionales y de usuarios.

Tabla 12.Requerimientos de *Stakeholders*

#	REQUERIMIENTO	StSR			RELACIÓN
		PRIORIDAD			
		Alta	Media	Baja	
REQUERIMIENTOS OPERACIONALES					
StRS1	El sistema debe tener la capacidad de funcionamiento durante 1 hora cada semana.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
StRS2	El dron debe tener una cámara de una resolución adecuada para la detección de diferentes tonalidades de color de las hojas en el cultivo.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
StRS3	El dron al tomar las muestras en el cultivo debe conseguir una adecuada estabilidad con relación al viento, para obtener imágenes claras.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
StRS4	La adquisición de los datos se debe obtener en un período de 7 días para prevenir las plagas en el cultivo.	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	

StRS5	El dron debe tener un vuelo a una altura prudencial de acuerdo con el crecimiento del cultivo para que su cámara pueda detectar los colores de la hoja del tomate riñón.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
--------------	--	-------------------------------------	--------------------------	--------------------------

REQUERIMIENTOS DE USUARIOS

StRS6	El acceso a la información de la página web, es mediante autenticación por seguridad y validar la información del usuario.	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
--------------	--	--------------------------	-------------------------------------	--------------------------

StRS7	La plataforma web deberá contener tablas y resultados estadísticos con precisión de la identificación de la plaga que genera una alerta al agricultor.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
--------------	--	-------------------------------------	--------------------------	--------------------------

StSR8	Los resultados y alertas se muestran mediante un reporte o documento dentro de la plataforma web.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
--------------	---	-------------------------------------	--------------------------	--------------------------

Nota. Se describen los requerimientos operacionales y requerimientos de usuario con el grado de prioridad alta, media, baja. **Fuente:** Encuestas en el terreno de estudio.

Los requerimientos planteados han sido obtenidos mediante una encuesta realizada al usuario en este caso al propietario del campo agrícola y trabajadores, además, se considera la experticia para la realización de este tipo de proyectos. De tal forma se consigue una relación entre el usuario y el sistema, que brinda una idea general del producto final al entorno operativo.

3.3.3. Requerimientos del Sistema

Los requerimientos se los realiza de acuerdo con las funciones y limitaciones que va a desempeñar el sistema de discretización de imágenes. Entre estos se va a analizar requerimientos de uso, performance, interfaces, estados y físicos que tengan coherencia con los requerimientos de *Stakeholders*. La tabla 13 contiene la información de los requerimientos de sistema. Este campo señala la funcionalidad del sistema en base a la aplicación de acuerdo con la prioridad del requerimiento, estos tienen relación con los requerimientos de *Stakeholders*.

Tabla 13. Requerimientos del Sistema

SySR						
#	REQUERIMIENTO	PRIORIDAD			RELACIÓN	
		ALTA	MEDIA	BAJA		
REQUERIMIENTOS DE INTERFAZ						
SySR 1	Conectividad tecnología comunicación inalámbrica.	a	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
		de				
SySR2	Tarjeta 64Gb.	MicroSD	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
		de				

SySR 3	La interfaz de procesamiento de imágenes debe captar las diferentes tonalidades de color de la hoja del cultivo para la posible detección de plagas.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
---------------	--	-------------------------------------	--------------------------	--------------------------

SySR 4	La base de datos en la nube debe recopilar y almacenar los datos en un formato adecuado para generar un reporte en la página web.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
---------------	---	-------------------------------------	--------------------------	--------------------------

REQUERIMIENTOS DE USO

SySR5	Debe tener flexibilidad al volar el dron desde el inicio hasta el final, en los campos agrícolas.	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
--------------	---	--------------------------	-------------------------------------	--------------------------

SySR6	Los datos deben ser obtenidos rápidamente.	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
--------------	--	--------------------------	-------------------------------------	--------------------------

SySR7	El proceso debe rendir a largo plazo y no saturarse.	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
--------------	--	--------------------------	-------------------------------------	--------------------------

REQUERIMIENTOS DE PERFORMANCE

SySR 8	El dron debe tener un punto de inicio de fácil acceso.	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
---------------	--	--------------------------	-------------------------------------	--------------------------

SySR 9	El drone deberá realizar un sobre vuelo sobre el área del campo agrícola sin interferir con el crecimiento del cultivo.	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
SySR 10	La plataforma web no debe saturarse y debe tener un funcionamiento continuo de al menos 3 horas diarias.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
SySR 11	Se debe asegurar que todos los datos recolectados por el drone lleguen a la base datos mediante la página web.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
SySR 12	Visualización grafica de los datos en la página web.	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
REQUERIMIENTOS DE MODO Y ESTADO				
SySR 13	La plataforma web indica mediante una alerta al usuario cuando exista la detección de plaga en el cultivo.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
REQUERIMIENTOS FÍSICOS				
SySR 14	El drone necesita zonas de espacio aéreo despejadas para evitar obstáculos en su trayectoria.	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>

SySR 15	El dron debe volar en condiciones ambientales idóneas al no ser susceptible al agua.	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
SySR 16	El sistema debe tener una SD card con suficiente espacio para no saturarse.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

Nota. Se describen los requerimientos de interfaz, uso, performance, de estado y físicos con el grado de prioridad alta, media, baja. **Fuente:** Requerimientos del proyecto.

3.3.4. Requerimientos De Arquitectura

Los requerimientos de arquitectura hacen referencia a los componentes de hardware y software, sus características son en base al funcionamiento que tendrá el sistema. Para ello se toma los requerimientos lógicos, diseño, hardware, software y eléctricos. A continuación, en la tabla 14 se describe los requerimientos de arquitectura.

Tabla 14. Requerimientos de Arquitectura

SRSR					
#	REQUERIMIENTO	PRIORIDAD			RELACIÓN
		ALTA	MEDIA	BAJA	
REQUERIMIENTOS DE DISEÑO					
SRSR 1	El sistema debe tener una plataforma compatible con el dron para el sobrevuelo.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
SRSR 2	Comunicación con la plataforma de procesamiento de imágenes, base de datos y la plataforma web.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	

SRSH 3	Los datos de telemetría y video del vuelo del drone deben ser cargados a la plataforma web de forma manual.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
---------------	---	-------------------------------------	--------------------------	--------------------------

SRSH 4	El sistema debe ser accesible para los administradores.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
---------------	---	-------------------------------------	--------------------------	--------------------------

REQUERIMIENTOS LÓGICOS

SRSH 5	Aplicación para conectar el móvil con el drone.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
---------------	---	-------------------------------------	--------------------------	--------------------------

SRSH 6	Acceso de la base de datos con la plataforma web.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
---------------	---	-------------------------------------	--------------------------	--------------------------

SRSH 7	Acceso de la base de datos con la plataforma en la nube.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
---------------	--	-------------------------------------	--------------------------	--------------------------

REQUERIMIENTOS DE HARDWARE

SRSH 8	El drone deberá tener una cámara de al menos 5Mpx y una aplicación móvil.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
---------------	---	-------------------------------------	--------------------------	--------------------------

SRSH 9	El drone debe tener sistema de GPS para el mapeo del drone.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
---------------	---	-------------------------------------	--------------------------	--------------------------

REQUERIMIENTOS DE SOFTWARE

SRSH 10	Sistema operativo que sea Open Source	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
----------------	---------------------------------------	--------------------------	-------------------------------------	--------------------------

SRSH 11	Plataforma de programación html debe ser Open Source.	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
SRSH 12	Plataforma de procesamiento de imágenes digitales que sea Open Source.	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
SRSH 13	La base de datos debe ser Open Source.	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
SRSH 14	La plataforma de almacenamiento de datos (Cloud) debe ser Open Source.	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
REQUERIMIENTOS ELÉCTRICOS				
SRSH 15	Se necesita una batería recargable de 5V y 3A para el sistema de drone.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

Nota. Se describen los requerimientos de diseño, lógicos, hardware, software y eléctricos con el grado de prioridad alta, media, baja. **Fuente:** Requerimientos del proyecto.

Los requerimientos analizados generan una estrecha relación con las necesidades establecidas por los usuarios y con las del sistema; por tanto, se puede establecer un sistema robusto de hardware por el drone con las mejores prestaciones y software libre para el uso de lenguajes de programación, librerías y protocolos.

3.4. Recursos

Es importante considerar que en la elaboración del proyecto se deben integrar recursos que son fundamentales para alcanzar los objetivos planteados. Dichos recursos se plantean en la siguiente sección:

3.4.1. Recursos económicos

Permite evaluar un costo aproximado del prototipo final, los gastos que se generan para el diseño de este proyecto y los recursos administrativos para la presentación del proyecto los cuales se muestran en la tabla 15 que se presenta a continuación.

Tabla 15. Recursos Económicos

RECURSOS ECONÓMICOS				
#	MATERIAL	COSTO U.	# DE ELEMENTO	COSTO T.
1	Drone	\$1200	1	\$1200
3	Resma Hojas	\$5	1	\$5
4	Empastado	\$35	1	\$35
			TOTAL	\$1240

Nota. Se describen los recursos económicos que participan en el proyecto. **Fuente:** Desarrollo del proyecto.

3.4.2. Recursos tecnológicos

En esta parte se define el software posible a utilizar para el desarrollo del prototipo, los cuales son detallados en la tabla 16.

Tabla 16. Recursos Tecnológicos

RECURSOS TECNOLÓGICOS	
SOFTWARE	COSTO
Dji gs pro	\$0
Python	\$0
Total, Costo	\$0

Nota. Se describen los recursos tecnológicos que participan en el proyecto. **Fuente:** Desarrollo del proyecto.

3.5. Elección de hardware y software

Para elegir un correcto hardware y software, se relaciona algunas metodologías que permiten seleccionar de una manera técnica los elementos ideales, por consiguiente en la elección del hardware utilizaremos un benchmark al hacer uso de las hojas de datos (datasheets) de cada elemento y para la elección del software se integra los requerimientos de los *stakeholders*, sistema y arquitectura, donde se realiza un análisis comparativo para poder evaluar cada uno, en efecto, conseguir la opción viable al implementar en el proyecto.

3.5.1. Elección de Hardware

Para realizar el benchmark, en primer lugar, se debe establecer algunos indicadores a evaluar, los cuales fueron seleccionados en la sección 1.1.6.1. del capítulo 2, que están enfocados en aplicaciones de agricultura y monitoreo, estos tipos de drones fueron elegidos que se basan en la disponibilidad y precio de estos en el mercado ecuatoriano, además, que presenten compatibilidad con la aplicación para realizar un vuelo autónomo.

3.5.1.1. Selección del Drone

Para la elección del drone se enfocará en el objetivo del proyecto, por lo tanto, al realizar un estudio de mercado en Ecuador, se encontró disponibilidad de la familia DJI, Parrot y Yamaha, se caracterizan por su estabilidad de vuelo, en efecto, han sido seleccionados para el desarrollo del benchmark algunos de los criterios de evaluación como son: estabilidad, compatibilidad con la plataforma, resolución de cámara, GPS y energía, que se muestran en el tabla 17, de tal forma, se adquiere el drone para cumplir con la funcionalidad de mapeo del campo agrícola y conseguir imágenes con mayores prestaciones.

Tabla 17. Análisis comparativo de selección del drone.

DRONE	DJI MAVIC 2 ZOOM	PARROT EBEE SQ	DJI AGRAS MG-1	YAMAHA RMAX
PARÁMETROS	DESCRIPCIÓN			
Fiabilidad.	Alta	Alta	Alta	Alta
Estabilidad	Vibración Angular $\pm 0.005^\circ$	Hasta 3 cm (1,2 in)/5 cm (2 in)	Sistema RTK de precision.	3.630 mini-rotors
GPS	Si	Si	Si	Si
Cámara	12Mpx	16Mpx	FPV	N/A
Sensor	1/2.3" CMOS,	GSD 12cm/pix multiespectral: (4,72 pulg/pix)	CCD 1/3".	N/A
Batería	3950 mAh	5000 mAh	12000 mAh	N/A
Tiempo de vuelo	31 minutos	55 minutos	22 minutos	60 minutos
Precio	\$1200,00	\$12000,00	\$5000,00	\$85000,00
Disponibilidad	Quito	Quito	Quito	E.E.U.U.

Nota. Selección del drone mediante benchmark **Fuente:** (Sensefly, 2019)(DJI, 2016)(DJI, 2018)

En relación con los indicadores a evaluar como son la estabilidad, compatibilidad con la plataforma, resolución de la cámara, GPS y energía; la selección del drone se ha considerado su precio en el mercado Ecuatoriano y sus prestaciones de la cámara, en efecto, los drones Parrot ebee sq, DJI agras mg-1, y Yamaha rmax son costosos por lo tanto excluidos para ser seleccionados, de esta forma el drone DJI 2 Zoom con estabilidad del vuelo, GPS, su tiempo de vuelo, y la más importante es su cámara de 12 Mpx y la duración de la batería de 31 minutos permiten vincularse con el objetivo del proyecto.

3.5.2. Elección del Software

El software seleccionado depende de los atributos que se evalúan en la tabla 13 y 14 tanto de los requerimientos de sistema y arquitectura para elegir el adecuado en este proyecto. A continuación, se presenta un análisis de elección del software para las diferentes etapas del proyecto como son: plataforma de vuelo autónomo, tecnología de comunicación inalámbrica, framework, base de datos y la plataforma web.

El formato de la tabla 18 presentada a continuación indica en la primera columna las opciones de software existentes en el mercado, la siguiente columna contiene los requerimientos que deben ser analizados y se indica con la abreviatura correspondiente a que tabla anterior hace referencia, y finalmente tenemos la columna de valoración total donde se muestra el puntaje obtenido por cada una de las opciones de software; los datos se han definido de la siguiente manera: se califica con un valor de 1 si cumple el requerimiento y un valor de 0 si no cumple el requerimiento indicado. En la parte inferior existe una sección en la que se explica la selección ejecutada y su respectiva justificación.

3.5.2.1. Plataforma de vuelo autónomo.

Para la elección de la mejor aplicación se considera el requerimiento SRS5 por la compatibilidad del drone con el móvil, además, se examina el requerimiento SRS1, este permite realizar el sobrevuelo y conseguir las muestras de acuerdo con algunas ventajas para realizar un vuelo autónomo. También se integra el requerimiento SRS9 con respecto al GPS para mapear con el drone y el requerimiento SRS10 si es Open Source cada uno de estos se muestran en la tabla 18.

Tabla 18. Elección de la plataforma de vuelo autónomo

PLATAFORMA DE VUELO AUTÓNOMO						
TIPO	REQUERIMIENTO					VALORACIÓN
	SRSH1	SRSH4	SRSH8	SRSH9	SySR1	
DJI gs pro	1	1	1	1	1	5
Flight Plan	1	1	1	0	1	4
Pix4D	1	1	0	1	1	4

Cumple “1” No cumple “0”

Elección: La plataforma DJI GS PRO es la adecuada por su compatibilidad con el dron, y es Open Source, además, su funcionalidad en generar un registro de la posición como gran ventaja sobre las otras aplicaciones, al conocer la ubicación para realizar el mapeo con el dron, y de esta manera seguir la trayectoria total de volar por el cultivo. Este software además de cumplir con los requerimientos analizados permite grabar en tiempo real y tomar fotos en los tiempos acordes según se establezca los parámetros de los waypoints estratégicos, los cuales están definidos en relación con la altura, velocidad, solape frontal, lateral y el número de puntos, además una consideración importante es realizar la forma de la trayectoria del vuelo.

Nota. Se realiza la elección de la plataforma de vuelo autónomo. **Fuente:** Desarrollo del proyecto.

3.5.2.2. Tecnología de transmisión inalámbrica

Para la elección de la tecnología de transmisión inalámbrica se considera el requerimiento SySR1 por la conectividad a la tecnología de comunicación inalámbrica, SySR11 enfocado en asegurar que todos los datos recolectados por el dron lleguen a la base de datos, además, se examina el requerimiento SRSH 2, este permite establecer la comunicación con la plataforma de procesamiento de imágenes y la plataforma web, también se integra el requerimiento SRSH5 con relación con la conectividad de la base de datos con la plataforma web, cada uno de estos se muestran en la tabla 19.

Tabla 19. Elección de la tecnología de transmisión inalámbrica

TECNOLOGÍA DE TRANSMISIÓN INALÁMBRICA					
TIPO	REQUERIMIENTO				VALORACIÓN
	SySR1	SySR11	SRS2	SRS5	
Wi-Fi	1	1	1	1	4
WiMAX	1	0	1	1	3
GPRS	1	0	1	1	3
Cumple "1" No cumple "0"					

Elección: La tecnología de transmisión inalámbrica wi-fi es la adecuada por su versatilidad de establecer un nodo de comunicación de modalidad hotspot para establecer como punto de acceso la comunicación entre las diferentes plataformas, donde su conectividad es estable para la transmisión de datos, en efecto va de la mano asegurar que los datos lleguen sin existir pérdidas de paquetes, además es esencial que su funcionalidad este de transmisor-receptor. Este software además de cumplir con los requerimientos analizados tiene altas prestaciones con demandas de tráfico lo que produce los paquetes rtmp, además, tienen una cobertura entre 30 a 300 metros de acuerdo con la antena del fabricante. Sin embargo, en cuestión a la seguridad es de fácil acceso por el medio de propagación es por ondas.

Nota. Se realiza la elección de la tecnología de transmisión inalámbrica. **Fuente:** Desarrollo del proyecto.

3.5.2.3. Framework

La plataforma de procesamiento de imágenes digitales tendrá el objetivo de interactuar con las muestras obtenidas a través de un preprocesamiento para identificar las características, de este modo se consigue resultados de la precisión con las diferentes interacciones. Por lo tanto, se ha determinado el requerimiento SySR3 este debe captar las diferentes tonalidades de color de la hoja; con relación al SySR7 el proceso tiene que mantenerse a largo plazo y no saturarse, además, el SRS2 se muestra con la comunicación del framework con la plataforma web y debe ser Open Source como especifica el SRS13; todos estos requerimientos se los detalla en la tabla 20.

Tabla 20. Elección del Framework

FRAMEWORK					
TIPO	REQUERIMIENTO				VALORACIÓN
	SySR3	SySR7	SRSH 2	SRSH11	
Caffe	1	0	1	1	3
Tensorflow	1	0	1	1	3
OpenCV	1	1	1	1	4
Cumple "1" No cumple "0"					

Elección: Para la elección del framework se ha seleccionado Open CV, por su alto nivel en la precisión de identificar los colores, también es escalable para tiempos largos y mantiene una comunicación con el servidor web, de esta manera es un modelo de programación con mayor legibilidad y minimiza líneas de código, tiene una documentación robusta y admite redes convolucionales. Por otro lado, dentro de su funcionalidad es multiplataforma, se puede ejecutar en diferentes sistemas operativos, en ese sentido está orientado a trabajar con varias capas, para tener mejores respuestas al aumentar el tiempo de entrenamiento con la función de activación Leaky ReLU.

Nota. Se realiza la elección del framework. **Fuente:** Desarrollo del proyecto.

3.5.2.4. Plataforma de almacenamiento en la nube

La plataforma de almacenamiento en la nube es importante por su administración eficiente de relaciones y datos, en relación con su infraestructura permite tener un espacio de almacenamiento y guardar la información en un entorno virtual y conseguir el sistema accesible para los usuarios en cualquier dispositivo electrónico conectado a la red. En ese contexto, para la elección de la plataforma se determina el requerimiento SySR11 visualización gráfica de los datos almacenados en la nube, SRSH6 por la conectividad del computador a la plataforma de almacenamiento en la nube, SRSH7 el acceso del Cloud al servidor web y el SRSH12 donde la plataforma de almacenamiento de datos debe ser Open Source, los cuales están en la tabla 21 detallada a continuación.

Tabla 21. Elección de la plataforma de almacenamiento en la nube.

PLATAFORMA DE ALMACENAMIENTO EN LA NUBE					
TIPO	REQUERIMIENTO				VALORACIÓN
	SySR5	SySR6	SRSH 12	SySR12	
Pydio	1	1	0	1	3
AWS EC2	1	1	1	1	4
Sandstorm	1	0	1	1	3
Cumple "1" No cumple "0"					

Elección: La plataforma de almacenamiento en la nube AWS Amazon es seleccionada por sus prestaciones de integrar varios servicios, en ese sentido, es compatible con API estándares del sector con lenguajes de programación Python, C++; además, incorpora una capa gratuita que permite trabajar con un rango de capacidad en todas sus aplicaciones, sin embargo, integra algunos servicios que permite tener una dinámica propia para el proyecto en conjunto con la base de datos y servicios externos y ser mostrados en consultas que se faculta al gestionar el servidor web con las peticiones que se generan desde la plataforma de código abierto.

Nota. Se realiza la elección de la plataforma de almacenamiento en la nube. **Fuente:** Desarrollo del proyecto.

3.5.2.5. Base de datos

La base de datos almacena y posteriormente accede a los datos de forma rápida y estructurada. Los datos se recopilan y se organizan para su ejecución. De este modo en la tabla 22 se seleccionan algunos requerimientos como SySR4 donde debe recopilar y almacenar los datos para generar un reporte, SySR11 estos datos del dron deben llegar a la base de datos, además, el SRSH6 para la conectividad de la base de datos con la plataforma de almacenamiento en la nube y respectivamente el SRSH12 debe ser Open Source.

Tabla 22. Elección de Base de datos

BASE DE DATOS					
TIPO	REQUERIMIENTO				VALORACIÓN
	SySR4	SySR11	SRSH 6	SRSH12	
MySQL	1	1	0	1	3
Amazon RDS	1	1	1	1	4
PostgreSQL	1	0	1	1	3

Cumple “1” No cumple “0”

Elección: Para la elección de la base de datos se ha seleccionado Amazon RDS se considera la versatilidad de manejar los datos en la nube para la realización del proyecto, de esta manera ejecuta un sistema de compatibilidad con la plataforma de almacenamiento en la nube, además, un api del modelo de entrenamiento y así realizar la conexión con las consultas en nuestro diseño web, también, tiene la funcional de recopilar y almacenar los datos, de tal forma conseguimos conectividad con la plataforma de almacenamiento en la nube y posteriormente abstrae sus características a un nivel administrativo de los datos para emplearlos en aplicaciones de desarrollo.

Nota. Se realiza la elección de la base de datos. **Fuente:** Desarrollo del proyecto.

3.5.2.6. Plataforma Web

La elección de la plataforma web deberá ser en un lenguaje abierto y claro para lograr cumplir con los requerimientos planteados, por esta razón se puede mostrar la información de una manera concreta que permita al usuario abstraer los resultados. Por lo tanto, en la tabla 23 se encuentra algunas de las mejores opciones de acuerdo con los requerimientos como el SySR12 donde la visualización de los datos almacenados, en el SySR13 indica mediante una alerta la detección de la enfermedad, además el SRSH6 especifica el acceso a la base de datos con el servidor web para mostrar los resultados, además, en el SRSH11 la plataforma debe ser Open Source para poder integrar algunas funciones y tener el sistema actualizado.

Tabla 23. Elección del software de Plataforma Web.

PLATAFORMA WEB					
TIPO	REQUERIMIENTO				VALORACIÓN
	SySR12	SySR13	SRSH 6	SRSH10	
				1	
Ext.Net	1	1	1	1	4
Ionos	1	1	1	0	3
Worpress	1	0	0	1	1
Cumple "1" No cumple "0"					

Elección: De las tres plataformas web, se ha seleccionado Ext.Net que integra los requerimientos del proyecto, de acuerdo con la visualización de datos almacenados de manera concisa, uno de los más importantes es generar un reporte de las alertas hacia el usuario, además se adhiere la autenticación hacia la plataforma web a la nube para crear aplicaciones centralizadas conjuntamente con PHP para realizar consultas que se comuniquen entre estaciones de trabajo, páginas web, dispositivos móviles, dispositivos embebidos y consolas, entre otros.

Nota. Se realiza la elección del software de la plataforma web con relación a los requerimientos de arquitectura y sistema. **Fuente:** Desarrollo del proyecto.

3.5.3. Elementos seleccionados para elaboración del proyecto

Una vez realizados la elección de hardware y software mediante los requerimientos de sistema y arquitectura se indica el listado de los elementos seleccionados para la elaboración del proyecto en la tabla 24, los cuales actúan de una manera funcional en el desarrollo del proyecto de una manera eficiente que cumplan la función de alertar al usuario sobre el tipo de enfermedad en tal sentido se aplica medidas de prevención de acuerdo al análisis ejecutado sobre el sistema.

Tabla 24. Elementos para elaboración del proyecto

ELEMENTOS	FUNCIONAMIENTO	CONSIDERACIONES
MAVIC 2 ZOOM	Vehículo aéreo utilizado para mapear los campos agrícolas.	
WI-FI	Permite la comunicación con la topología, por tal razón, integra todos los servicios y garantiza la transmisión de los datos.	Establecer un canal de comunicación para la transmisión y recepción.
DJI GS PRO	Generar un registro de la ubicación para realizar el mapeo con el dispositivo con waypoints estratégicos, por una trayectoria total, permite grabar y tomar fotos en los tiempos acordes según se establezca los parámetros.	Definir la trayectoria del vuelo de acuerdo con los parámetros de velocidad y de altura.
OPEN CV	Por su alto nivel de resolución, escalable para tiempos largos y porque mantiene una comunicación con el servidor web, tiene una documentación robusta y admite redes convolucionales.	Integra la funcionalidad del entrenamiento del algoritmo, para tener métricas de evaluación para su apreciación de precisión.
AWS EC2	Es compatible con API estándares del sector con lenguajes de programación Python y C++; además, faculta gestionar el servidor web con las peticiones que se generan desde la plataforma de código abierto.	La transmisión de las imágenes en la nube hace que sea el sistema de manera central que disminuye recursos.

AWS RDS

La base de datos sirve para recopilar y almacenar la información, compatible con PHP para realizar la conexión con las consultas en nuestro diseño web, además se conecta a la plataforma de almacenamiento en la nube y posteriormente abstrae sus características a un nivel administrativo.

Almacena las muestras que serán procesados por el framework y los envía a la plataforma web.

EXT.NET

Interacción con el agricultor y visualización de resultados del estado del cultivo en campos agrícolas. Además, realiza consultas con la plataforma web a la nube para crear aplicaciones centralizadas juntamente con PHP donde realiza consultas entre las estaciones de trabajo.

Contiene los resultados y parámetros de evaluación después del entrenamiento del sistema.

Nota: Se presenta el listado de los elementos y su funcionamiento. **Fuente:** Desarrollo del proyecto.

4. CAPÍTULO IV: PROPUESTA

4.1. Sistema Propuesto

En función a la información recolectada en los apartados anteriores se realizó un análisis para identificar las directrices para el diseño del sistema, en ese contexto, se presenta los criterios obtenidos para el desarrollo e implementación del sistema de visión artificial.

4.1.1. Descripción General del Proyecto

Para entender el proceso del proyecto se identificó estos bloques que permiten al sistema funcionar integralmente, como se muestra en la figura 28, de esta manera el resultado final que evidencia el usuario es un reporte en una plataforma web y así realizar un manejo preventivo.

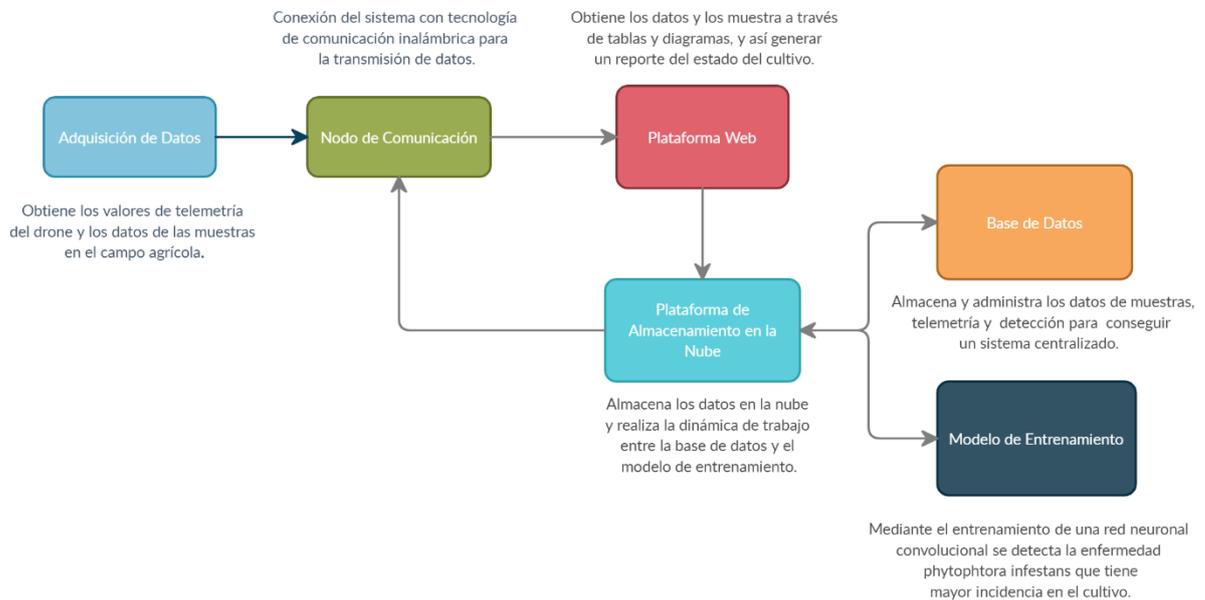


Figura 28. Diagrama de bloques del proyecto.

Fuente: Desarrollo del proyecto.

El sistema de discretización de imágenes es un proyecto innovador el cual, consiste en cinco fases:

La primera fase consiste en la adquisición de los datos mediante el monitoreo aéreo al utilizar un drone, el cual hace un recorrido por la plantación mediante *waypoints*⁹ estratégicos de manera autónoma, dentro de este proceso se considera la localización de cada punto, de esta manera se integra varios factores para la optimización de recursos. Luego los datos de telemetría y predicción del cultivo son cargados a la plataforma web de forma manual, sin embargo, no hay que dejar de por medio las limitaciones, que permiten evaluar de una manera eficiente el sistema, es decir, la calidad de la imagen, la velocidad de fotograma y la altura correspondiente.

La segunda fase establece la comunicación de los usuarios hacia la plataforma web, mediante un *hotspot*¹⁰, cuya funcionalidad centralizada es generar las consultas a la base de datos mediante la plataforma de almacenamiento en la nube y que la transmisión de los datos se suba de manera manual. No obstante, existen algunas limitaciones en base al retardo de carga del paquete en función del ancho de banda de la tecnología de comunicación. La versatilidad del tiempo de ejecución se verá reflejado en la eficiencia del sistema para generar una respuesta de las zonas de alerta hacia el usuario.

⁹ Conjunto de coordenadas que identifican un punto concreto en el espacio físico terrestre en relación con la latitud y longitud.

¹⁰ Se trata del acceso de cobertura que se ofrece a través de un dispositivo para que haya una comunicación inalámbrica, sin cables, WIFI.

Dentro del marco de la tercera fase se evidencia algunas etapas del desarrollo del método de entrenamiento de una Red Neuronal Convolutiva (CNN), tales como son: Convolución, Máxima Agrupación, Aplanamiento y Softmax. Este proceso se encuentra alojado en la plataforma de almacenamiento en la nube donde consume recursos que permiten conseguir el resultado mediante el ajuste de la red previo a un preentrenamiento de este modo se equilibra los pesos y así tener una salida con una precisión real.

La cuarta fase consiste en almacenar los resultados del modelo de entrenamiento de una manera organizada en la base de datos que logra llevar la información de una manera central; de este modo recopila y gestiona cada tabla para su posterior ejecución en la plataforma web, sin embargo, la estructura de las tablas se debe hacer desde los datos del proyecto hasta el proceso de cada uno.

La quinta y última fase consiste en la publicación de la información procesada en una plataforma web, el mismo que será expuesto al agricultor en términos sencillos de entender.

En referencia al funcionamiento estructural del proyecto, se plantea la siguiente topología: en primera instancia el administrador ejecuta el plan de vuelo, cuyos datos de telemetría y predicción son subidos en la plataforma web mediante un hotspot hacia el Amazon EC2 (Amazon Elastic Compute Cloud).

A continuación, el modelo de entrenamiento actúa con una tarea asignada para empezar a identificar la enfermedad con los videos, y que así sus datos se almacenen en el Amazon RDS (Relational Database Service). Una vez que el primer video se encuentre en estado de “procesado”, se empieza una nueva tarea mediante el demonio para reanudar el

proceso y dar paso al siguiente video. De este modo se consigue el total de muestras de acuerdo con los datos de telemetría captados.

Una vez procesada la información, el usuario puede hacer uso de la plataforma web para visualizar el reporte de datos generados por el sistema. Se muestra un resumen englobado del sistema en la figura 29.

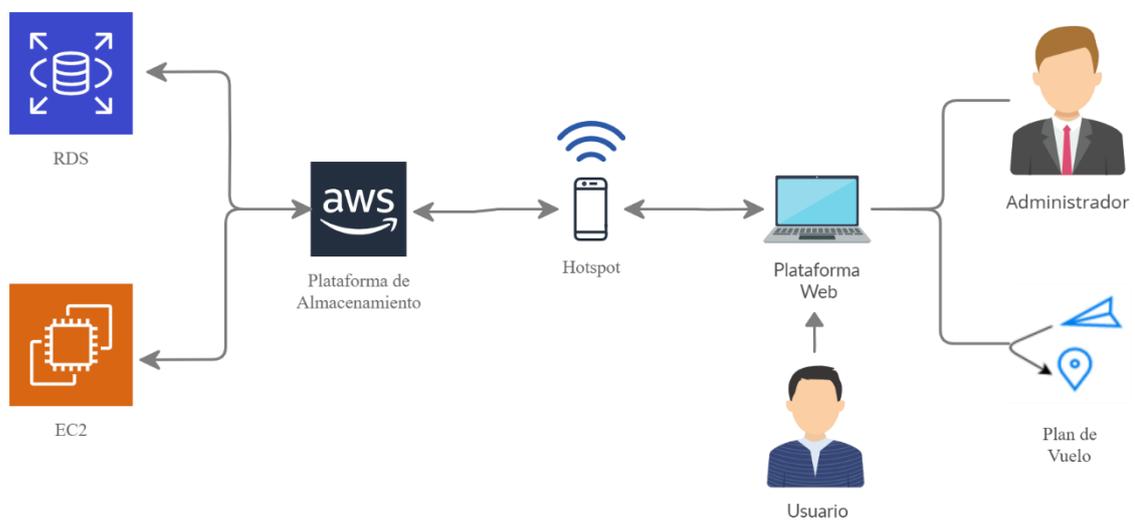


Figura 29. Topología de funcionamiento

Fuente: Desarrollo del proyecto

4.1.2. Adquisición de Datos

Como se menciona en la sección anterior, esta fase es esencial por el manejo de adquisición de los datos, sin embargo, este proceso tiene integrado algunos factores como se evidencia en la figura 30, en un inicio se debe considerar el punto de origen de vuelo, seguido de los parámetros de vuelo que hacen referencia a un waypoint inicial, en ese sentido, el funcionamiento se hace en waypoints estratégicos para cubrir la totalidad del cultivo, luego los datos obtenidos son transmitidos hacia la plataforma web de manera manual.

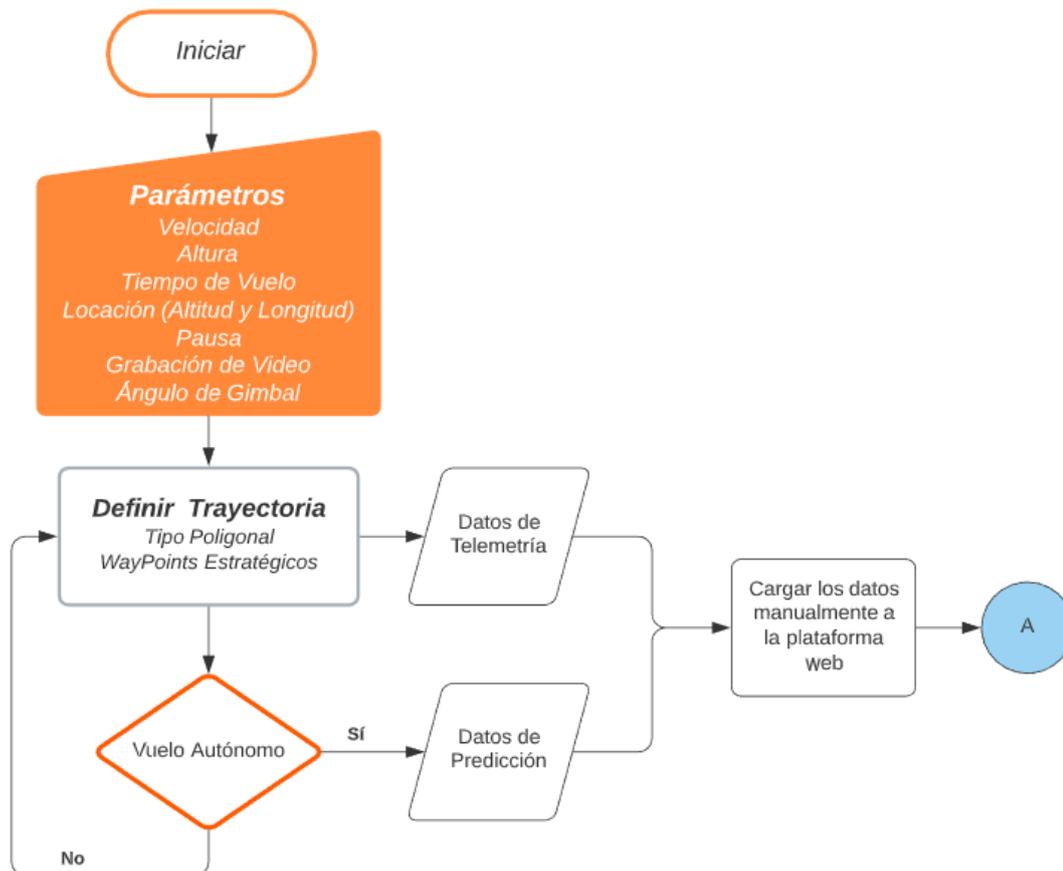


Figura 30. Diagrama de flujo de la adquisición de datos.

Fuente: Desarrollo del proyecto.

4.1.2.1. Plan de vuelo

El diseño de la trayectoria del vuelo del dron se hace en base a la totalidad del terreno de 76.24m², de este modo se define el número de puntos que van a ser estudiados; por tal razón se define el total de surcos e hileras del cultivo en el terreno de estudio de 22 para poder determinar el tiempo de vuelo y las consideraciones externas, es decir, si existe algún obstáculo y así conseguir el objetivo sin dificultades. En este aspecto, es necesario saber las condiciones edafoclimáticas para poder realizar un vuelo seguro, como se muestra en la figura 31. Es importante considerar las ráfagas de viento para que el dron pueda realizar el plan de vuelo de manera equilibrada y utilizar menos recursos de energía.



Figura 31. Ventana de consideraciones climáticas para vuelo del dron

Fuente: Desarrollo del proyecto.

Seguidamente tenemos la formulación de la hipótesis que genera el proceso del diseño para la resolución de la toma de datos a través del mapeo del dron, en ese aspecto realizaremos un análisis de las mejores consideraciones para que el proceso se lleve óptimamente como resultado sus datos sean correctos. Por lo antes expuesto, se considera importante algunos factores claves:

- Trayectoria del vuelo
- Solape entre las imágenes
- Posición de la cámara

4.1.2.1.1. Diseño adecuado

Para empezar a realizar el diseño especificaremos cada uno de los factores claves, donde la planificación de vuelo se realiza al generar ortomapas para seguir la trayectoria del drone, como se puede identificarla en la figura 32. En relación con la ubicación de los waypoints estratégicos se define a una distancia de 1.5 m, en referencia al fabricante del drone, donde si es de menos distancia entre waypoints se solapan, de esta forma con el fin de determinar los puntos que recubran toda la superficie sobre la que se realizará el estudio. En ese aspecto, se crea una malla con 70 waypoints estratégicos, de esta manera se obtiene una forma poligonal del recorrido del drone, cabe mencionar que la localización se muestra en la tabla 27.

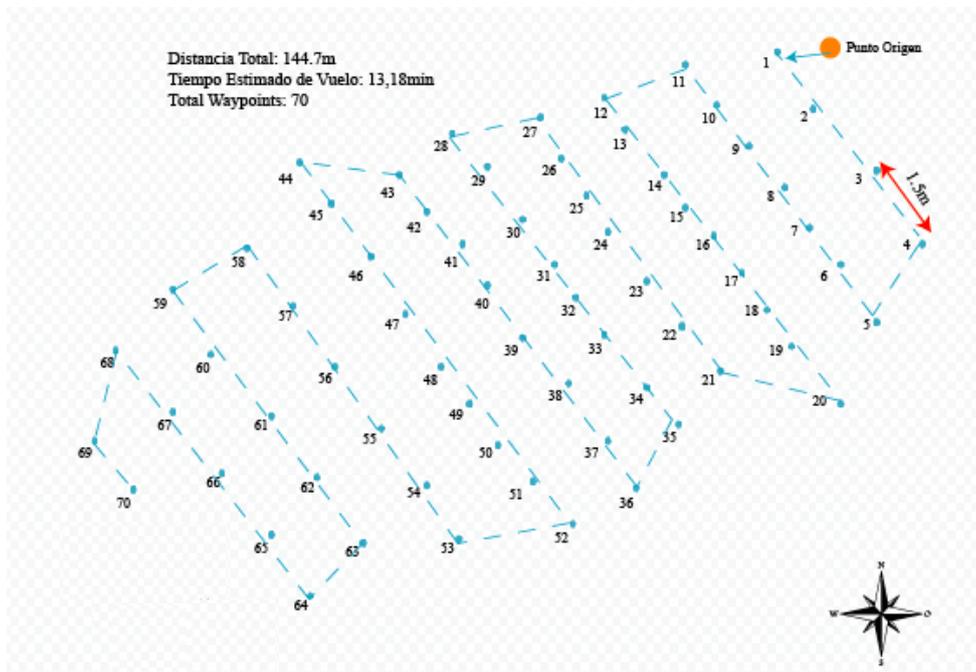


Figura 32. Esquema de waypoints de muestreo.

Fuente: Desarrollo del proyecto

4.1.2.1.2. Almacenamiento y análisis de datos

Para el desarrollo de la obtención de los datos se empieza del lugar de origen, es muy importante debido a que al generar el vuelo automático al encontrar algún obstáculo en su trayectoria de inicio el drone no se elevará al punto de partida de la trayectoria como se observa en la figura 33, sin embargo, es importante la colocación del drone al estar lo más plano posible para que la calibración de la brújula sea la idónea, además, el GPS necesita de un tiempo para poder generar la longitud y latitud.



Figura 33. Punto de origen de vuelo del drone

Fuente: Terreno de estudio.

Luego se realiza la trayectoria del vuelo del drone mediante la aplicación dji gs pro, de forma poligonal como se muestra en la sección 1.1.6.3. del capítulo II de acuerdo con el punto de origen, seguido de tener las mediciones del terreno para establecer el recorrido, además, se establece ciertos parámetros como se muestra en la figura 34, que permiten que el sistema sea estable, primero se considera el gimbal tomará la posición de 90° para la transmisión, luego empezará la grabación, para tener datos válidos con capacidades de 2.7k con una resolución de 2688x1512 a 24fps, sin embargo, el entorno operativo considera la detección de una superficie con patrón claro e iluminación adecuada ($luz > 15$) con una pausa

de 5s y finalmente se termina la grabación del waypoint, seguido el drone se dirige hacia el waypoint siguiente.

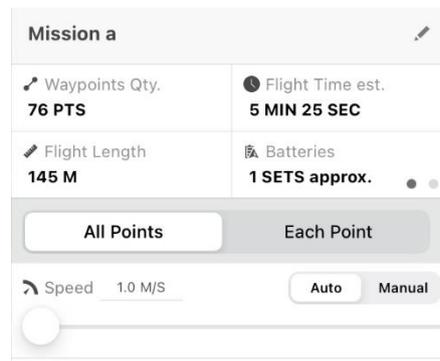


Figura 34. Ventana para modificar parámetros de waypoints.

Fuente: Aplicación Flight Plan en el terreno de estudio

Terminado la configuración de estos parámetros podemos iniciar con el plan de vuelo como se muestra en la figura 35, dentro del desarrollo podemos identificar en la parte izquierda como se muestra el cultivo, las coordenadas por donde el drone se encuentra, velocidad del drone y la altura. En la ventana derecha de evidencia como el drone sigue la trayectoria por todo el cultivo donde se debe nombrar la posición del drone en relación con el viento, por tal razón se opta por una postura que permite estabilizar al drone y en la parte superior nos muestra el estado del drone de acuerdo con a su señal, batería. Finalmente, la parte superior derecha de la ventana se encuentra la telemetría del drone para explicar la distancia del mando al drone, la elevación, velocidad del drone, y así al culminar el proceso el drone regresa al lugar de origen para procesar los datos que se obtienen después de todo el trayecto.

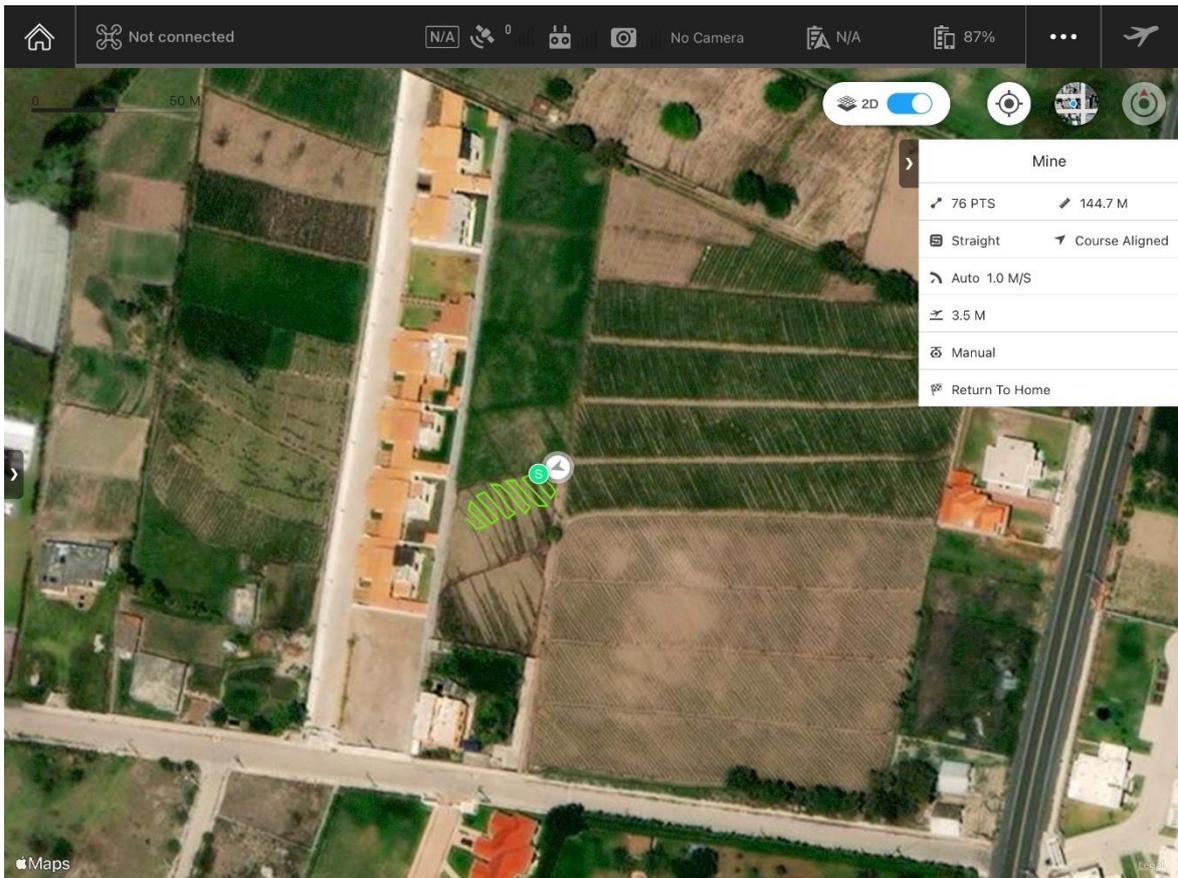


Figura 35. Trayectoria de vuelo del drone con aplicación dji gs pro

Fuente: Aplicación Flight Plan en el terreno de estudio

El registro de cada uno de los vuelos se utiliza el método de prueba y error que se muestra en la tabla 25, en base a parámetros como el número de puntos, latitud, longitud, tiempo de vuelo, distancia, altura y velocidad.

Cabe mencionar que estos valores permiten establecer mejor apreciación en la calidad de las muestras los cuales están definidos en el tiempo de vuelo, es decir, en menor tiempo de intervalo tendremos mayor número de muestras para su posterior entrenamiento. Otra consideración se relaciona con los solapes lateral y frontal, con este parámetro podemos obtener mayor número de puntos para realizar un vuelo total por todo el terreno de estudio, sin embargo, existe margen de error donde la aplicación muestra un solapamiento de

waypoint al estar cerca del otro waypoint, es importante recordar que el tamaño entre punto de referencia y línea de trayectoria serán esenciales para obtener muestras idóneas.

Tabla 25. Calibración para posicionamiento y recorrido del dron

Id	Latitud	Longitud	Tiempo de Vuelo(s)	Distancia	Altura (m)	Velocidad (m/s)
1	0,363224	-78,154676	338	1,6	4	1
2	0,363209	-78,154662	338	3,2	4	1
3	0,363194	-78,154644	338	5	4	1
4	0,363176	-78,154632	338	8	4	1
5	0,363157	-78,154644	338	9,5	4	1
6	0,363171	-78,154655	338	11	4	1
7	0,363180	-78,154664	338	12,5	4	1
8	0,363191	-78,154671	338	14	4	1
9	0,363202	-78,154681	338	15,5	4	1
10	0,363213	-78,154692	338	17	4	1
11	0,363221	-78,154699	338	18,5	4	1
12	0,363213	-78,154721	338	21,5	4	1
13	0,363202	-78,154712	338	23	4	1
14	0,363193	-78,154704	338	24,5	4	1
15	0,363184	-78,154696	338	26	4	1
16	0,363175	-78,154687	338	27,5	4	1
17	0,363169	-78,154681	338	29	4	1
18	0,363157	-78,154671	338	30,5	4	1
19	0,363150	-78,154664	338	32	4	1
20	0,363137	-78,154653	338	33,5	4	1
21	0,363138	-78,154677	338	35	4	1
22	0,363146	-78,154686	338	36,5	4	1
23	0,363156	-78,154698	338	38	4	1

24	0,363168	-78,154709	338	39,5	4	1
25	0,363179	-78,154720	338	41	4	1
26	0,363188	-78,154727	338	42,5	4	1
27	0,363197	-78,154735	338	44	4	1
28	0,363207	-78,154740	338	45,5	4	1
29	0,363203	-78,154765	338	48,5	4	1
30	0,363195	-78,154755	338	50	4	1
31	0,363184	-78,154745	338	51,5	4	1
32	0,363173	-78,154735	338	53	4	1
33	0,363165	-78,154729	338	54,5	4	1
34	0,363156	-78,154721	338	56	4	1
35	0,363143	-78,154709	338	57,5	4	1
36	0,363134	-78,154701	338	59	4	1
37	0,363117	-78,154713	338	60,5	4	1
38	0,363127	-78,154723	338	62	4	1
39	0,363142	-78,154734	338	65	4	1
40	0,363153	-78,154744	338	66,5	4	1
41	0,363166	-78,154752	338	68	4	1
42	0,363176	-78,154761	338	69,5	4	1
43	0,363184	-78,154771	338	70,5	4	1
44	0,363193	-78,154780	338	72	4	1
45	0,363196	-78,154806	338	73,5	4	1
46	0,363186	-78,154797	338	75	4	1
47	0,363173	-78,154787	338	76,5	4	1
48	0,363159	-78,154775	338	78,5	4	1
49	0,363146	-78,154767	338	80	4	1
50	0,363137	-78,154760	338	81,5	4	1
51	0,363127	-78,154752	338	83	4	1

52	0,363118	-78,154740	338	84,5	4	1
53	0,363104	-78,154761	338	86	4	1
54	0,363117	-78,154773	338	87,5	4	1
55	0,363131	-78,154785	338	89	4	1
56	0,363146	-78,154797	338	90,5	4	1
57	0,363161	-78,154810	338	92	4	1
58	0,363175	-78,154823	338	95	4	1
59	0,363165	-78,154844	338	96,5	4	1
60	0,363149	-78,154831	338	98	4	1
61	0,363134	-78,154815	338	99,5	4	1
62	0,363119	-78,154802	338	101	4	1
63	0,363103	-78,154787	338	102,5	4	1
64	0,363090	-78,154803	338	104	4	1
65	0,363105	-78,154817	338	105,5	4	1
66	0,363120	-78,154832	338	107,5	4	1
67	0,363135	-78,154845	338	109,15	4	1
68	0,363150	-78,154859	338	110,8	4	1
69	0,363128	-78,154865	338	112,45	4	1
70	0,363116	-78,154854	338	114,1	4	1

Nota: Se presenta los resultados de las muestras en los waypoints obtenidos. **Fuente:** Desarrollo del proyecto.

Por otro lado se debe considerar los datos para la predicción que se toma en cada waypoint de acuerdo con las características definidas con los parámetros establecidos cuando el dron llega al punto de inicio, el gimbal toma una dirección de 90°, luego inicia la grabación por 5s y finaliza el proceso y pasa hacia otro waypoint, por lo expuesto se aprecia de una mejor manera la enfermedad en el cultivo en tiempo real de duración de 5s, a continuación, se muestra en la figura 36 el desarrollo de los datos de predicción.

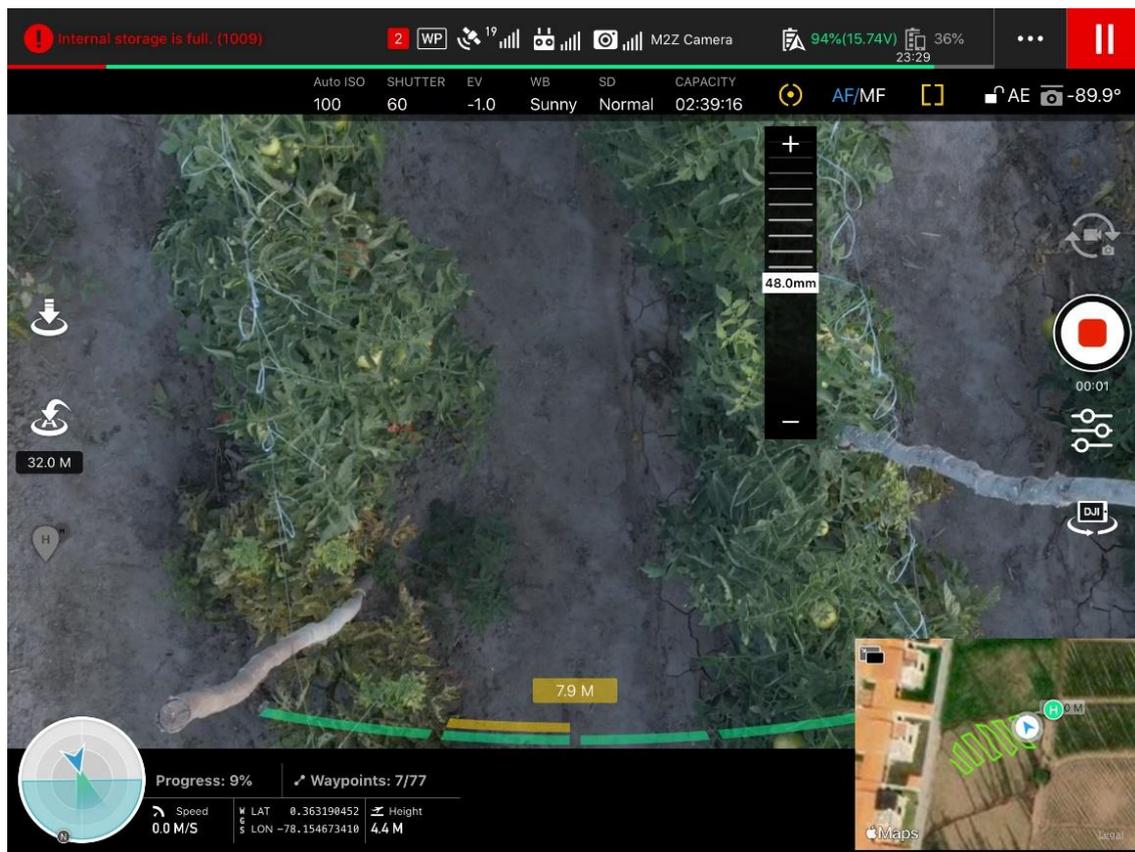


Figura 36. Datos para predicción

Fuente: Desarrollo del proyecto

4.1.2.2. Carga de Datos

Este procedimiento se realiza en subir los datos de telemetría en formato .csv y los datos de predicción que son en total 70, conseguidos cada 5s que son nombrados automáticamente en formato .mp4 extraídos de la tarjeta micro SD y cargados hacia la plataforma web, sin embargo, se debe esperar un tiempo acorde de acuerdo a las muestras obtenidas, a continuación se muestra en la figura 37 la ventana para cargar los datos de forma manual en la plataforma web.

CONTROL DE PLAGAS BIENVENID@ ADMIN

Menú Principal

- INICIO +
- PROYECTO -
- Crear Proyecto
- Cargar Mapa
- Cargar Videos
- REPORTE +
- RECURSO +

Inicio x Cargar Videos x

Id / Nombre Proyecto: Buscar Limpiar

Mapa:

Id Proyecto: Nombre Proyecto: Nombre Propietario:

Id Mapa: Descripción: Estado:

Id Vuelo: Inicio Vuelo: Tiempo Vuelo: Altitud:

Información del Mapa

Seleccione un archivo Vuelos:

id	Id Mapa	Id Vuelo	Id Dron	Ruta Archivo	Estado

Figura 37. Carga de datos de forma manual.

Fuente: Desarrollo del proyecto

4.1.3. Nodo de comunicación

La transmisión de los datos se lo hace mediante hotspot que emplea el dispositivo móvil en función de establecer la conexión del servidor con el agente y el usuario, de este modo interactúa la plataforma web y la plataforma de almacenamiento en la nube, además, dentro de esta plataforma integra los servicios de Amazon EC2 y el Amazon RDS, sin embargo, es importante nombrar que Amazon EC2 ejecuta el modelo de entrenamiento mediante un demonio que lleva a cabo una tarea para generar un proceso que luego es enviado hacia la plataforma web como se muestra en la figura 38 la estructura de la topología del sistema.

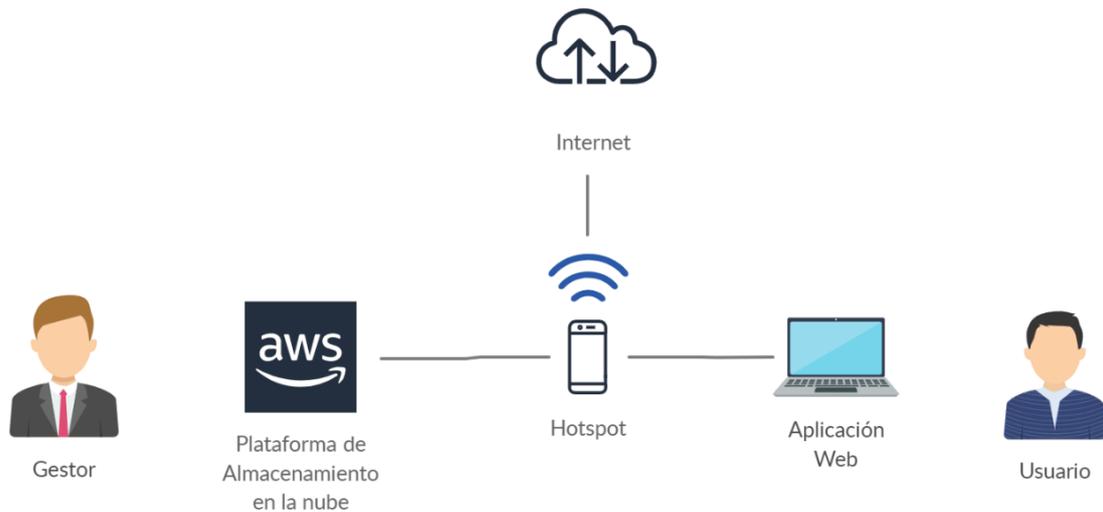


Figura 38. Funcionamiento del nodo de transmisión.

Fuente: Desarrollo del proyecto

4.1.4. Página Web

Esta fase del sistema consta de un proceso en base a los requerimientos del usuario, por tal causa se define la estructura que mantendrá el portal web durante su desarrollo. A continuación, se presenta en la figura 39 el diagrama de la estructura de la plataforma web.

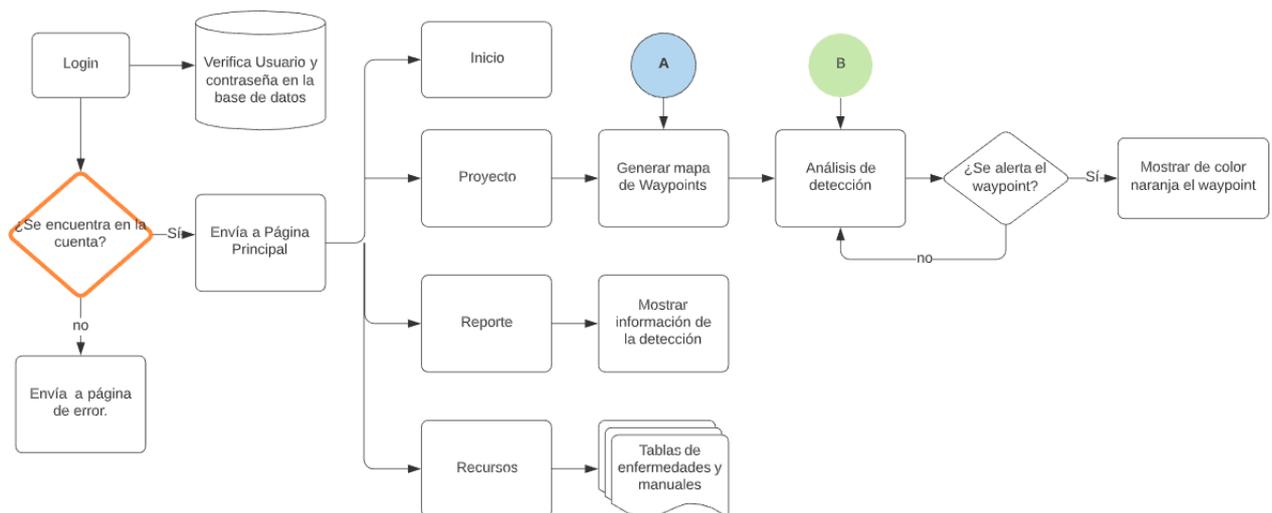


Figura 39. Diagrama de la estructura de plataforma web

Fuente: (Barba & Berenguer, 2013)

4.1.4.1.Estrategia

La estrategia es la primera fase del modelo, en la cual se determinan los objetivos que se desean lograr al informar los diferentes tipos de plagas y enfermedades para conocer el contexto del proyecto, así como, mostrar la zona al identificar la enfermedad (phytopthora infestans), del mismo modo cuáles son las necesidades para generar un reporte del análisis del terreno de estudio como se muestra en la figura 40. los pasos para una estrategia efectiva.

El primer paso se establece en tablas que engloben los diferentes tipos de plagas y enfermedades, además explicar el proceso del esquema de adquisición y procesamiento de datos. El segundo paso nos genera un mapa con las coordenadas, el cual está pintado de color verde (saludable) y rojo (enfermo). En relación con su ubicación permitirá ver el porcentaje de estimación de daño mediante los resultados del esquema. El tercer paso se obtiene un reporte que informe concretamente los resultados de la enfermedad, mediante un formulario que será impreso para tener un registro válido del comportamiento del cultivo. Finalmente, el último paso se debe recordar la incursión en internet, es por eso delimitar y fijar el alcance geográfico del proyecto, en vista a estas necesidades al ser un proyecto experimental se estipula que logre cubrir un alcance I o cobertura local.

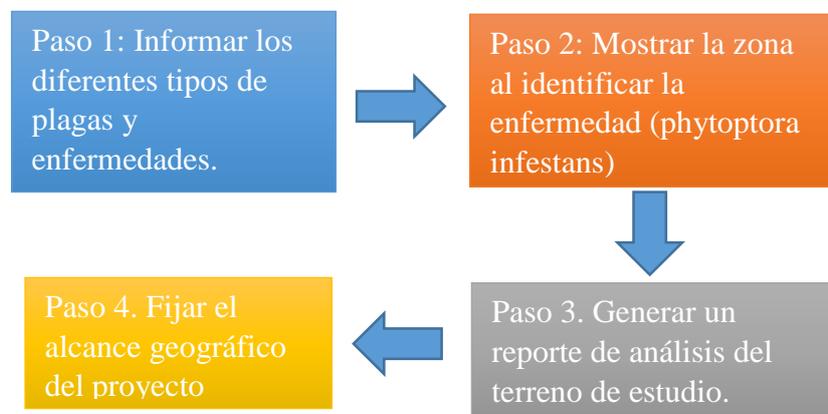


Figura 40. Pasos para lograr una estrategia efectiva

Fuente: Desarrollo del proyecto

4.1.4.2.Experiencia de usuario

Dentro de este campo se determina los recursos que depende la funcionalidad de la página web, como son materiales y técnicos, por lo tanto, contiene la dinámica de abstraer la información que se va a publicar, es decir lo puntual y claro para el desarrollo de la página web, además, se precede de la arquitectura de la información para generar las funciones con las cuales se va a integrar en el diseño.

4.1.4.3.Diseño

El diseño de cualquier sitio web es un tema de gran compromiso y complejidad, existe una gran variedad de metodologías con diferentes enfoques a lo que el diseño debería ser. A pesar de la facilidad relativa con la que se puede construir un sitio en Internet, se debe tomar en cuenta una gran cantidad de factores técnicos, mercado lógicos e inclusive elementos psicológicos y de percepción del usuario.

Es conveniente siempre empezar esta fase del proceso al abrir nuestro programa gráfico preferido y plasmarlo en una serie de gráficos vectoriales una primera visión de la interfaz que se crea, basada en la información que se recopila, y así como de alguna de las páginas secundarias y de los formularios necesarios

Podemos crear un sitio web totalmente funcional y operativo, en el que los procesos de intercambio con las bases de datos sean fácilmente implementables, y que además sea muy fácil de navegar, pero entonces seguramente estaremos muy limitados a la hora de expresar en sus páginas nuestras inquietudes estéticas y de diseño.

A continuación, en la figura 41 se describen los diferentes pasos del diseño y las consideraciones principales a tomar en cada uno de ellos.

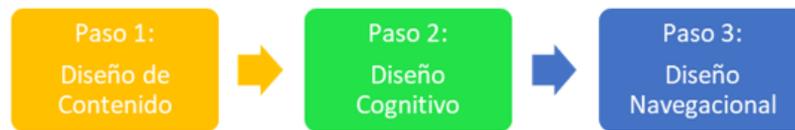


Figura 41. Diseño del sitio web

Fuente: Desarrollo del proyecto

Paso 1: Diseño de Contenido

El Diseño de Contenido es la etapa en la cual se definen los elementos a incluir en el sitio, dichos elementos pueden ser texto, vínculos, sonido o cualquier otro elemento soportado por la tecnología actual de los navegadores.

Paso 2: Diseño Cognitivo

El contenido que se presente en el sitio web de visión artificial para identificar la plaga en un terreno de estudio de tomate riñón puede tener gran impacto en la mente del usuario ya sea negativa o positiva, lo que se espera es una percepción positiva que logre un gran impacto en la mente del usuario final.

Paso 3: Diseño Navegacional

El diseño navegacional es el paso del modelo en el cual se define la forma en la que el usuario puede explorar todo el contenido del sitio de manera eficiente y dinámica. Se debe determinar que camino el usuario debe seguir, es decir una estructura clara con simples controles para llegar a cada servicio o pieza de información incluida en el sitio web.

4.1.4.4.Desarrollo

El desarrollo de este campo lo hace en base a la estructura del funcionamiento de los requerimientos, en ese sentido la figura 42 nos muestra la autenticación del usuario para acceder a la página de inicio.



Figura 42. Ventana de autenticación en la plataforma web

Fuente: Desarrollo del proyecto

De este modo para ingresar a la plataforma web se debe registrar al usuario mediante los permisos que se genere para los usuarios, por tal razón, la lista de usuario se establece mediante el administrador de acuerdo con los privilegios que se le asignen en función del proceso a ejecutarse dentro el análisis del cultivo que se muestran en la plataforma web.

Cuando el usuario se logea al ingresar el usuario y password, a través de la comunicación con nuestro SQL podemos tener acceso a nuestra plataforma web. En la figura 43 nos muestra el inicio de nuestra página de la información resumida de los temas a tratar para dar al usuario información importante.

De este modo, cuenta con un menú que adhiere algunos servicios de inicio, proyecto, reporte y recursos. La información esencial del proceso de funcionamiento y contacto se adhiere a la página de inicio para organizar la convivencia del usuario con el servicio.

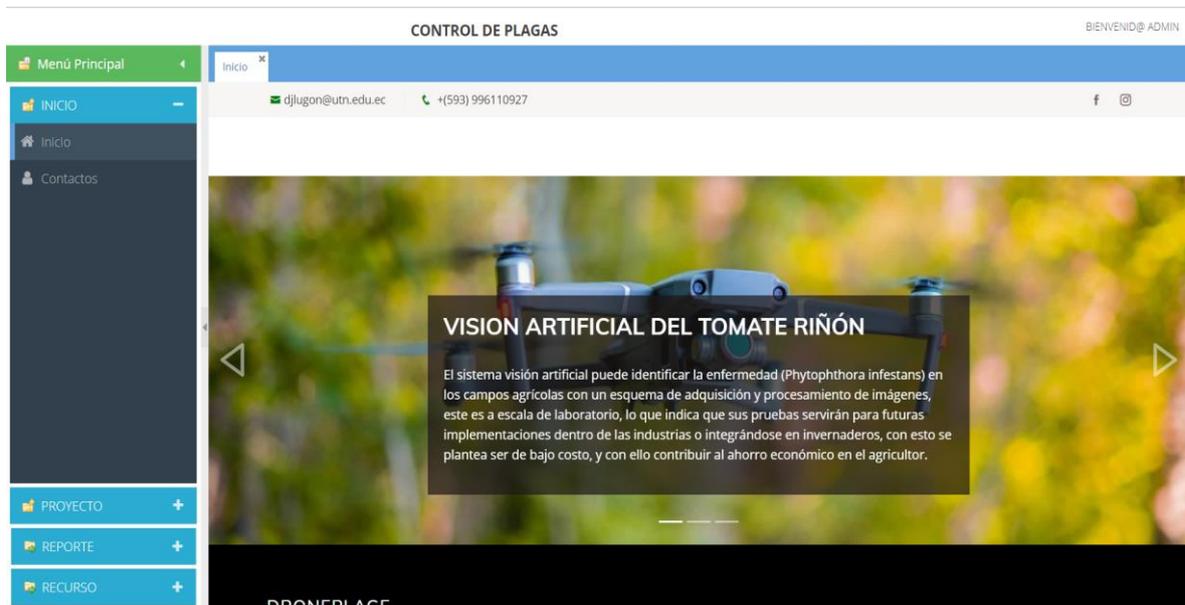


Figura 43. Ventana de inicio de la plataforma web

Fuente: Desarrollo del proyecto

También en la pestaña del menú en proyecto se genera un proyecto con los datos del proyecto a investigar, por lo que se ingresa los datos importantes para llevar un registro claro para mostrarlos en el reporte, como se evidencia en la figura 44, se considera las dimensiones del cultivo para establecer la trayectoria del drone, además, estos datos identifican el proceso para generar una mejor precisión.

CONTROL DE PLAGAS BIENVENID@ ADMIN

Menú Principal

- INICIO
- PROYECTO
- Crear Proyecto
- Cargar Mapa
- Cargar Videos
- REPORTE
- RECURSO

Crear Proyecto

Id: AUTOMATICO Nombre Proyecto: Tipo Cultivo:

Descripción: Estado:

País: Provincia: Ciudad:

Id Propietario: Nombre Propietario: Dimensión Lote:

PROYECTOS					
Id	Nombre Proyecto	Propietario	Tipo Cultivo	Dimensión Lote	Estado
1	Sector 1	Daniel Perez	TOMATE	34543 m2	ACTIVO
2	Sector 2	Reinaldo Augusto	TOMATE	23234 m2	INACTIVO
3	Imbaya 1	María Zapata	TOMATE	3545 p2	ACTIVO
4	Imbaya 2	Andrés Sañudo	TOMATE	345345 m2	INACTIVO
5	Caranqui	Carlos Sandoval	TOMATE	45454 m2	ACTIVO
6	Otavalo	Reinaldo Augusto	TOMATE	34324 p2	ACTIVO
7	Imbaya 3	Fernando Pérez	TOMATE	1200 m2	ACTIVO
8	Chorlari	Leonardo León	TOMATE	525 m2	ACTIVO
9	Puambo	Fernando Perez	TOMATE	12000 m2	ACTIVO
10	Sector 3	Anibal García	TOMATE	4820 m2	ACTIVO

Figura 44. Ventana para crear proyecto

Fuente: Desarrollo del proyecto

Con el fin de generar un mapa de waypoints se empieza a buscar el proyecto al cual se va a asignar la base de datos en formato .csv para poder extraer los datos y de esta manera cargar el proyecto, sin embargo, con esta funcionalidad podemos graficar el mapa, todo este proceso se adhiere en la figura 45.

CONTROL DE PLAGAS BIENVENID@ ADMIN

Menú Principal

- INICIO
- PROYECTO
- Crear Proyecto
- Cargar Mapa
- Cargar Videos
- REPORTE
- RECURSO

Cargar Mapa

Id / Nombre Proyecto: Información...

Id Proyecto: 7 Nombre Proyecto: Imbaya 3 Validación de información correcta...

Id Mapa: 1 Descripción: Nombre Propietario: Fernando Pérez

Estado:

Información del Mapa

base 123.csv Guardar Mapa Ver Mapa

Id	Id Dron	Id Proy.	Latitud	Longitud
1	DJL_0001	7	0.36322398640053	-78.1546721096359
2	DJL_0002	7	0.363209451006527	-78.154662599229
3	DJL_0003	7	0.363194813336539	-78.1546446692648
4	DJL_0004	7	0.363176316632759	-78.1546318683897
5	DJL_0005	7	0.363157482078377	-78.1546447538382
6	DJL_0006	7	0.36317178331172	-78.1546540982365
7	DJL_0007	7	0.363180275568202	-78.154663240033
8	DJL_0008	7	0.363190188858887	-78.1546705745185
9	DJL_0009	7	0.36320051377171	-78.1546809290915
10	DJL_0010	7	0.363210249574831	-78.1546896471411

Figura 45. Ventana para cargar mapa

Fuente: Desarrollo del proyecto

Luego nuestro mapa se muestra de acuerdo con el archivo .csv que se carga de los datos obtenidos de la telemetría, en ese contexto, podemos identificar el área del terreno de estudio y su forma, de este modo conocer la localización como se muestra en la figura 46 la longitud y latitud.

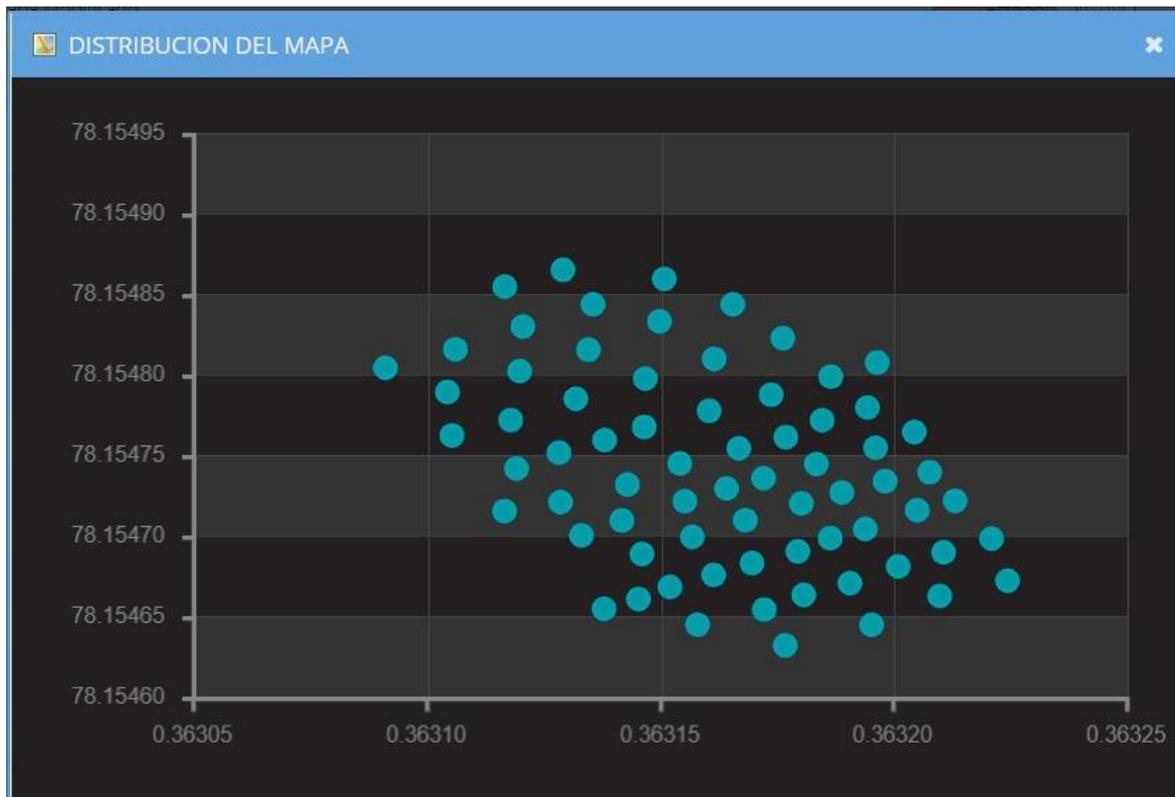


Figura 46. Mapa con waypoints de resultado.

Figura: Desarrollo del proyecto

4.1.5. Plataforma de almacenamiento en la nube

Particularmente en el proceso de la plataforma web, se empieza a crear las instancias de la plataforma de servicios en la nube de amazon web service, de tal forma se incluye el servicio amazon EC2 (Amazon Elastic Compute Cloud), el cual permite generar la administración de los recursos de manera confiable, escalable, infraestructura bajo demanda, por lo cual en base a su almacenamiento se designado un período de 750 horas dentro de la capa gratuita durante 12 meses para poder levantar el servicio con tamaño modificable.

Dentro de esta plataforma utiliza procesadores de 400Gbps de red ethernet, con varias instancias GPU para usarlas en nuestro proyecto, además cuenta con un estándar de seguridad VPC launch wizard como se muestra en la figura 47.

Actualmente, utiliza los siguientes recursos de Amazon EC2 en la región EE.UU. Este (Ohio):

Instancias en ejecución	1	Balanceadores de carga	0
Direcciones IP elásticas	0	Grupos de seguridad	2
Grupos de ubicación	0	Hosts dedicados	0
Instancias (todos los estados)	1	Instantáneas	0
Pares de claves	1	Volúmenes	1

Realice fácilmente tareas de ajuste de tamaño, configuración e implementación de grupos de disponibilidad Always On de Microsoft SQL Server en AWS con el asistente de lanzamiento de AWS. [Mas información](#)

Lanzar la instancia

Para comenzar, lance una instancia de Amazon EC2, que es un servidor virtual en la nube.

Estado del servicio

Panel de estado del servicio

Región: EE.UU. Este (Ohio) Estado: Este servicio funciona

Figura 47. Ventana de instancia EC2

Fuente: Desarrollo del proyecto

De tal forma se adhiere el servicio de base de datos relacional en la nube RDS (Relational Database Service) que administra los recursos de las diferentes plataformas para suministrar capacidad rentable y escalable, de esta manera proporciona instancias que son creadas con servicios adjuntos como es sql server para administrar este servicio, sin embargo, hay un período de retardo para realizar las consultas de las tablas, que son cargados al sistema como se evidencia en la figura 48.

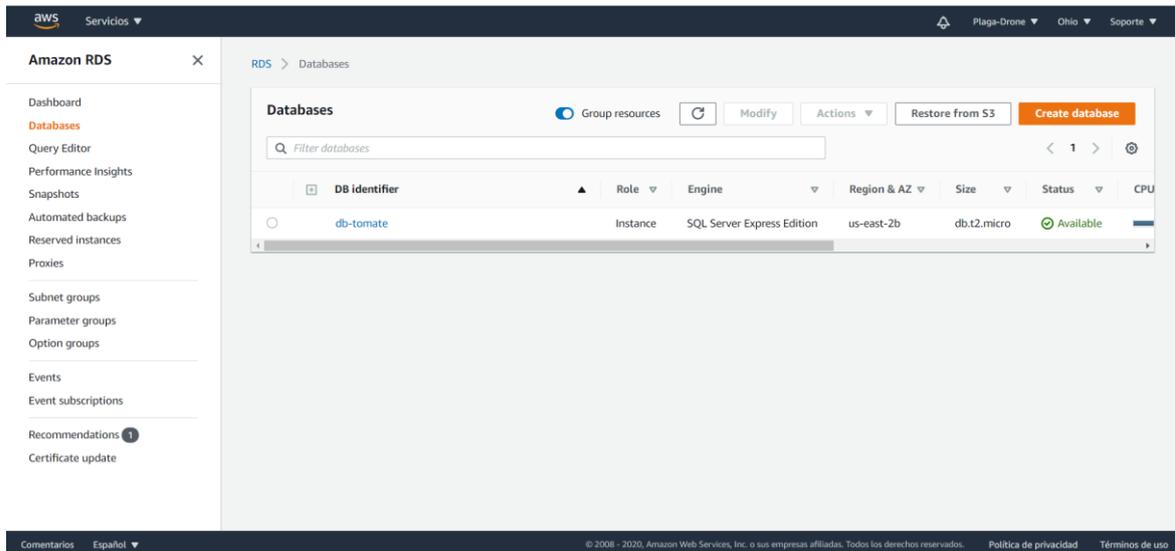


Figura 48. Ventana de base de dato RDS.

Fuente: Desarrollo del proyecto.

4.1.6. Base de Datos

Dentro del almacenamiento de la base de datos tendremos tres tablas que nos permitirán dinamizar los resultados adquiridos como se muestra en la figura 49, en primer lugar tenemos la tabla usuarios pertenece al módulo de seguridad, en esta se puede guardar los usuarios que tienen acceso al sistema y se valida los datos al ingresar al sistema, luego la tabla país almacena los países donde se puede registrar proyecto, la tabla provincia almacena provincias de cada país registrado, la tabla ciudad almacena ciudades de cada ciudad registrada. Con estos elementos se puede localizar en donde se encuentra geográficamente un proyecto. Para anexar con el proceso se encuentra la tabla tipoCultivo guarda los registros de qué tipo de cultivo tiene sembrado el terreno. En la tabla proyectos se registran todos los datos de cada proyecto, como información geográfica, de propietario, de cultivo, dimensiones. Cada proyecto puede tener diferentes mapas a lo largo del tiempo y estos registros se guardan en la tabla mapaProyecto_Cab y cada mapa guarda la latitud y longitud de cada waypoint en la tabla mapaProyecto_Det. Por otro lado, cada vuelo de

control que se realice con el vuelo se guardará en la tabla controlVuelo_cab y los resultados del analisis del vuelo se guardarán en controlVuelo_Det.

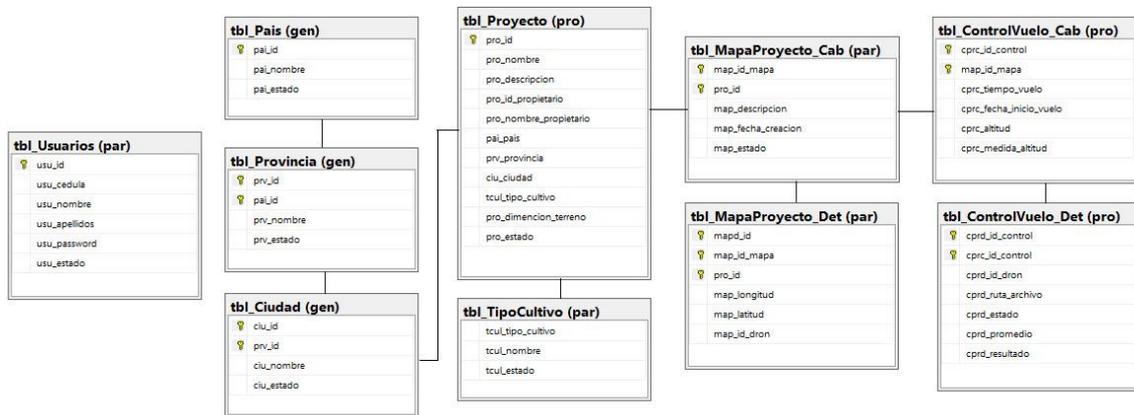


Figura 49. Diagrama de tablas de la base de datos

Fuente: Desarrollo del proyecto

Este gestor de base de datos nos permite administrar y desarrollar de una mejor manera la funcionalidad de las tablas para poder generar resultados y consultas de los datos que se transmiten a través de la plataforma web, de este modo podemos observar en la figura 50 el nombre de todas las columnas y el estado en el que se encuentran de acuerdo con el funcionamiento de cada uno.

pro_id	pro_nombre	pro_descripcion	pro_id_propietario	pro_nombre_propietario	pai_pais	prv_provincia	ciu_ciudad	tcu_tipo_cultivo	pro_dimencion_terreno	pro_estado
1	Sector 1	di99f9df	109990	Daniel Perez	EC	03	241	1	34543 m2	ACTIVO
2	Sector 2	edf9dfdf	1212	Ramón Augusto	EC	02	180	1	23234 m2	INACTIVO
3	Imbaya 1	edf9dfdf	1213	Maria Zapata	EC	02	185	1	35452 m2	ACTIVO
4	Imbaya 2	di99f9df	1214	Andrés Bañudo	EC	01	280	1	34545 m2	INACTIVO
5	Caranqui	fg9fgh	1214	Carlos Sandoval	EC	05	115	1	45454 m2	ACTIVO
6	Obispo	exccc	1215	Ramón Augusto	EC	03	245	1	34324 m2	ACTIVO
7	Imbaya 3	edf9dfdf	1216	Fernando Pérez	EC	04	020	1	1200 m2	ACTIVO
8	Chorrali	Descripción del proyecto	1216	Leonardo León	EC	10	030	1	525 m2	ACTIVO
9	Puñendo	Producto cultivado en los campos de imbaya	1217	Fernando Pérez	EC	10	030	1	12000 m2	ACTIVO
10	Sector 3	VFFRE	1219	Anibal García	EC	10	030	1	4820 m2	ACTIVO

Figura 50. Ventana del gestor sql server 2016.

Fuente: Desarrollo del proyecto

4.1.7. Modelo de entrenamiento

Se empleó la red neuronal convolucional Yolov3, que permite la recepción del flujo de datos de la cámara del dron en tiempo real. Se emplea el módulo dnn de OpenCV que basa en un enfoque híbrido entre yoloV3 y Darknet-53, como se muestra la estructura en la figura 51, este modelo de entrenamiento tiene grandes prestaciones como varias capas convolucionales de acuerdo con varios filtros de diferentes tamaños que integran la función de activación.

	Type	Filters	Size	Output
	Convolutional	32	3 3	256 256
	Convolutional	64	3 3 / 2	128 128
1	Convolutional	32	1 1	
	Convolutional	64	3 3	
	Residual			128 128
	Convolutional	128	3 3 / 2	64 64
2	Convolutional	64	1 1	
	Convolutional	128	3 3	
	Residual			64 64
	Convolutional	256	3 3 / 2	32 32
8	Convolutional	128	1 1	
	Convolutional	256	3 3	
	Residual			32 32
	Convolutional	512	3 3 / 2	16 16
8	Convolutional	256	1 1	
	Convolutional	512	3 3	
	Residual			16 16
	Convolutional	1024	3 3 / 2	8 8
4	Convolutional	512	1 1	
	Convolutional	1024	3 3	
	Residual			8 8
	Avgpool		Global	
	Connected		1000	
	Softmax			

Figura 51. Arquitectura de la red implementada.

Fuente: (Redmon, n.d.)

A continuación, se detalla las fases para su diseño:

1. Conjunto de datos: se obtuvo 1000 fotografías del cultivo de tomate riñón, realizadas con la cámara del dron con alta resolución en megapíxeles.
2. Etiquetado de imágenes: este proceso se realizó de manera manual, con la ayuda de la herramienta labelImg 1.8.3. De este modo se etiquetaron objetos como: manchas de las hojas enfermas, de tal forma se consigue 1000 archivos txt correspondiente a la cantidad de muestras, además, el proceso se visualiza en la figura 52.

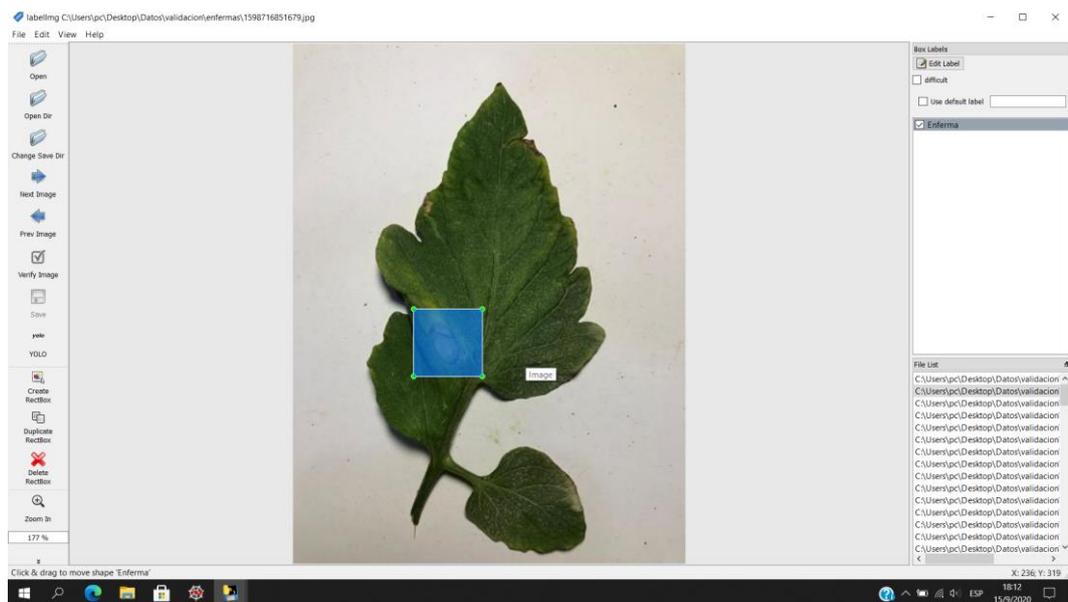


Figura 52. Etiquetado de imágenes

Fuente: Desarrollo del proyecto

3. Clasificación del conjunto de datos: se divide el conjunto de datos de manera aleatoria donde el 80% de las imágenes fueron destinadas para el entrenamiento, mientras que el 20% para el testeo, como se evidencia en la figura 53.

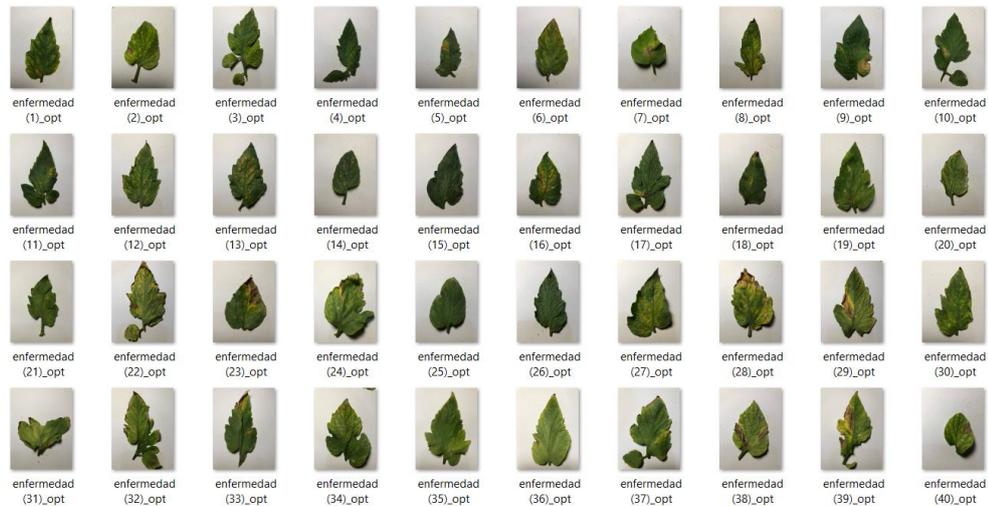


Figura 53. Dataset de la enfermedad

Fuente: Desarrollo del proyecto

4. Configuración de archivos: Para tener un correcto procedimiento se necesita tres archivos los cuales son: weight, cfg y classes. El primer archivo contiene los pesos del modelo entrenado, aquí está el núcleo del algoritmo de detección; dentro del archivo .cfg se especifican los parámetros de la red convolucional y, finalmente, el archivo classes donde se ubicarán las etiquetas de las posibles detecciones. En este proyecto se tiene la clase “enferma”.
5. El proceso de detección inicia con los datos de entrada adquiridos que son enviados de la plataforma web, con esos datos de predicción establecidos en 5s son procesados en la red de pre-entrenada donde tomará los valores de acuerdo al entrenamiento, entonces entra una condicionante, donde si detecta establece la posición de la plaga, luego nos da el cuadro delimitador que nos dará la precisión de acuerdo con los valores de la detección, luego envía estos datos a la base de datos y vuelve a reanudar el proceso, sin embargo si no detecta la plaga vuelve a la etapa de la adquisición del video e inicia de nuevo la consulta, como se evidencia en la figura 54.

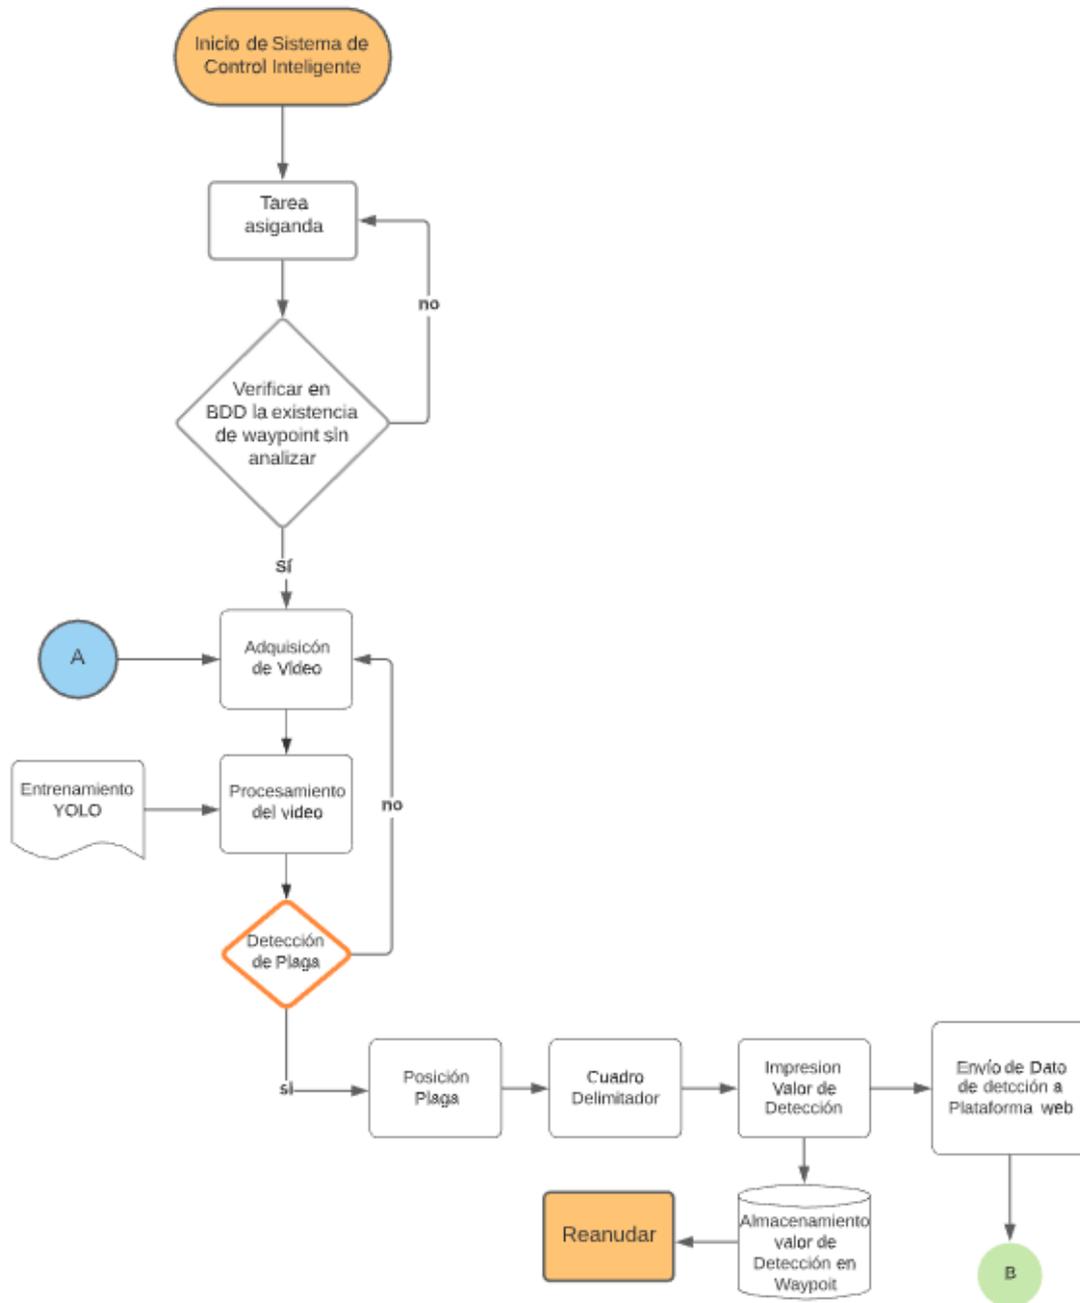


Figura 54. Diagrama de fases del modelo de entrenamiento.

Fuente: Desarrollo del proyecto

4.1.8. Proceso de Entrenamiento

El modelo de detección de la enfermedad hace referencia a tres escalas del objeto a encontrar para tener mejor eficiencia en base a la reutilización y representación de características que son propuestas, de este modo mejora los procesos de detección como se muestra en la figura 55.

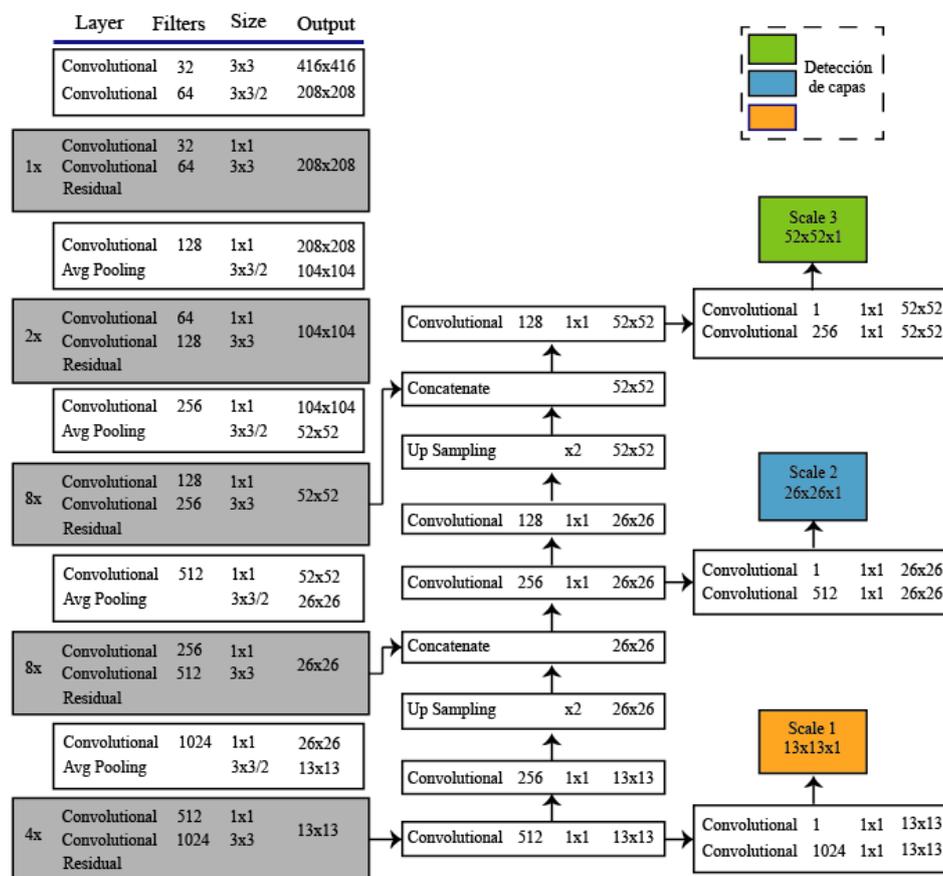


Figura 55. Modelo propuesto de la arquitectura densa

Fuente: Desarrollo del proyecto

Como primera instancia se modifica los datos de entrada mediante los archivos de pesos y configuración que son cargados previamente entrenados para disminuir el proceso de identificación de la plaga. Luego se prepara la entrada de la red, donde se convierte la imagen a un blob con la resolución para ser admitida por yolo:

- 320x320px. Menor precisión frente a mayor velocidad de procesamiento.
- 416x416px. Mejor relación precisión/velocidad de procesamiento.
- 609x609px. Mayor precisión frente a menor velocidad de procesamiento.

En relación con la opción adecuada del tamaño es importante asegurar la precisión para no perder de vista la enfermedad de tal forma utilizamos imágenes de 416x416px que generan mayor precisión al procesarlas en tiempo real y así generar el reporte al agricultor.

En este apartado se presenta las técnicas utilizadas para reducir el overfitting que se conocen como Data Augmentation, se trata de hacer una copia de las imágenes de entrada y modificar ciertas características entre estas se encuentran el tamaño o rotación de forma aleatoria y a su vez copias modificadas como nuevas muestras al conjunto de entrada. Sin embargo, una de las ventajas es el aumento de datos de entrada que son favorables en caso de datasets con pocos datos.

Otro factor es modificar las características de las imágenes de entrada como el brillo o rotación, tamaño, traslación, saturación, exposición, de tal forma están inmersos en el entrenamiento. Para determinar el valor óptimo se especifica el rango máximo en el que se realizarán ciertas características, donde la dinámica del funcionamiento del algoritmo aumentará o disminuirá aleatoriamente. Los parámetros de Data Augmentation utilizados son:

- batch=8: Indica que usará 8 imágenes para cada paso de entrenamiento.
- subdivisions=1: Muestra que el batch se dividirá por 1 para disminuir los requisitos de la GPU.

- width=416: Resolución de la imagen
- height=416: Resolución de la imagen
- channels=3: Canales de colores RGB.
- Momentum=0.9: Controla las fluctuaciones de los pesos entre interacciones.
- Decay=0.0005: Ajusta los pesos cuando son exagerados, en caso de que la red sobreaprenda.
- Angle= 0: Modifica el ángulo de la imagen aleatoria. En nuestro caso tenemos imágenes balanceadas que no requiere.
- Saturation=1.5: Modifica la saturación de la imagen dentro del rango [-1.5, 1.5].
- Exposure =1.5: Modifica la exposición de la imagen dentro del rango [-1.5, 1.5].
- Hue =.1: Modifica el tono de la imagen en un rango 0.1.
- Learning rate= 0.001: la tasa de aprendizaje para controlar la agresividad en el aprendizaje.
- burn_in=1000: El proceso inicia en 1000.
- steps=400000,450000: Cuando pase por la iteración 400000 comenzará a multiplicarse por 0.1 y la iteración 450000 volverá a repetirse este escalado.
- scales=.1.1: valor del escalado para comenzar a balancear el entrenamiento.

El modelo de entrenamiento luego de configurar los parámetros de acuerdo con nuestras necesidades. En ese sentido, se modifica el parámetro $classes = 1$, y el número de filtros de acuerdo con la ecuación 1. donde se consigue un valor de 18.

$$filtros = (numClases + 5) * 3 \quad \text{Ec 1.}$$

Para el entrenamiento se realizó a través de google colab con la tarjeta gráfica TESLA T4 que permite realizar entrenamientos y procesamientos de imágenes rápido que las tarjetas de un computador normal, esta herramienta es muy utilizada ya que un procesamiento de imagen o entrenamiento puede durar aproximadamente 16 horas mientras que con esta ayuda se podrá realizar el entrenamiento en un tiempo promedio de 3 a 5 horas, en efecto este procedimiento se encuentra en el anexo 5.

4.1.9. Validación

Luego de haber finalizado el entrenamiento, se procede a realizar una validación de los resultados con diferentes interacciones. En nuestro primer caso se identifica la enfermedad *Phytophthora infestans* en una hoja, se muestra en la figura 56. Este apartado está en relación con ambientes ideales, es decir que puede producir ciertos cambios de las condiciones como iluminación, presencia de neblina y lluvia acordes con el anexo 7 del script de validación.



Figura 56. Identificación de la enfermedad

Fuente: Desarrollo del proyecto.

4.1.10. Grados de severidad de phytophthora infestans

Para determinar el grado de severidad se hace referencia a 4 estratos como se muestra en la tabla 26 y se ajusta a las condiciones de trabajo para evaluar el grado de área afectada en la hoja por *P. infestans*.

Tabla 26. Escala para evaluar el grado de severidad de *P. infestans*. en tomate.

Grado de Severidad	% de enfermedad	Síntomas	Evidencia
I	0.0-0.5	Sin síntoma de enfermedad	
II	0.50-0.60	Muy pocos síntomas de enfermedad.	
III	0.60-0.70	Hasta la mitad del follaje presenta algún síntoma de enfermedad.	
IV	Mayor a 0.70	Todo el follaje con síntomas de enfermedad.	

Nota: Se presenta los grados de severidad de *P. infestans*. **Fuente:**(Lara, 2009)

4.1.11. Métricas de eficiencia

Con respecto a la eficiencia de nuestro sistema se define la matriz de confusión que es una herramienta de visualización donde los resultados verdaderos positivos son las clases detectadas de forma correcta, y los falsos positivos son en relación con los objetos que no forman parte del entrenamiento como se evidencia en la tabla 27.

Tabla 27. Matriz de Confusión

Valoración		Predicciones	
		Positivos	Negativos
Valor Real	Positivos	Verdaderos Positivos Marchito	Falsos Negativos Enfermo
	Negativos	Falsos Positivos Potencialmente enfermos	Verdaderos Negativos Saludable

Nota: Se presenta la estructura de la matriz de confusión. **Fuente:**(Electrónica et al., 2018)

4.1.11.1. *Exactitud (Accuracy)*

Mide específicamente el porcentaje de datos que son correctos, es decir la proporción entre el número de predicciones correctas y el total de predicciones como se muestra en la ecuación 2.

$$Exactitud = \frac{Verdaderos\ positivos + Verdaderos\ negativos}{Total} \quad Ec\ 2$$

4.1.11.2. *Precisión*

La precisión es un valor que define a los elementos seleccionados en los cuadros delimitadores son relevantes o exactos en su predicción. Para obtener este parámetro se divide el número de predicciones verdaderos positivos entre la suma de los verdaderos positivos y falsos positivos, se evidencia en la ecuación 3.

$$\text{Precisión} = \frac{\text{Verdadero Positivo}}{\text{Verdadero Positivo} + \text{Falso Positivo}} \quad \text{Ec 3}$$

4.1.11.3. Sensibilidad

Este parámetro de evaluación mide la fracción de ejemplos positivos que están correctamente etiquetados, donde su valor más alto es 1 y el bajo 0. Se calcula al dividir el número de predicciones verdaderas positivas entre la suma de las predicciones verdaderas positivas y las falsas negativas definida en la ecuación 4.

$$\text{Sensibilidad} = \frac{\text{Verdadero Positivo}}{\text{Verdadero Positivo} + \text{Falso Negativo}} \quad \text{Ec 4}$$

4.1.11.4. Tiempo de respuesta

El tiempo de respuesta se considera para escenarios en tiempo real donde corresponde al tiempo de ejecución desde que se ingresa hasta que se obtiene la imagen de salida detectada, como se muestra en la ecuación 10.

$$t = t_{fin} - t_{inicio} \quad \text{Ec 5}$$

4.1.12. Integración del sistema

Finalmente, se obtiene el proceso general de todo el proyecto como se visualiza en la figura 57, donde inicia con la planificación del vuelo de cada waypoint con los parámetros correspondientes como son: velocidad, altura, tiempo de vuelo, locación, pausa, captura de video, luego se procede a definir la trayectoria poligonal o rectangular en referencia a la superficie del terreno de estudio. Los datos de telemetría de cada waypoint son almacenados en la base de datos en el sistema de la plataforma web mediante un archivo .csv, previo a esto se registra los datos del usuario, para guardar la información del estado del análisis.

El vuelo autónomo se realiza de acuerdo con las condiciones correctas, en base a parámetros del plan de vuelo definidos en la sección 4.1.2, de esta forma los datos de predicción son cargados a la plataforma web de manera manual. Además, para el procedimiento del modelo de entrenamiento, los datos son administrados de acuerdo con las tareas que se generan en el modelo de entrenamiento, al ejecutarse en conjunto con los archivos tanto de pesos como de configuración previamente pre-entrenados, se consigue la detección de la enfermedad *phytophthora infestans* mediante 60 interacciones donde el valor de confianza o precisión del sistema mayor a 0.5, y generar así un promedio de cada uno de los 70 waypoints estratégicos que se van a analizar.

Finalmente, los resultados del proyecto se los evidencia al concluir todas las muestras, para señalar los datos en la plataforma web se genera un menú de inicio, proyecto, reporte y recursos; respecto a su funcionalidad integra la seguridad mediante autenticación de usuario donde permite recrear los datos obtenidos, concretamente en la pestaña de proyecto no indica en el mapa los waypoints definidos con los datos de locación y detección. El resultado del vuelo está en un diagrama de pastel que identifica los porcentajes de cada estado, de acuerdo con la matriz de confusión, sin embargo, para abstraer de una manera concisa los valores se muestran en un mapa con cada waypoint estratégico con el color verde (sano), marrón (enfermo), naranja (potencialmente enfermo), rojo (marchito) y la etiqueta correspondiente, de este modo se examina las métricas de eficiencia y algunas de las pruebas que son implementadas dentro del proceso.

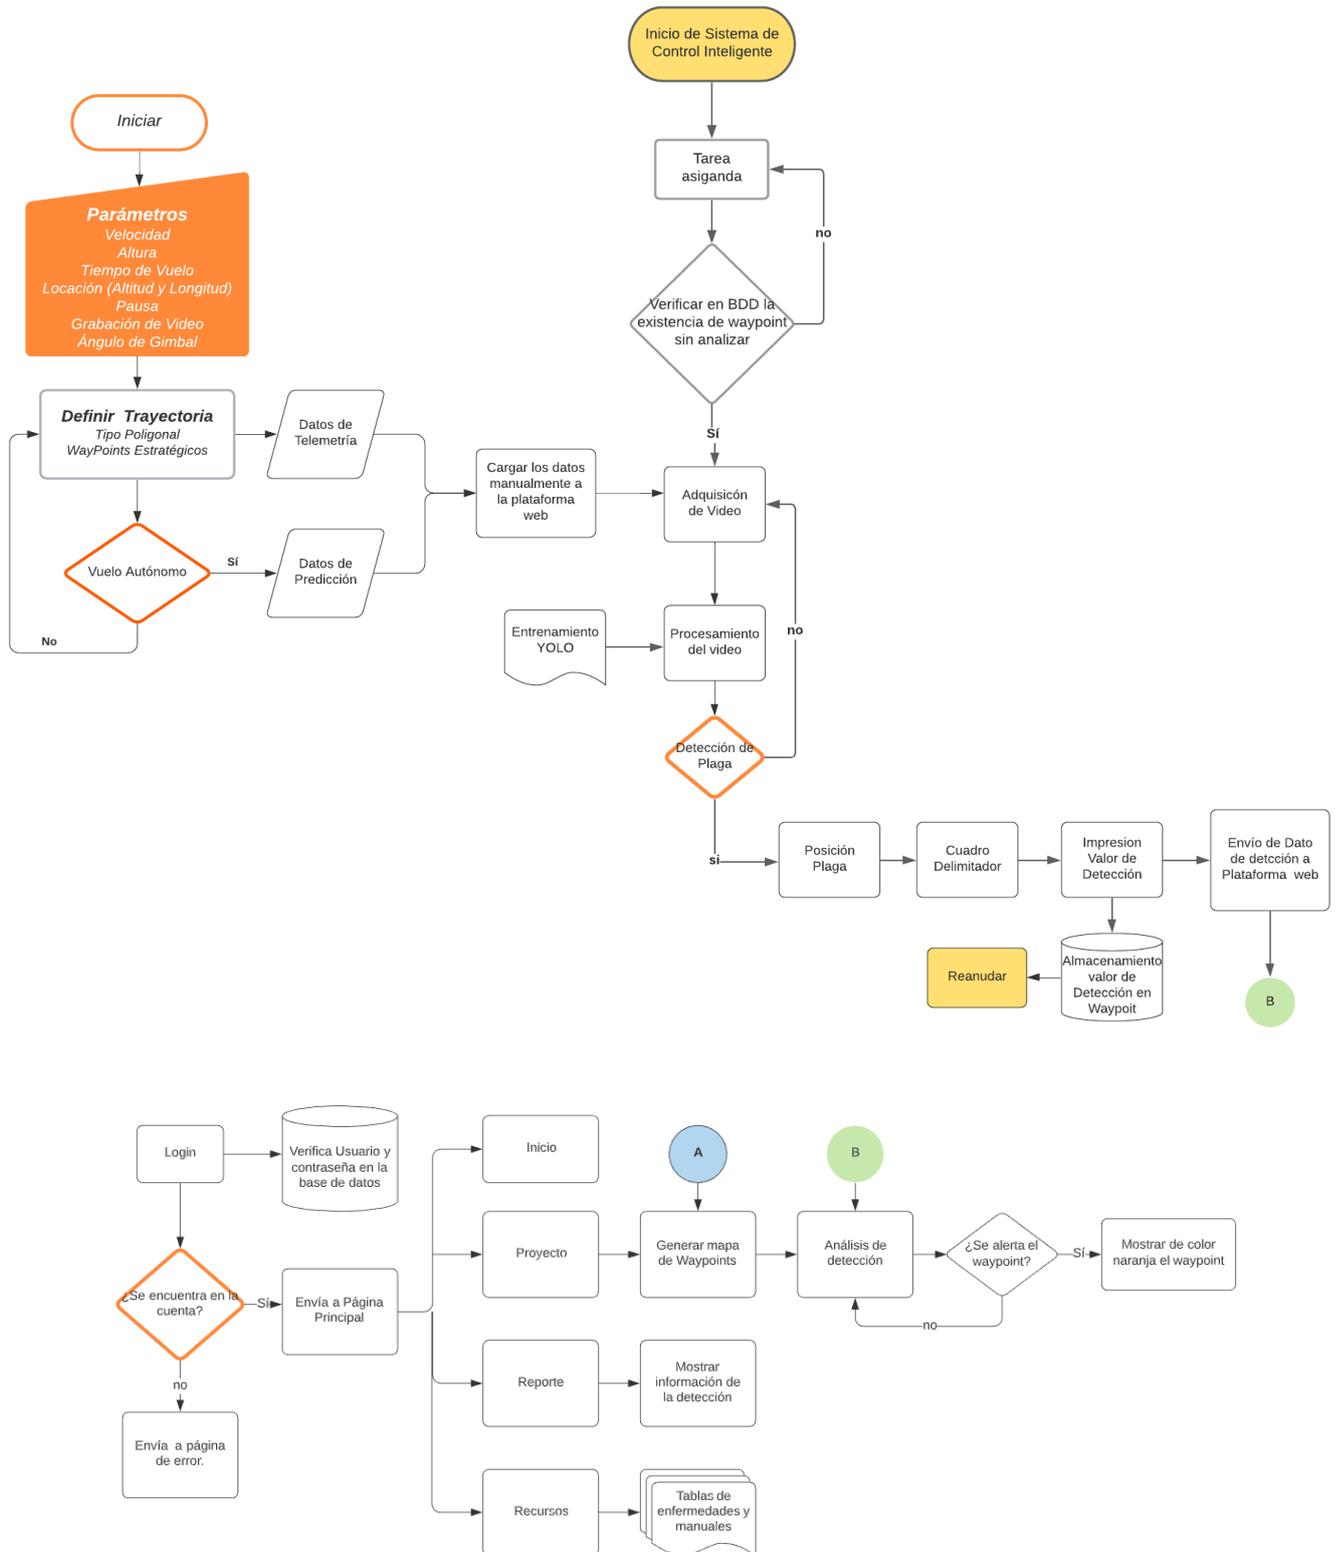


Figura 57. Diagrama de flujo global del proyecto

Fuente: Desarrollo del proyecto.

5. CAPITULO V: ANÁLISIS E INTERPRETACIÓN DE RESULTADOS

Este capítulo se muestra los resultados de la red CNN entrenada y validada, donde se comprueba la eficacia del sistema de visión artificial mediante una plataforma para aquello se usa un drone para identificar la enfermedad lanchara (*Phytophthora infestans*) en campos agrícolas de tomate riñón, además se integra un análisis cualitativo y cuantitativo.

5.1. Resultados

En el capítulo anterior se describe los resultados de la detección de la enfermedad de una imagen real, además se integra los resultados de tiempo de respuesta y la precisión del cuadro delimitador.

5.1.1. Resultados de entrenamiento

El resultado de nuestro entrenamiento de la red neuronal convolucional, el cual se encuentra en el anexo 5, se genera el modelo entrenado. La salida de este proceso es un archivo con extensión `.weights`, el que contiene los pesos de la red y las directrices de aprendizaje, además el `.cfg` donde está la configuración para proceder a validar como se evidencia en la figura 58.

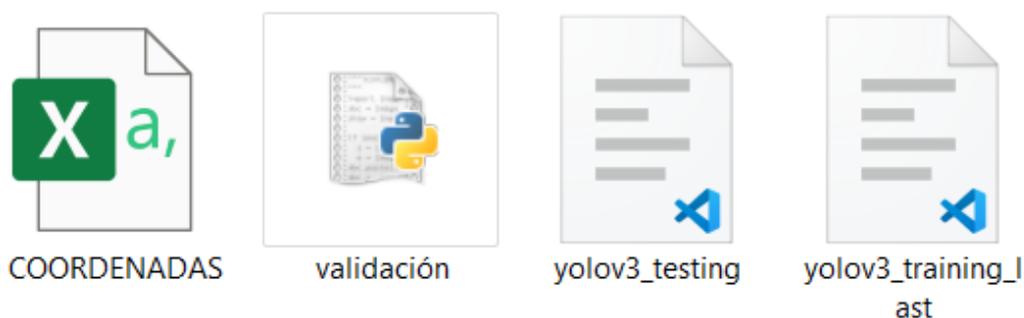


Figura 58. Métodos Entrenados

Fuente: Desarrollo del proyecto

5.1.2. Resultados de Validación

Para tener casos válidos con muestras de predicción obtenidas en cada waypoint al realizar las pruebas en el campo, se obtuvo algunos resultados que se validan de acuerdo con la discriminación de los falsos positivos, en ese sentido se observa en la figura 59 la dinámica de nuestro detector.



Figura 59. Identificación de la enfermedad de cada waypoint

Fuente: Desarrollo del proyecto.

5.2.Eficiencia del sistema

Para verificar la eficiencia del sistema de visión artificial para el reconocimiento de la enfermedad *phytophthora infestans*, se emplea el análisis de manera cualitativa y cuantitativa mediante las métricas que son referidas en el apartado 4.1.11. Se toma los datos de predicción de los 70 waypoints estratégicos definidos en la sección 4.1.2.1.2. del capítulo IV con los parámetros esenciales que a partir de diferentes pruebas realizan la adquisición

de los datos, de tal forma estas muestras se utilizan en el entrenamiento de la red neuronal convolucional YoloV3, en ese contexto, para optimizar la respuesta del resultado transmitido hacia la plataforma web se incluye la utilización de los recursos de la plataforma de almacenamiento en la nube.

5.2.1. Análisis cualitativo

Para realizar un análisis cualitativo de las muestras se hace énfasis en las tablas de verificación de los requerimientos del anexo 5, y constituir un proceso para la creación de escenarios de acuerdo con el cumplimiento del sistema para mejorar la eficacia, eficiencia y calidad. Sin embargo, las pautas que señalan estas pruebas permiten el desarrollo de los puntos fuertes de ejecución del sistema para comparar y obtener un resultado real en función de requerimientos de *stakeholders*, diseño y arquitectura, consecuentemente se muestran en las diferentes tablas.

5.2.1.1. Escenario A

La primera situación en estado óptimo, donde se consigue las muestras de los waypoints estratégicos una hora después de la salida/puesta del sol, donde se muestra la luz blanca de 3000k-4000k, que permite un mayor enfoque de los videos. (Bustos Araya, 2017) Por otro lado, se considera los parámetros de adquisición en relación con la altura de 3,8m para evitar obstáculos del cultivo y tener un mayor grado de visualización debido al obturador del zoom de 24mm-48mm (DJI, 2018) sin la existencia de un desenfoque, además cada muestra se etiqueta para su posterior análisis.

A continuación, en la figura 60 se observa el mapa que contiene 70 waypoints estratégicos con indicadores de color, de acuerdo con el grado de severidad que se encuentra en la sección 4.1.10. del capítulo IV, siendo el grado III y IV de mayor afección, que

corresponde al 71% del cultivo, por consiguiente, se debe tomar medidas de control inmediatas para evitar que la producción sea afectada en su mayoría, además se recomienda realizar técnicas de aporques, saneamiento periódico y aplicar potentes fungicidas de mayor eficacia para favorecer un manejo integrado y recuperar las partes afectadas.

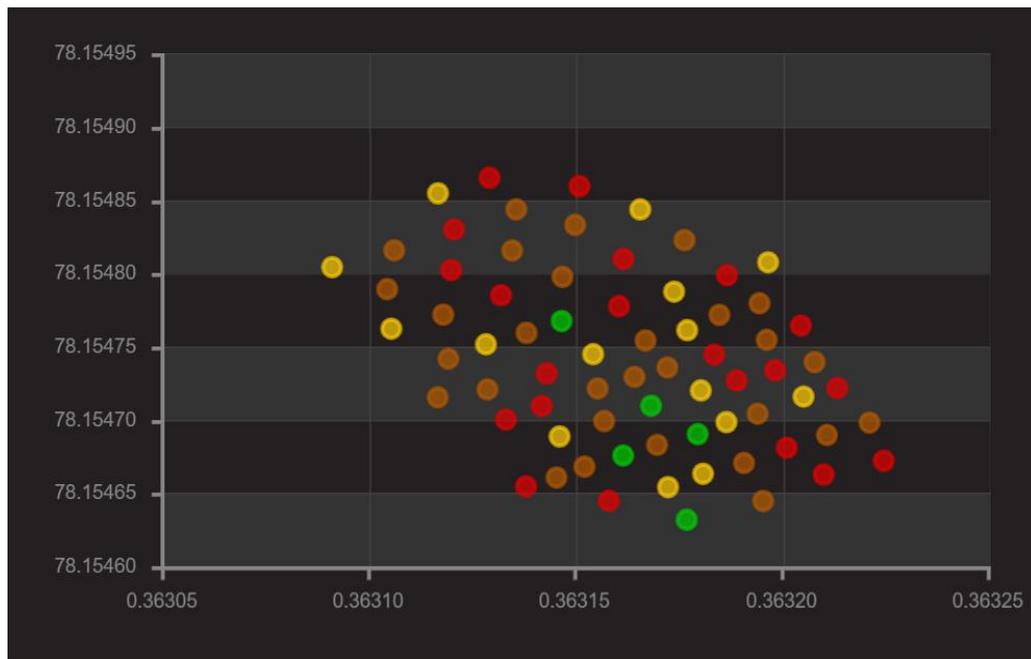


Figura 60. Mapa estratégico del escenario A.

Fuente: Desarrollo del proyecto.

En relación con los resultados del mapa en la figura 61 se identifica los porcentajes del grado de severidad, donde se expresa que el 41% está enfermo, marchito el 30%, potencialmente enfermo el 21% y sano el 7%. De tal forma que el estado enfermo predomina en esta toma de muestras.

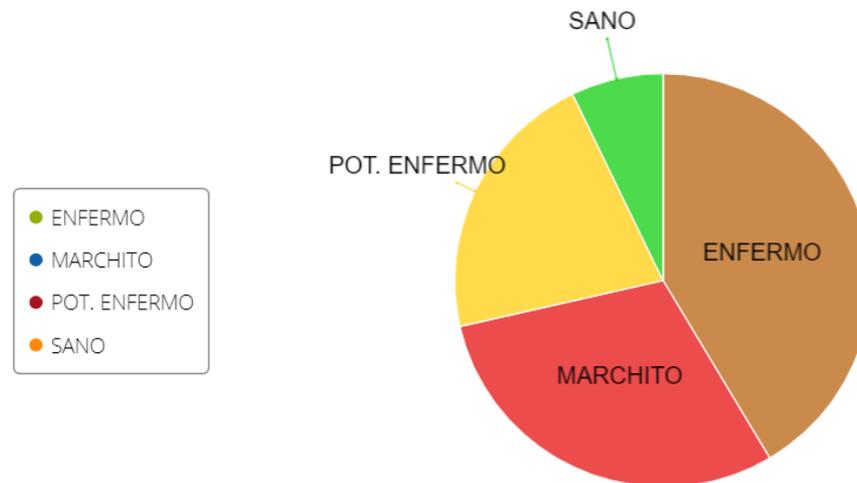


Figura 61. Niveles de grado de afección del escenario A

Fuente: Desarrollo del proyecto.

5.2.1.2. Escenario B

De acuerdo con el escenario A, existe una relación con el enfoque y apreciación del sistema donde se plantea pruebas en diferentes horas del día, se considera la luminosidad un factor crucial, que hace referencia una hora después de la salida/puesta del sol en estado óptimo, se obtiene las muestras de 7:00-8:00, luego de 12:00 a 13:00 y en la tarde de 17:00 a 18:00, a una altura de 3.8m y cada dato de predicción con un período de 5s.

Posteriormente, en la figura 62 se muestra el mapa que contiene 70 waypoints estratégicos con indicadores de color, de acuerdo con el grado de severidad, se conoce que el grado III y IV es de mayor afección, que corresponde al 86% del cultivo, en consecuencia, existe una menor parte saludable que identifica el cultivo en estado de deterioro. Por lo tanto, el sistema identifica un mayor grado de afección en el cultivo por la exposición al sol, sin embargo, se debe tomar medidas de control inmediatas para evitar pérdidas económicas.

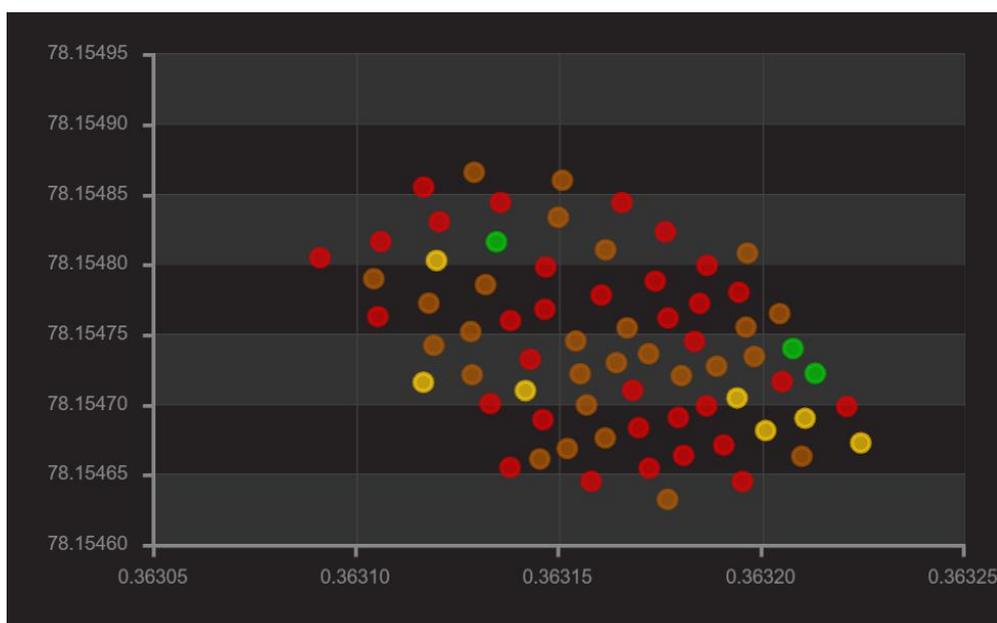


Figura 62. Mapa estratégico del escenario B de 12:00 a 13:00

Fuente: Desarrollo del proyecto.

Acorde con los resultados del mapa en la figura 63 se identifica los porcentajes del grado de severidad, donde se expresa que el 47% está marchito, enfermo el 39%, potencialmente enfermo el 10% y sano el 4%. Ciertamente el mayor grado está en estado marchito del total del cultivo.

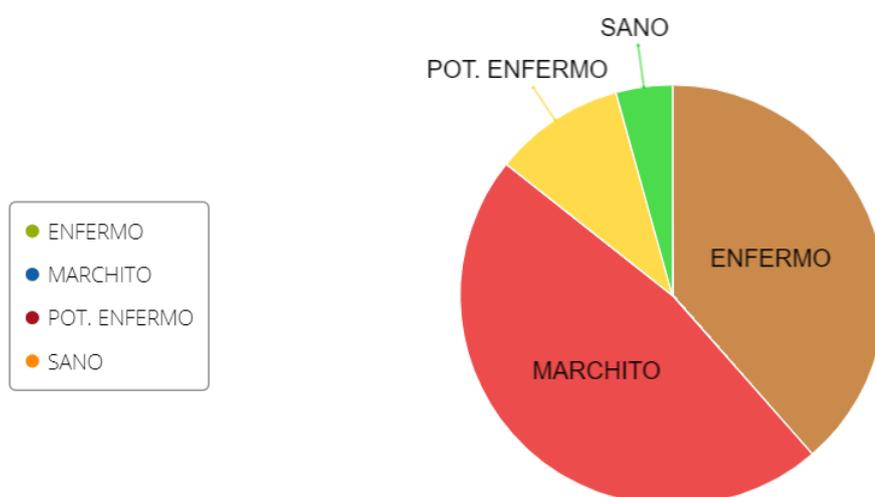


Figura 63. Niveles de grado de afección del escenario B de 12:00 a 13:00

Fuente: Desarrollo del proyecto.

En efecto, en la figura 64 se evidencia el mapa que contiene 70 waypoints estratégicos con indicadores de color, de acuerdo con el grado de severidad, se conoce que el grado I y II es de menor afección, que corresponde al 56% del cultivo, por esta razón, existe una mayor parte saludable que identifica el cultivo en estado adecuado. De tal forma, el sistema identifica un menor grado de afección en el cultivo por la baja exposición al sol, además, se debe practicar medidas preventivas para evitar una propagación de la enfermedad.

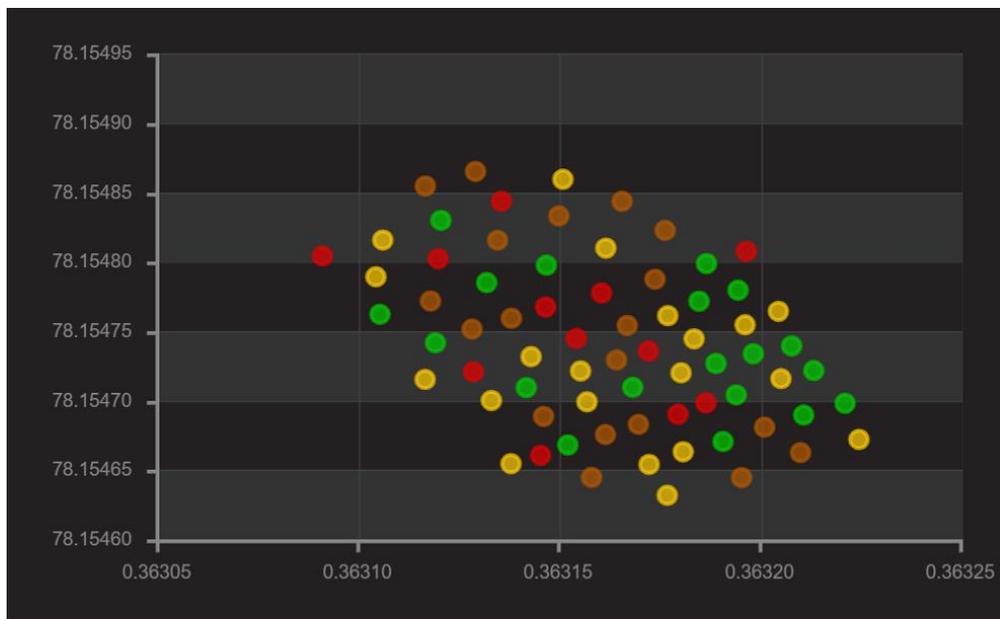


Figura 64. Mapa estratégico del escenario B de 17:00 a 18:00.

Fuente: Desarrollo del proyecto.

Por otro lado, los resultados del mapa en la figura 64 se denotan los porcentajes del grado de severidad, donde se expresa que el 27% está sano, potencialmente enfermo el 29%, enfermo el 27% y marchito el 17%. Ciertamente el mayor grado está en estado potencialmente enfermo del total del cultivo.

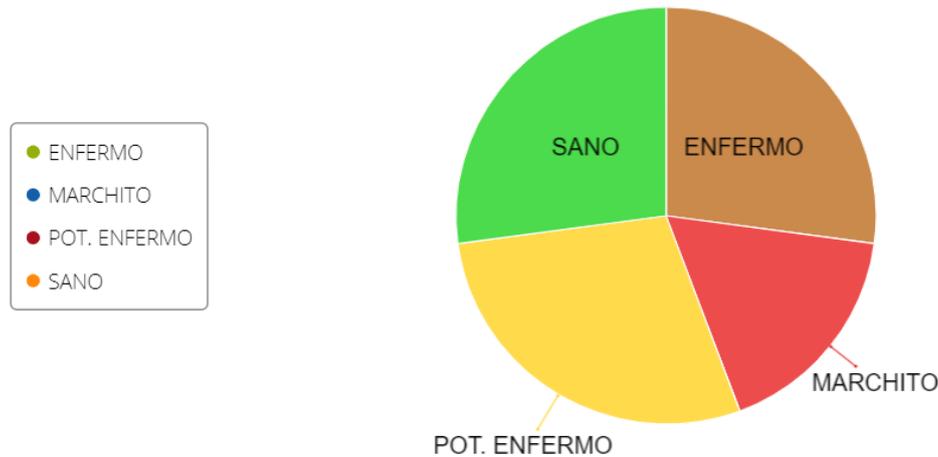


Figura 65. Niveles de grado de afección del escenario B de 17:00 a 18:00.

Fuente: Desarrollo del proyecto.

5.2.1.3. Escenario C

Determinar la altura idónea es un proceso por el cual se identifica la precisión del sistema, define la prueba que se requiera en función de las prestaciones del hardware en relación con el zoom óptico. Por este motivo se plantea varias pruebas como: altura normal de 3.8m en cuanto a la estructura del tutoreo, luego a una altura de 5m y finalmente abarcar una mayor cantidad del cultivo con 5m. Es preciso denotar el enfoque de la cámara del dron en vista que el sistema tenga dificultades para identificar la enfermedad.

En particular, en la figura 66 se muestra el mapa que contiene 70 waypoints estratégicos con indicadores de color, de acuerdo con el grado de severidad, se conoce el grado III y IV de mayor afección, que corresponde al 71% del cultivo, por lo expuesto, existe una mayor parte que se identifica en el cultivo en estado deteriorado. Es preciso validar que al tener una mayor distancia existe confusión en la detección de la enfermedad.

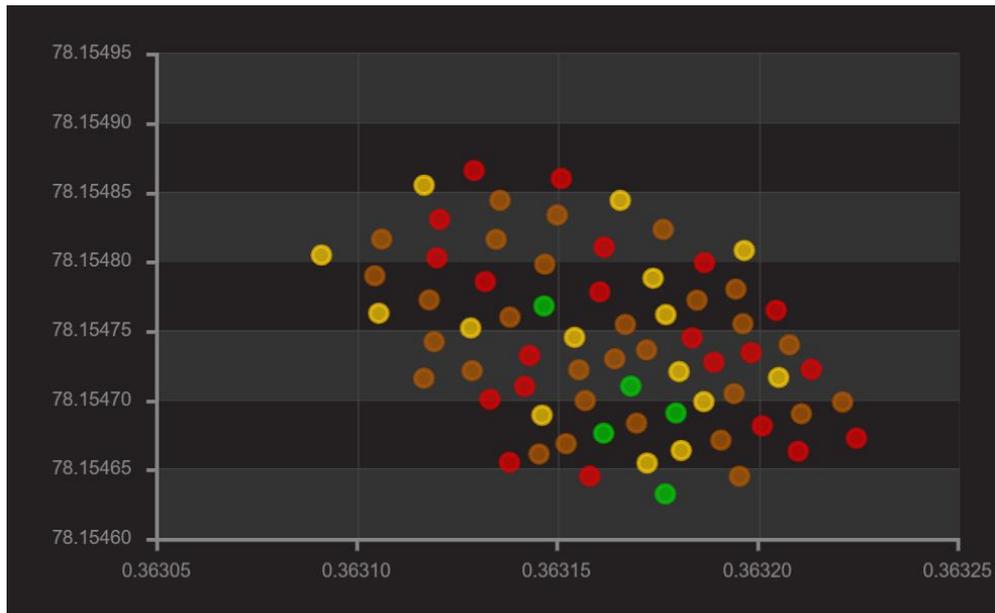


Figura 66. Mapa estratégico del escenario C a 5m de altura.

Fuente: Desarrollo del proyecto.

Los resultados de esta prueba de la figura 67 se muestra los porcentajes del grado de severidad, donde se expresa que el 41% está enfermo, marchito el 30%, potencialmente enfermo el 21% y sano el 7%. De tal forma que el estado enfermo predomina en esta toma de muestras.

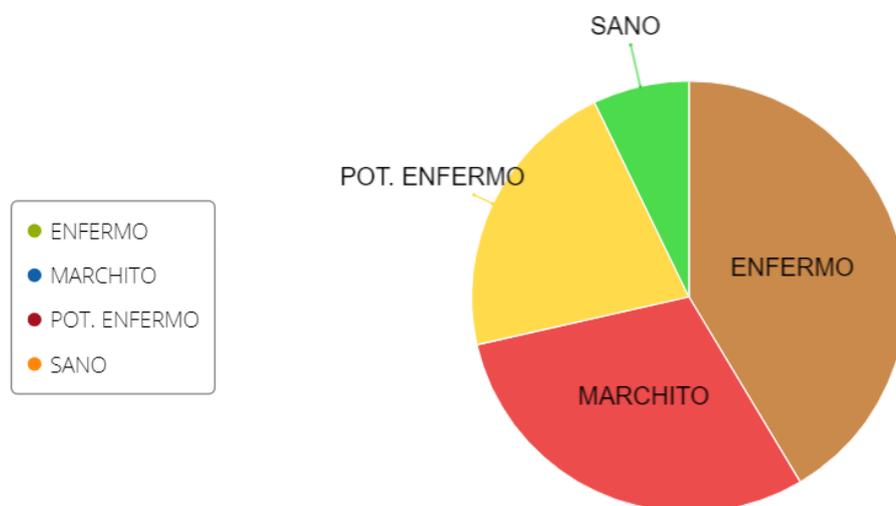


Figura 67. Niveles de grado de afectación del escenario C a 5m de altura.

Fuente: Desarrollo del proyecto.

Se puede apreciar en la figura 68 el mapa que contiene 70 waypoints estratégicos con indicadores de color, de acuerdo con el grado de severidad, se determina el grado I de mayor afección, que corresponde al 36% del cultivo, por lo expuesto, existe una mayor parte que se identifica en el cultivo en estado adecuado. Por tal razón, a 5m de altura existe una mayor parte saludable donde las muestras de predicción no dejan percibir las manchas en las hojas y así generar varios falsos negativos. Sin embargo, el grado de severidad IV no tiene mayor incidencia que cause falsas interpretaciones para informar al agricultor.

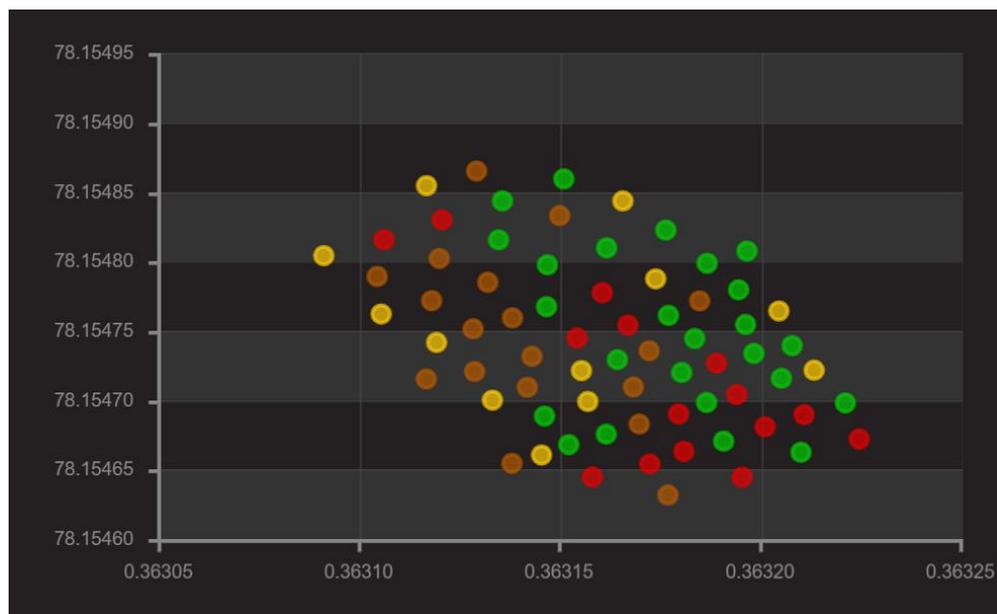


Figura 68. Mapa estratégico del escenario C a 6m de altura.

Fuente: Desarrollo del proyecto.

En el momento de cuantificar los resultados del mapa en la figura 69 se muestran los porcentajes del grado de severidad, donde se expresa que el 36% está sano, potencialmente enfermo el 17%, enfermo el 26% y marchito el 21%. En consecuencia, el mayor grado está en estado saludable del total del cultivo que resulta eficiente, pero no interpreta como manchas con mayor zona de afección de la enfermedad por desenfoque.

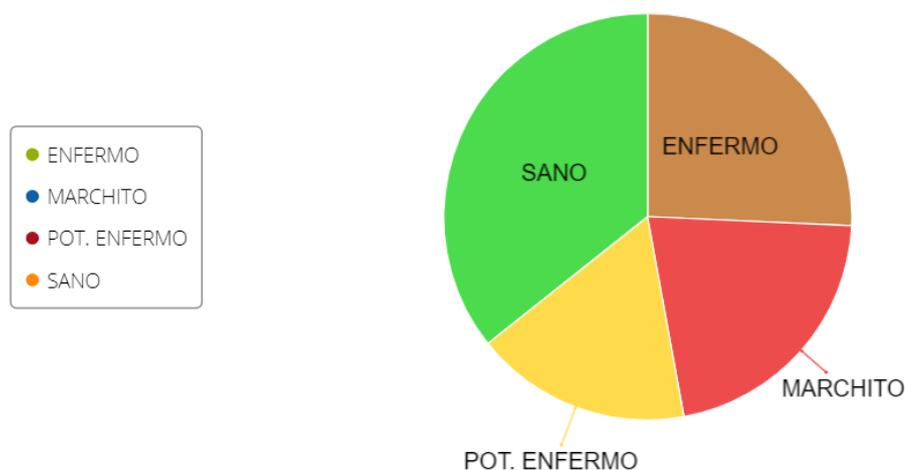


Figura 69. Niveles de grado de afección del escenario C a 6m de altura.

Fuente: Desarrollo del proyecto.

5.2.2. Análisis cuantitativo

El resultado se expresa en cada uno de los escenarios de acuerdo con sus parámetros mediante la matriz de confusión para conseguir los verdaderos positivos (VP), verdaderos negativos (VN), falsos positivos (FP), falsos negativos (FN), precisión (Pr), recall o sensibilidad (Rec), Exactitud (Exact) y tiempo de respuesta (Ts) de cada una de las muestras de predicción mediante el sistema que engloba en la tabla 28.

Tabla 28. Análisis cuantitativo de los escenarios.

Escenario	Descripción	Métricas							
		VP	VN	FP	FN	Pr	Rec	Exac	T (s)
A	6:00-7:00;3.8m	21	5	15	29	0.58	0.42	0.37	1776
	6:00-7:00;3.8m	21	5	15	29	0.58	0.42	0.37	1776
B	12:00-13:00;3.8m	33	3	7	27	0.82	0.55	0.51	3468
	17:00-18:00;3.8m	12	19	20	19	0.38	0.39	0.44	3581
C	6:00-7:00;3.8m	21	5	15	29	0.58	0.42	0.37	1776
	6:00-7:00;5m	15	25	12	18	0.56	0.45	0.57	4697
	6:00-7:00;6m	21	5	15	29	0.58	0.42	0.37	4159

Nota: Se presenta un análisis cuantitativo de los diferentes escenarios. **Fuente:** Desarrollo del proyecto.

En función de las métricas medidas en la validación se obtiene un valor mayor de verdaderos positivos y falsos negativos para los escenarios A, dando lugar al sistema ser capaz de conseguir detecciones correctas, por tal razón, la existencia de 21 verdaderos negativos y 29 falsos positivos con relación a los escenarios B y C, por tal razón el procesamiento es en menor tiempo de respuesta y así conseguir una mejor optimización del sistema.

El escenario B denota una mayor afección de la enfermedad en la prueba de 12:00 a 13:00 con mayor precisión, esto resulta por la sombra que genera los datos de predicción por lo que el sistema identifica como mancha y por lo tanto se obtiene un mayor grado de verdaderos positivos. Sin embargo, de 17:00 a 18:00 tiene una menor precisión por la presencia de ráfagas de viento existentes en la zona, de tal forma se consigue menor cantidad de verdaderos positivos.

Dentro de la validación del sistema hace uso del escenario C en función de diferentes alturas, donde se expresa que a una altura de 5m existe una mayor cantidad de verdaderos negativos por la presencia de desenfoque, en relación con las prestaciones del hardware, además, a una altura de 6m contiene datos de predicción con pérdida de visibilidad en el cultivo, al ser así, genera un mayor tiempo de respuesta.

5.2.3. Gráfica Precisión-Recall

Para expresar los resultados obtenidos de precisión frente a sensibilidad se visualiza en la figura 70.

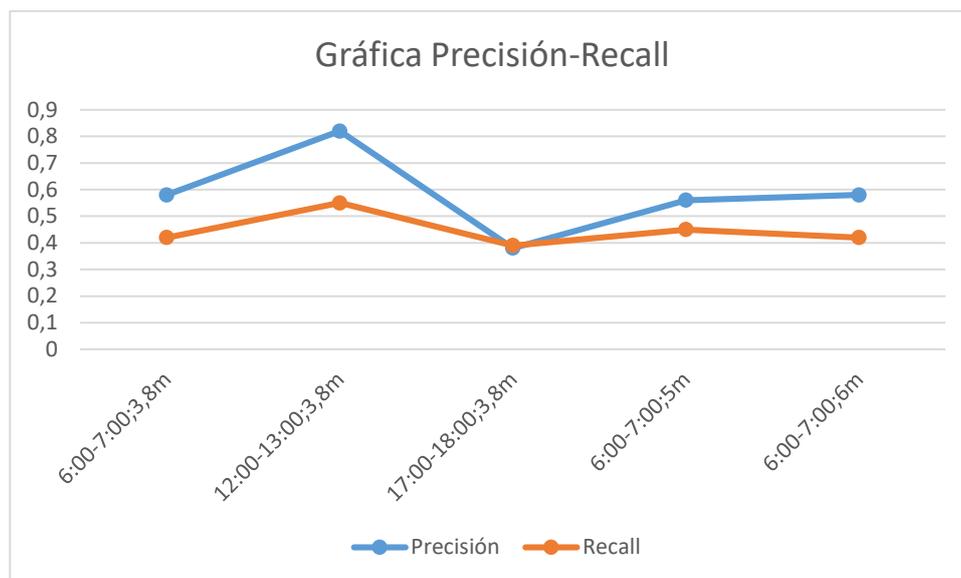


Figura 70. Gráfica de Precisión-Sensibilidad

Fuente: Desarrollo del proyecto.

Dentro del comportamiento de la precisión en base a la sensibilidad, se observa que la precisión es alta y la sensibilidad es bajo, por tal razón, el modelo no detecta la clase muy bien, pero cuando lo hace es altamente confiable. En tal virtud en el análisis de nuestros datos la sensibilidad indica la capacidad del estimador para discriminar los casos positivos. El resultado del diseño en base a la precisión y sensibilidad equilibrada se llega a tener una precisión entre 58% a 85% con sensibilidad máxima de 55% en la identificación de la enfermedad.

El área que existe en cada caso bajo la curva de la gráfica precisión-sensibilidad, determina el valor precisión promedio. Cuando más se acerque este valor a 1, mayor será el rendimiento del diseño del sistema, sin embargo, en nuestro sistema se identifica que en las diferentes pruebas de los escenarios se logra un mejor desempeño, y consecuentemente presenta un rendimiento mayor al 50%.

6. CONCLUSIONES

- El sistema de visión artificial mediante una plataforma usando un drone logró la identificación y detección de la plaga (*phytophthora infestans*) para alertar al agricultor las zonas con mayor grado de incidencia en el cultivo y tomar medidas de control.
- La detección e identificación de la enfermedad *phytophthora infestans* en el cultivo mediante el sistema tiene una precisión del 58% en su grado óptimo en referencia a los escenarios B y C, donde existe mayor afección de grado III y IV del 71%, por esta causa se debe realizar un manejo integrado para prevenir el contagio de todo el cultivo.
- Las redes neuronales convolucionales permiten generar nuevas aplicaciones dentro de la innovación y tecnología, al realizar una revisión sistemática de la literatura se consigue una mayor precisión en el campo del reconocimiento y procesamiento de imágenes, de tal forma obtener resultados con mejores recursos computacionales.
- El estado del cultivo se evalúa de acuerdo con los parámetros del sistema, que permite extraer las condiciones óptimas del área de estudio mediante tablas de verificación de requerimientos y así se corrobora el planteamiento integral del esquema.
- La preparación de datos de detección se genera en cada waypoint estratégico una hora antes de la salida del sol con luz blanca, con ráfagas de viento menores a 35Km/h, además, un vuelo autónomo del dispositivo para cubrir zonas cercanas de 2 metros en el cultivo, de tal forma se establece configuraciones de un período de 5s, ángulo de inclinación de 90 grados y la altura de acuerdo con el tutoreo para obtener

muestras de predicción y telemetría con mayores prestaciones de enfoque, precisión y calidad.

- Dentro del dataset existen muestras extraídas que oscilan en un rango de especificaciones expuestas de 1 a 1000 fotografías que son etiquetadas para formar un conjunto de datos útil para nuestro sistema de detección debido a que contiene la información de las características de la enfermedad, es decir su estructura, forma y color, lo cual permite enfocarnos al objetivo de nuestro proyecto.
- La capacidad de extraer las características de las muestras de entrada con un blob de 416x416 con una mejor relación de precisión y velocidad de procesamiento, se consigue como resultado reducir el overfitting y a su vez controlar la tasa de aprendizaje.
- El tiempo de inferencia en referencia a las predicciones de la red neuronal convolucional YoloV3 es menor que otras redes, capaz de lograr una mayor precisión.
- El tiempo de ejecución del esquema de entrenamiento es de 7 horas mediante la tarjeta gráfica TESLA T4 de google colab que permite realizar entrenamientos y procesamientos de imágenes más rápido que las tarjetas de un computador normal, y así determinar el objetivo de la detección mediante la red neuronal convolucional YoloV3 y Darknet-53, en relación con los datos de predicción es de alta calidad por lo tanto consume mayores recursos.

- Cabe aclarar que al presentar las pruebas con mayor altura ocasiona distorsiones, donde el sistema interpreta zonas de mayor incidencia de estado saludable por causa del desenfoque que se genera a mayor altura, esto asegura que la altura ideal es 3.8m en consideración de la estructura del tutorio por tal razón mejora la identificación de las manchas en las hojas.
- Dentro del escenario B en relación con la luminosidad se determina que el período óptimo para las pruebas es de 7:00-8:00 de la mañana, porque existe menor presencia de luz solar y así, el sistema no la detecta como enfermedad, sin embargo, en las otras pruebas existe confusión y nos devuelve falsos positivos debido a las manchas solares por la sombra.
- El tiempo de respuesta de nuestro escenario en condiciones idóneas es de 1772 segundos de esta manera genera una mayor cantidad de verdaderos positivos que son aceptables en relación con las métricas de precisión y sensibilidad.

7. RECOMENDACIONES

- Se debe realizar la trayectoria del mapeo del drone en un espacio abierto, el cual permitirá que el proyecto se realice de una manera óptima para llevar a cabo la adquisición de las muestras idealmente, consecuentemente el drone podrá realizar el vuelo en menor tiempo.
- Para el manejo del software del manejo del drone se recomienda realizar pruebas de vuelo para conseguir una mejor apreciación de los datos y mayor efectividad.

- Las circunstancias que presenta la búsqueda, análisis y estudio del dataset se debe estar seguro de que contenga las prestaciones para saber la enfermedad phytophthora infestans.
- Al momento de realizar la programación de la plataforma web tener estructurado el esquema de funcionamiento y además, hacerlo de manera organizada para evitar contratiempos.
- Es recomendable llevar un estudio profundo de la estructura y funcionamiento de las redes neuronales convolucionales en cada capa para poder optimizar el modelo mediante el ajuste de los pesos.
- Se recomienda tener mejores prestaciones tanto de RAM y procesador en la implementación del modelo de entrenamiento para que el sistema sea eficiente.
- Es favorable obtener un gran número de datos para el entrenamiento de la red, para que el aprendizaje sea más preciso de tal forma balancear las características de las muestras y sus pesos.

8. BIBLIOGRAFÍA

- Acuña, A. (2019). *Visión artificial aplicada a la detección e identificación de personas en tiempo real*. Escuela Politécnica Nacional.
- Agrocalidad. (2015). *Guía De Buenas Prácticas Agrícolas Para Tomate Riñón*. 80. <http://www.agrocalidad.gob.ec/wp-content/uploads/2016/07/guia-tomate-rinon-final.pdf>
- Aguirre, H. (2019). *DESARROLLO Y ANÁLISIS DE SISTEMAS DE ESTIMACIÓN Y DETECCIÓN DE OBJETIVOS DE RADAR MEDIANTE ALGORITMOS DE MACHINE Y DEEP LEARNING*. Universidad de las fuerzas armadas.
- Allende, M., Salinas, L., Rodríguez, F., Olivares, N., Riquelme, J., Antúñez, A., Martínez, J., Corradini, F., Sepúlveda, P., Abarca, P., Guzmán, A., & Felmer, S. (2017). Manual de cultivo del tomate bajo invernadero. *Boletín INIA*, 12, 112. <http://www.inia.cl/wp-content/uploads/ManualesdeProduccion/12 Manual de Tomate Invernadero.pdf>
- Barba, J. P., & Berenguer, F. (2013). *DISEÑO Y DESARROLLO WEB. Análisis de casos*. 39. https://riunet.upv.es/bitstream/handle/10251/49757/MEMORIA_Barba Soler%2C Juan Pedro.pdf?sequence=1
- Belmonte, P. (2014). Las tecnologías wifi y wimax. *Jornada Wifi*, 41. https://www.dip-badajoz.es/agenda/tablon/jornadaWIFI/doc/tecnologias_wifi_wmax.pdf
- BETANCOURT, G. A. (2005). *LAS MÁQUINAS DE SOPORTE VECTORIAL (SVMs)*. 27, 67–72. <https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=2&cad=rja&uact=8&ved=2ahUKEwj2v7Ly-OTIAhVyvFkKHe8zABoQFjABegQIBRAC&url=https%3A%2F%2Fdialnet.unirioja.es%2Fdescarga%2Farticulo%2F4838384.pdf&usg=AOvVaw3kfYiwmutArOwETXpNPv7i>
- Bongiovanni, R., Chartuni, E., Best, S., & Roel, Á. (2006). Agricultura de Presición: Integrando Conocimientos para una Agricultura Moderna y Sustentable. In *Ciencia y Tecnología* (Vol. 10).
- Borovkov, A. (2017). *Image Classification with Deep Learning*. UNIVERSITÄT HAMBURG.
- Bradford. (2015). *TEAR GASSING BY*. December.
- Bustos Araya, M. J. (2017). *Índice de Reproducción Cromática CRI para Fuentes de Luz*. 4.
- Canziani, A., Paszke, A., & Culurciello, E. (2016). *An Analysis of Deep Neural Network Models for Practical Applications*.
- Cardona, L., Castaño, J., & Ceballos, N. (2016). EPIDEMIOLOGÍA DEL TIZÓN TARDÍO (Phytophthora infestans (MONT.) DE BARY) EN QUINCE INTRODUCCIONES DE TOMATE SILVESTRE TT - EPIDEMIOLOGY OF LATE BLIGHT (Phytophthora infestans(MONT.) DE BARY) IN FIFTEEN INTRODUCTIOS OF WILD TOMATO. *Revista U.D.C.A Actualidad & Divulgación Científica*, 19(1), 45–54. http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0123-42262016000100006&lang=pt
- Carlos, J., & Pérez, M. (2018). *Aprendizaje supervisado para la detección de amenazas Web*.
- Casado García, Á., & Heras Vicente, J. (2017). *Guiando la creación de modelos de detección de objetos basados en deep learning*.

- Cha, Y.-J., Choi, W., & Buyukozturk, O. (2017). Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks. *Computer-Aided Civil and Infrastructure Engineering*, 32, 361–378. <https://doi.org/10.1111/mice.12263>
- Cicero, I. E. (2018). *Utilización de redes neuronales convolucionales para la detección de tipos de imágenes* [INSTITUTO TECNOLÓGICO DE BUENOS AIRES –ITBA]. https://ri.itba.edu.ar/bitstream/handle/123456789/1660/Trabajo_Especialización_Cicero.pdf?sequence=1&isAllowed=y
- Cong, J., & Xiao, B. (2014). Minimizing in Convolutional Neural Networks. *International Conference on Artificial Neural Networks*, 281–290.
- De-La-Hoz, E. J., De-La-Hoz, E. J., & Fontalvo, T. J. (2019). Metodología de Aprendizaje Automático para la Clasificación y Predicción de Usuarios en Ambientes Virtuales de Educación. *Información Tecnológica*, 30(1), 247–254. <https://doi.org/10.4067/s0718-07642019000100247>
- DJI. (2016). *Manual de Drone Agras MG-1*. 1–51.
- DJI. (2018). *Mavic 2 Pro / Zoom User Manual*. 1–69.
- Electrónica, C. D. E. I., Orlando, D., & Mogrovejo, R. (2018). *Desarrollo de un sistema de detección de armas de fuego cortas en el monitoreo de videos de cámaras de seguridad*. 1–63.
- Energy, R., Development, S., Independent Electricity System Operator, I., Republic of Malawi, Manual, C. C., RSA Grid Code Secretariat, Version, D., Eskom, NERSA, Olowu, T. O., Sundararajan, A., Moghaddami, M., Sarwat, A. I., Unigwe, O., Okekunle, D., Kiprakis, A., Latif, A., Gawlik, W., & Palensky, P. P. (2016). Table of Contents Table of Contents *نشر ني - تماش با ما*. *CIREC - Open Access Proceedings Journal*, 2017(July), 1–67. <https://doi.org/10.1049/oap-cired.2017.1227>
- Enyinna, C., Ijomah, W., Gachagan, A., & Marshall, S. (2018). *Activation Functions: Comparison of Trends in Practice and Research for Deep Learning*.
- García-Cambronero, C., & Gómez-Moreno, I. (2009). Algoritmos de aprendizaje: K-NN & K-Means. *Inteligencia En Redes de Telecomunicación*.
- García, A. B. S. (2018). Aplicación de Aprendizaje en la identificación de obstáculos en el trayecto de vehículos. In *Universidad Militar Nueva Granada*. <https://repository.unimilitar.edu.co/bitstream/handle/10654/17651/AlfonsoGarcíaBryanSteven2018.pdf?sequence=1&isAllowed=y>
- García, R. P. (2015). *CONTROL DE VIROSIS EN CULTIVOS DE TOMATE CHERRY : EVALUACIÓN*.
- Gonzalez Muñoz, A., & Díaz Blanco, I. (2018). *Aplicaciones de Técnicas de Inteligencia Artificial Basadas en Aprendizaje Profundo (deep learning) al Análisis y Mejora de la Eficiencia de Procesos Industriales*. February 2018, 75. <https://doi.org/10.13140/RG.2.2.15144.72967>
- Goyal, P., Pandey, S., & Jain, K. (2018). *Deep Learning for Natural Language Processing*. <https://doi.org/10.1007/978-1-4842-3685-7>
- Infoagro Systems S. L. (2016). *El cultivo del tomate. 1ª parte*. https://www.infoagro.com/documentos/el_cultivo_del_tomate__1__parte.asp
- INIA, R. M. (2014). *Nuevos virus afectan al cultivo*. 1–4.
- Jaramillo, J. (2015). Evaluación agronómica del cultivo de tomate (*Solanum lycopersicum*) bajo tres diferentes coberturas plásticas. *Universidad San Francisco de Quito USFQ*, 62–64. <https://doi.org/00105441>
- Jiménez, M. (2015). Desarrollo de un sistema de visión artificial para la detección de aglomeración de personas en un semáforo. *Dspace.Unl.Edu.Ec*.

- [http://dspace.unl.edu.ec/jspui/bitstream/123456789/11225/1/Jiménez Ochoa%2C Magaly Gabriela.pdf](http://dspace.unl.edu.ec/jspui/bitstream/123456789/11225/1/Jiménez%20Magaly%20Gabriela.pdf)
- Jones, T. (2017). *Arquitecturas de aprendizaje profundo*.
- José Antontio, T. C. (2006). Sistema de visión artificial para el reconocimiento y manipulación de objetos utilizando un brazo robot. *Test*, 1–125. <https://doi.org/10.1017/CBO9781107415324.004>
- Lara, A. L. (2009). *Comportamiento de cuatro heteroinjertos (HIB) de Tomate frente a la enfermedad de la gota producida por Phytophthora infestans De Bary*. 1–62.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521, 436.
- Lecun, Y., Kavukcuoglu, K., & Farabet, C. (2010). Convolutional Networks and Applications in Vision. In *ISCAS 2010 - 2010 IEEE International Symposium on Circuits and Systems: Nano-Bio Circuit Fabrics and Systems*. <https://doi.org/10.1109/ISCAS.2010.5537907>
- Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y., & Alsaadi, F. (2016). A survey of deep neural network architectures and their applications. *Neurocomputing*, 234. <https://doi.org/10.1016/j.neucom.2016.12.038>
- López Márquez, G. A. (2016). *Sistema inteligente de reconocimiento de patrones con visión artificial para la alerta automática de intrusos en las áreas de almacenamiento de las PYMES*. <http://repo.uta.edu.ec/handle/123456789/23065>
- López Martín, L. M. (2017). *Manual técnico del cultivo de tomate*. <http://repositorio.iica.int/bitstream/11324/3143/1/BVE17079148e.pdf>
- Mart, C., & Gonz, J. M. (2018). *Estudio de viabilidad de una empresa basada en drones*. <http://bibing.us.es/proyectos/abreproy/91824/fichero/TFG-1824-MARTINEZ.pdf>
- Martínez-Ruiz, F. E., Cervantes-Díaz, L., Aíl-Catzím, C. E., Hernández-Montiel, L. G., Sánchez, C. L. D. T., & Rueda-Puente, E. O. (2016). Hongos Fitopatógenos Asociados Al Tomate (*Solanum Lycopersicum L.*) En La Zona Árida Del Noroeste De México: La Importancia De Su Diagnóstico. *European Scientific Journal, ESJ*, 12(18), 232. <https://doi.org/10.19044/esj.2016.v12n18p232>
- Matich Damián. (2011). Redes Neuronales: Conceptos Básicos y Aplicaciones. *Historia*, 55. <ftp://decsai.ugr.es/pub/usuarios/castro/Material-Redes-Neuronales/Libros/matich-redesneuronales.pdf>
- Merchan, F., Cornejo, A., & Sanchez Galan F, J. (2018). Uso de Redes Neuronales Convolucionales para el Reconocimiento Automático de Imágenes de Macroinvertebrados para el Biomonitorio Participativo. In *KnE Engineering* (Vol. 3). <https://doi.org/10.18502/keg.v3i1.1462>
- Meza, J., Pantoja, A., Galan, P. R., Godoy, N., Gattini, J., Villasanti, C., Chávez, R., & Díaz, J. (2013). *El Cultivo De Tomate Con Buenas Prácticas Agrícolas En La Agricultura Urbana Y Periurbana*.
- Mohammed, M., Khan, M. B., & Bashie, E. B. M. (2016). Machine learning: Algorithms and applications. In *Machine Learning: Algorithms and Applications* (Issue December). <https://doi.org/10.1201/9781315371658>
- Morales, E., & Escalante, H. J. (2012). *Arboles de Decisi on Contenido Algoritmo ID3 Como le hace y manejo de ruido Ruido y Sobreajuste ´ y de Modelos de Regresi on*. 1–66.
- Múniera Salazar, L., & Andrés, M. (2012). Sistema de visión artificial para conteo de objetos en movimiento. *El Hombre y La Máquina, No. 40 - 2012*, 40, 87–101.
- Neapolitan, R. E. (2018). Neural Networks and Deep Learning. *Artificial Intelligence*, 389–411. <https://doi.org/10.1201/b22400-15>

- Nilsen, M. (2018). *Neural Networks and Deep Learning*. Determination Press.
- Nuñez, F. J. (2016). Diseño de un sistema de reconocimiento automático de matrículas de vehículos mediante una red neuronal convolucional. *Universitat Oberta de Catalunya*, 53.
<http://openaccess.uoc.edu/webapps/o2/bitstream/10609/52222/6/fnunezsTFM0616me mòria.pdf>
- Ochoa, A., Forero, A. M., & Cangrejo, L. D. (2012). *Actualidad y tendencias de la Agricultura de Precisión*. *Abril*, 1–15.
- Oñate Valdivieso, F. R. (2012). Proyecto: “Generación De Geoinformación Para La Gestión Del Territorio a Nivel Nacional Escala 1: 25 000.” *Memoria Técnica*, 26.
<https://doi.org/10.1017/CBO9781107415324.004>
- Oropeza, C. (2007). *Modelado y Simulación de un Sistema de Detección de Intrusos Utilizando Redes Neuronales Recurrentes*. 15–25.
http://catarina.udlap.mx/u_dl_a/tales/documentos/lem/oropeza_c_ca/
- Patel, S., & Patel, A. (2018). Deep Learning Architectures and its Applications A Survey. *International Journal of Computer Sciences and Engineering*, 6, 1177–1183.
<https://doi.org/10.26438/ijcse/v6i6.11771183>
- Patterson, J., & Gibson, A. (2017). *Deep Learning: A Practitioner’s Approach* (O’Reilly).
- Pichisaca, M. (2003). *El cultivo de Tomate Riñón en Invernadero (Lycopersicon esculentum) Cultivo de tomate riñón en invernadero*. 59.
https://digitalrepository.unm.edu/cgi/viewcontent.cgi?referer=https://www.google.com/&httpsredir=1&article=1366&context=abya_yala
- Pineda, P. (2018). *Diseño De Un Sistema De Reconocimiento Automático De Vehículos Mediante El Uso De Redes Neuronales Profundas (Dnn)*.
<http://repositorio.utn.edu.ec/bitstream/123456789/9136/1/04 RED 220 TRABAJO DE GRADO.pdf>
- Raúl E. López Briega. (2012). *Deep Learning - Libro online de IAAR*.
<https://iaarbook.github.io/deeplearning/>
- Redmon, J. (n.d.). *YOLOv3: An Incremental Improvement*.
- Restrepo Cuestas, B., Holguín Londoño, G., Abril Cañas, M., & Valencia López, J. (2007). *Computer Vision System for Real-time Registry of Pedestrian Density*. 35, 79–83.
- Robots, M. (2009). *Sistemas De Visión Artificial*.
- Salazar, J. (2012). Redes Inalámbricas. In *Redes* (Vol. 2).
<http://www3.uah.es/vivatacademia/ficheros/n54/redesinalam.PDF>
- Sato, A. (2003). The RMAX Helicopter UAV. *DTIC Document*.
- Sensefly. (2019). *eBeeSQ.pdf*.
- SENSEFLY. (2019). *El dron para la agricultura de precisión Supervisión de cultivos al alcance de un dron para elegir eBee SQ Por qué elegir senseFly*.
<http://www.uavsensefly.cl/abee-sq/>
- Silva, J. M. (2019). EVALUACIÓN DE CUATRO PROGRAMAS DE FERTILIZACIÓN FOLIAR COMPLEMENTARIA EN LA PRODUCCIÓN DE TOMATE RIÑÓN (*Solanum lycopersicum*) L. var. Sheila BAJO INVERNADERO. *Journal of Chemical Information and Modeling*, 53(9), 1689–1699.
<https://doi.org/10.1017/CBO9781107415324.004>
- Vizcaya, R. (2018). *DEEP LEARNING PARA LA DETECCIÓN DE PEATONES Y VEHÍCULOS SOBRE FPGA TESIS*. UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MÉXICO.

- Wang, W., & Yang, Y. (2019). Development of convolutional neural network and its application in image classification: a survey. *Optical Engineering*, 58(04), 1. <https://doi.org/10.1117/1.oe.58.4.040901>
- Wheeler Lane Technology College. (2016). Familia IEEE 802.11 2.1. *Familia IEEE 802.11*, 53.
- Wu, J. (2017). Introduction to convolutional neural networks. *National Key Lab for Novel Software Technology*, 1–31. <https://doi.org/10.1007/978-3-642-28661-2-5>
- Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology. *Insights into Imaging*, 9(4), 611–629. <https://doi.org/10.1007/s13244-018-0639-9>
- Yang, G., Xu, N., & Hong, Z. (2018). Identification of navel orange lesions by nonlinear deep learning algorithm. *Engenharia Agricola*, 38(5), 783–796. <https://doi.org/10.1590/1809-4430-Eng.Agric.v38n5p783-796/2018>

9. ANEXOS

Anexo 1. Encuesta de Stakeholders



UNIVERSIDAD TÉCNICA DEL NORTE
FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS
CIERCOM



ENCUESTA DIRIGIDA A PROPIETARIO Y TRABAJADORES EN CAMPO AGRÍCOLA

El objetivo de la presente encuesta es determinar los requerimientos de stakeholders para implementar el sistema de visión artificial.

Marque con una X en el casillero correspondiente:

- ¿Cada qué periodo de tiempo se debe fumigar el cultivo para prevenir el contagio de las plagas?
 - Cada 15 días
 - Cada 7 días
 - Una vez al mes
 - Sólo si la planta está enferma
- ¿Qué estado de la hoja considera que son más susceptibles a mostrarse durante el cultivo?

Estado	Etapa 1 (1-4 semanas)	Etapa 2 (5-8 semanas)	Etapa 3 (9-12 semanas)	Etapa 4 (13-16 semanas)
Verde (Saludable)	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Amarillo (Enfermo)	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Verde-Amarillo (Potencial-Enfermo)	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Café (Marchito)	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
- ¿Qué etapa es idónea para el contagio del tizón tardío (*phytophthora infestans*) en el cultivo?
 - Etapa 1 (1-4 semanas)
 - Etapa 2 (5-8 semanas)
 - Etapa 3 (9-12 semanas)
 - Etapa 4 (13-16 semanas)
- El drone debe tomar medidas de precaución para no ocasionar daños dependiendo del tamaño de la planta y el tutoreo instalado; volando a una altura prudencial de:
 - 1 metro
 - 2 metros
 - 3 metros
 - 3.5 metros

- ¿A qué hora del día considera que hay menos viento para que el drone pueda volar sin limitaciones?

- 6:00 - 7:00
- 7:00 - 8:00
- 8:00 - 9:00
- 9:00 - 10:00
- 10:00 -11:00
- 11:00 - 12:00
- 12:00 - 13:00
- 13:00 – 14:00
- 14:00 – 15:00
- 15:00 – 16:00

- El resultado del sistema de detección de plagas debe ser mostrado en la página web mediante:

- Tablas
- Gráficos
- Información Organizada
- Histogramas

- Para mostrar la información en el sistema debe contar con seguridad de autenticación para validar la información por el usuario.

- Si No

- ¿Considera que se debe mostrar la información de la identificación de la plaga mediante un reporte o documento?

- Si No

- Que medios considera para realizar la visualización de los datos del proyecto:

- Teléfono móvil
- Computador
- Tablet
- Televisor

Anexo 2. Tabulación de Encuestas

En la primera pregunta realizada se solicitó a los encuestados identificar en cada qué período de tiempo se debe fumigar el cultivo para prevenir el contagio de las plagas, en este caso el 100% de la muestra especifico que se debe fumigar cada 7 días para prevenir el contagio de plagas. Estos resultados se muestran en el gráfico



Figura 71. Gráfico de tabulación de pregunta 1

Fuente: Desarrollo del proyecto

En el proceso de la encuesta, el propietario y los trabajadores indicaron que durante las 4 etapas, el estado de la hoja durante el cultivo puede estar verde (saludable), además se muestra que la hoja se torna amarilla (enfermo) con más seguridad desde la segunda hasta la cuarta etapa del cultivo, y la hoja puede tornarse de un tono verde-amarillo (potencial enfermo) con una respuesta homogénea del 50% entre la segunda y cuarta etapa y el otro 50% desde la tercera hasta la cuarta etapa, por último una hoja tiene un color café (marchito) en la última etapa con un 50% de la muestra y el otro 50% responde que más probable es que tenga desde la tercera semana, únicamente una persona nos dice que también puede darse desde la segunda etapa hasta la cuarta etapa. Como se muestra en el gráfico de barras a continuación.

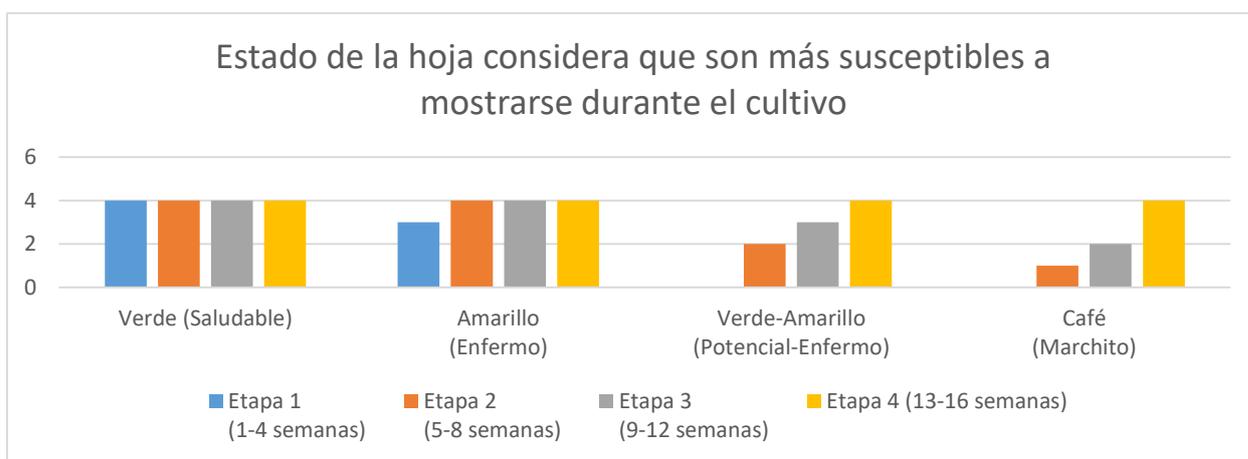


Figura 72. Gráfico de tabulación de pregunta 2

Fuente: Desarrollo del proyecto

La siguiente pregunta que se realizó fue respecto a la etapa idónea para el contagio del tizón tardío (*phytophthora infestans*) en el cultivo de tomate riñón, el 75% de la muestra concuerda que la etapa idónea para el contagio es en la etapa 1 que va de la semana uno a la cuarta semana, mientras que el 25% de la muestra dice que esta etapa de contagio es durante la etapa 2 que va entre la quinta semana hasta la octava semana. Como se aprecia en el gráfico.

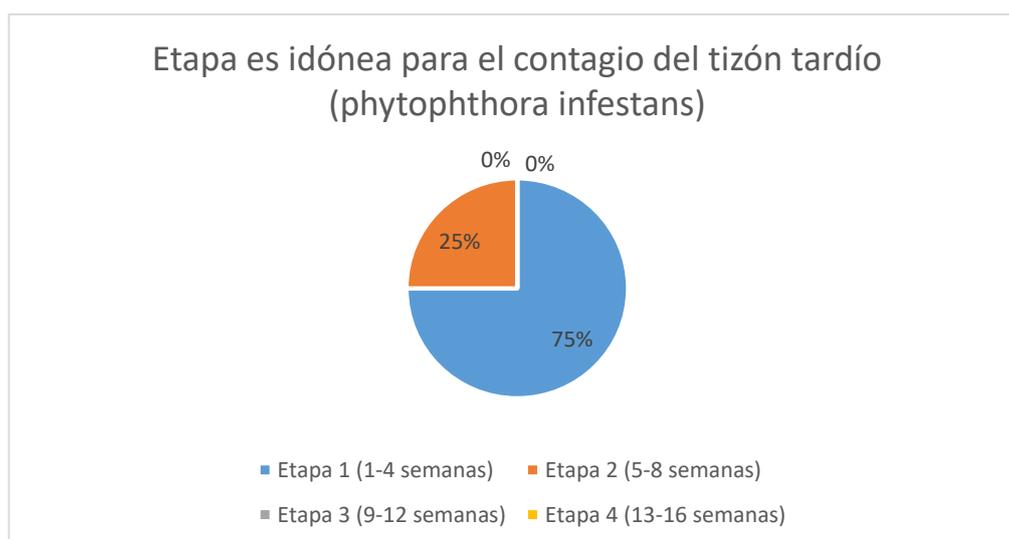


Figura 73. Gráfico de tabulación de pregunta 3

Fuente: Desarrollo del proyecto

Para que no exista daños en la plantación de tomate riñón el propietario y los trabajadores expresan que es prudente volar el drone a una altura de dos metros lo que corresponde al 75% de la muestra, únicamente el 25% de la muestra asegura el cultivo de los daños y prefiere que el drone vuele a 3 metros. Como se muestra en el siguiente gráfico.

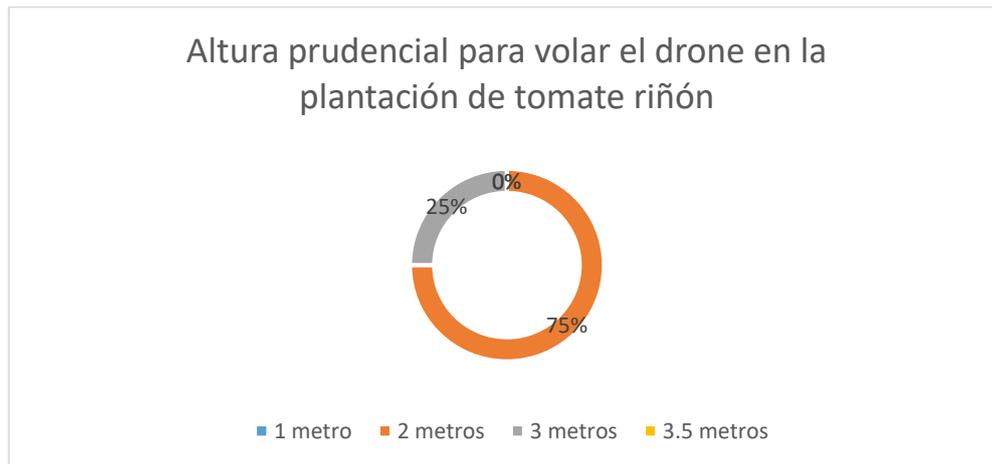


Figura 74. Gráfico de tabulación de pregunta 4

Fuente: Desarrollo del proyecto

En el desarrollo de la encuesta se pidió al propietario y trabajadores especificar a qué hora considera que existe menos viento para que el drone pueda volar sin limitaciones, los resultados muestran que la hora recomendable es de 7:00 a 8:00, en menor porcentaje de 8:00 a 9:00 y solo una consideración en el horario de 6:00 a 7:00. Como vemos en el siguiente gráfico estadístico.

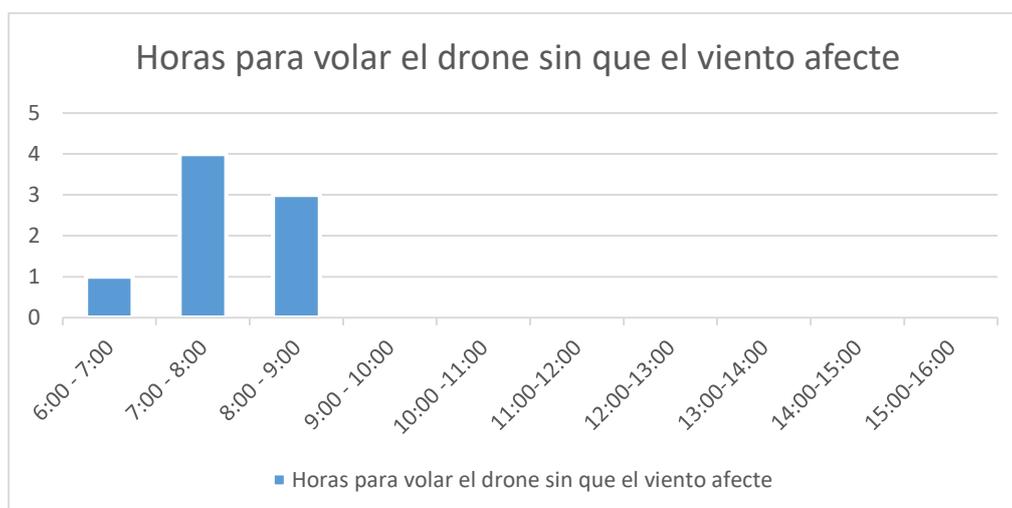


Figura 75. Gráfico de tabulación de pregunta 5

Fuente: Desarrollo del proyecto

En la presente encuesta, en cuanto a cómo le gustaría al propietario y trabajadores observar los resultados de detección de plagas en el cultivo de tomate riñón muestra que el 75% desea visualizarlo en gráficos, y únicamente el 25% de la muestra lo prefiere ver en histogramas. Como el gráfico a continuación muestra.

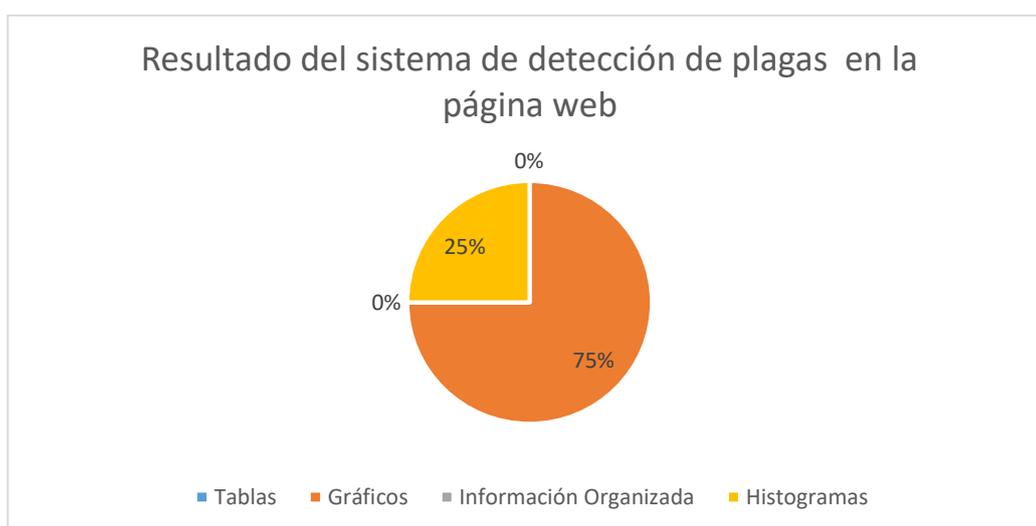


Figura 76. Gráfico de tabulación de pregunta 6

Fuente: Desarrollo del proyecto

El propietario y los trabajadores afirman al 100% que se debe mostrar la información en el sistema con seguridad de autenticación para validar la información por el usuario. Como se puede apreciar en el gráfico.

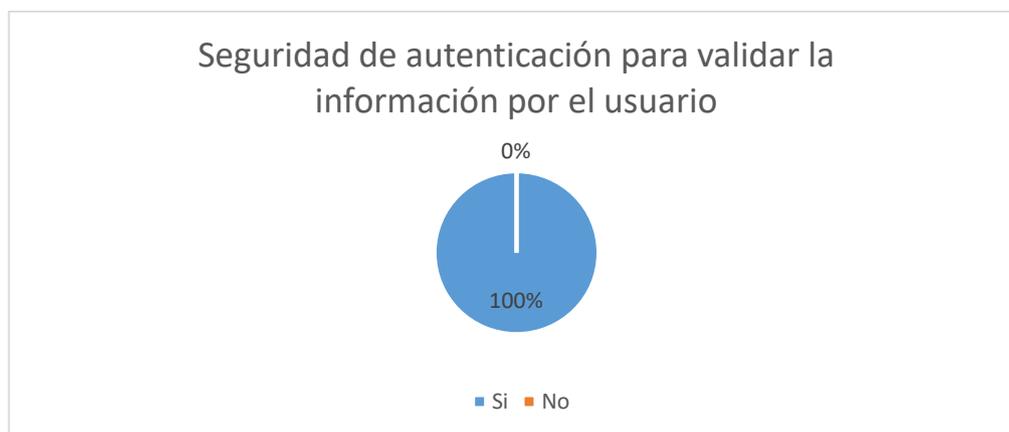


Figura 77. Gráfico de tabulación de pregunta 7

Fuente: Desarrollo del proyecto

Particularmente la encuesta realizada al propietario y trabajadores lo que concierne la presentación de un reporte o documento para dar a conocer la información de la identificación de la plaga están de acuerdo al conseguir un resultado completo de 100%. Como se aprecia en el gráfico de pastel.

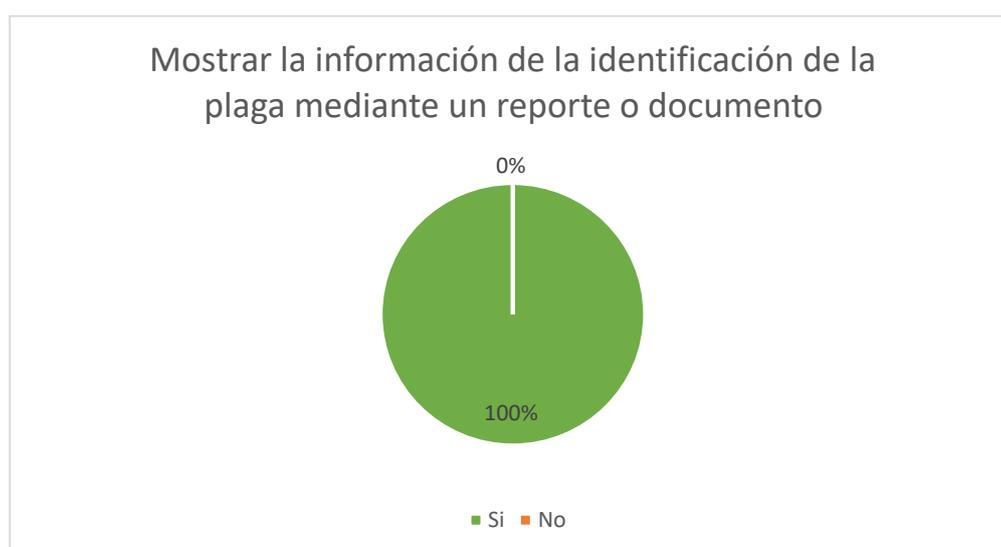


Figura 78. Gráfico de tabulación de pregunta 8

Fuente: Desarrollo del proyecto

Finalmente se preguntó sobre los medios electrónicos que se consideran para poder visualizar los datos del proyecto, en el que se obtuvieron que los dispositivos más adecuados son el computador y el teléfono móvil ambos con el 50% de la muestra respectivamente. Como vemos en el gráfico a continuación.

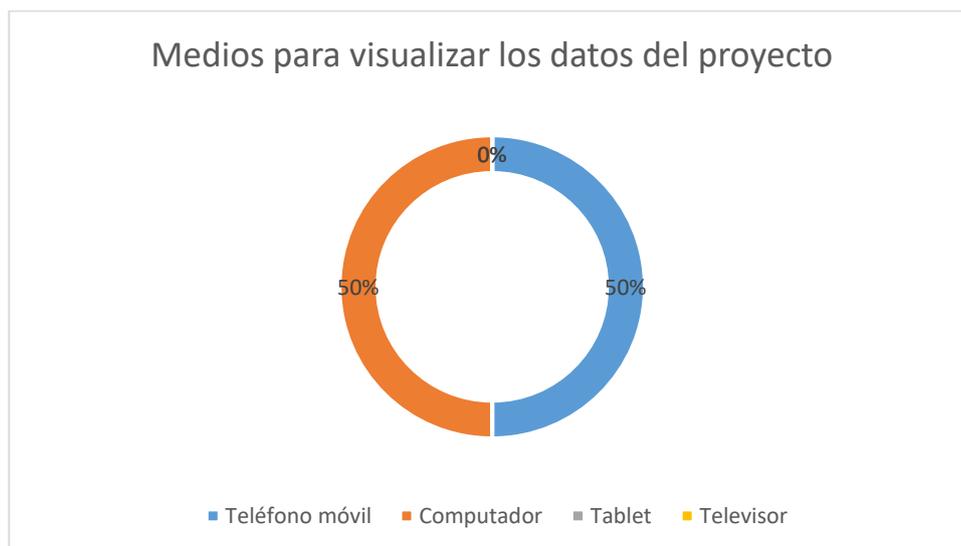


Figura 79. Gráfico de tabulación de pregunta 9

Fuente: Desarrollo del proyecto

Anexo 3. Localización del campo agrícola



Figura 80. Localización del cultivo

Fuente: Desarrollo del proyecto

Anexo 4. Tabla de verificación de los requerimientos

Tabla 29. Requerimientos de *Stakeholders*

#	REQUERIMIENTO	StSR			OBSERVACIÓN
		Si	No	N/A	
REQUERIMIENTOS OPERACIONALES					
StRS1	El sistema debe tener la capacidad de funcionamiento durante 2 horas cada semana.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
StRS2	El drone debe tener una cámara de una resolución adecuada para la detección de diferentes tonalidades de color de las hojas en el cultivo.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
StRS3	El drone al tomar las muestras en el cultivo debe tener una adecuada estabilidad con relación al viento, para obtener imágenes claras.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
StRS4	La adquisición de los datos se debe obtener en un período de 7 días para prevenir las plagas en el cultivo.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
StRS5	El drone debe tener un vuelo a una altura prudencial de acuerdo con el crecimiento del cultivo para que su cámara pueda detectar los colores de la hoja del tomate riñón.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
REQUERIMIENTOS DE USUARIOS					
StRS6	El acceso a la información de la página web, es mediante autenticación por seguridad y validar la información del usuario.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
StRS7	La plataforma web deberá contener tablas y resultados estadísticos con precisión de la identificación de la plaga para generar una alerta al agricultor.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
StRS8	Los resultados y alertas se muestran mediante un reporte o documento dentro de la plataforma web, y así identificar la plaga en el cultivo.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	

Tabla 30. Requerimientos del Sistema

SySR					
#	REQUERIMIENTO	ESTADO			OBSERVACIÓN
		SI	NO	N/A	
REQUERIMIENTOS DE INTERFAZ					
SySR 1	Conectividad a tecnología de comunicación inalámbrica.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
SySR2	Tarjeta MicroSD de 64Gb.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
SySR 3	La interfaz de procesamiento de imágenes debe captar las diferentes tonalidades de color de la hoja del cultivo para la posible detección de plagas.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
SySR 4	La base de datos debe recopilar y almacenar los datos en un formato adecuado para generar un reporte en la página web.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
REQUERIMIENTOS DE USO					
SySR5	Debe tener flexibilidad al volar el dron desde el inicio hasta el final, en los campos agrícolas.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
SySR6	Los datos deben ser obtenidos rápidamente.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
SySR7	El proceso debe rendir a largo plazo y no saturarse.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
REQUERIMIENTOS DE PERFORMANCE					
SySR 8	El dron debe tener un punto de inicio de fácil acceso.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
SySR 9	El dron deberá realizar un sobre vuelo sobre el área del campo agrícola sin interferir con el crecimiento del cultivo.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	

SySR 10	La plataforma no debe saturarse y debe tener un funcionamiento continuo de al menos 3 horas diarias.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
SySR 11	Se debe asegurar que todos los datos recolectados por el drone lleguen a la base datos.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
SySR 12	Visualización grafica de los datos en la página web.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
REQUERIMIENTOS DE MODO Y ESTADO				
SySR 13	La plataforma indica mediante una alerta al usuario cuando exista la detección de plaga en el cultivo.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
REQUERIMIENTOS FÍSICOS				
SySR 14	El drone debe tener espacio grande para el vuelo, de este modo no existan obstáculos en su trayectoria.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
SySR 15	El drone debe volar en condiciones ambientales idóneas ya que no es susceptible al agua.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
SySR 16	El sistema debe tener una SD card con suficiente espacio para que el drone no se sature.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

Tabla 31. Requerimientos de Arquitectura

SRSH					
#	REQUERIMIENTO	ESTADO			OBSERVACIÓN
		SI	NO	N/A	
REQUERIMIENTOS DE DISEÑO					
SRSH 1	El sistema debe tener una plataforma compatible con el dron para el sobrevuelo.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
SRSH 2	Comunicación con la plataforma de procesamiento de imágenes, base de datos y la plataforma web.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
SRSH 3	Los datos de telemetría y video del vuelo del dron deben ser cargados a la plataforma web de forma manual.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
SRSH 4	El sistema debe ser accesible para los administradores.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
REQUERIMIENTOS LÓGICOS					
SRSH 5	Aplicación para conectar el móvil con el dron.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
SRSH 6	Conectividad de la base con datos con la plataforma web.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
SRSH 7	Acceso de la base de datos con la plataforma en la nube.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
REQUERIMIENTOS DE HARDWARE					
SRSH 8	El dron deberá tener una cámara de al menos 5Mpx y una aplicación móvil.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
SRSH 9	El dron debe tener sistema de GPS para el mapeo del dron.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	

REQUERIMIENTOS DE SOFTWARE				
SRSH 10	Sistema operativo que sea Open Source	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
SRSH 11	Plataforma de programación html debe ser Open Source.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
SRSH 12	Plataforma de procesamiento de imágenes digitales que sea Open Source.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
SRSH 13	La base de datos debe ser Open Source.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
SRSH 14	La plataforma de almacenamiento de datos (Cloud) debe ser Open Source.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
REQUERIMIENTOS ELÉCTRICOS				
SRSH 15	Se necesita una batería recargable de 5V y 3A para el sistema de drone.	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

Anexo 5. Entrenamiento de la Red

#Revisar si la Tarjeta NVIDIA GPU esta activada.

```
!nvidia-smi
```

#Importar las librerías de Google colabration

```
from google.colab import drive
drive.mount('/content/gdrive')
!ln -s /content/gdrive/My\ Drive/ /mydrive
!ls /mydrive
```

#Clonar el Darknet

```
!git clone https://github.com/AlexeyAB/darknet
```

#Compilar Darknet al usar NVIDIA GPU

```
%cd darknet
!sed -i 's/OPENCV=0/OPENCV=1/' Makefile
!sed -i 's/GPU=0/GPU=1/' Makefile
!sed -i 's/CUDNN=0/CUDNN=1/' Makefile
!make
```

#Configurar la red Convolucional Darknet para entrenar Yolo v3

```
!cp cfg/yolov3.cfg cfg/yolov3_training.cfg
```

#Crear una carpeta en Google drive donde nosotros podemos guardar los pesos.

```
!mkdir "/mydrive/yolov3"
!echo "Enferma" > data/obj.names
!echo -e 'classes= 1\ntrain = data/train.txt\nvalid = data/test.txt\nnames =
data/obj.names\nbackup = /mydrive/yolov3' > data/obj.data
!mkdir data/obj
```

#Descargar los pesos del modelo Darknet 53

```
!wget https://pjreddie.com/media/files/darknet53.conv.74
```

#Extraemos las imágenes

```
!unzip /mydrive/yolov3/images.zip -d data/obj
import glob
import os
import re
txt_file_paths = glob.glob(r"data/obj/*.txt")
for i, file_path in enumerate(txt_file_paths):
```

#Obtener el tamaño de la imagen

```
with open(file_path, "r") as f_o:
lines = f_o.readlines()
text_converted = []
for line in lines:
print(line)
numbers = re.findall("[0-9.]+", line)
print(numbers)
if numbers:
```

#Definir las coordenadas

```
text = "{} {} {} {} {}".format(0, numbers[1], numbers[2], numbers[3], numbers[4])
text_converted.append(text)
print(i, file_path)
print(text)
```

#Escribir el archivo

```
with open(file_path, 'w') as fp:
for item in text_converted:
fp.writelines("%s\n" % item)
```

#lista de imágenes

```
import glob
images_list = glob.glob("data/obj/*.jpg")
print(images_list)
```

#Crear el archive training.txt

```
file = open("data/train.txt", "w")
file.write("\n".join(images_list))
file.close()
```

#Inicio del entrenamiento

```
!./darknet detector train data/obj.data cfg/yolov3_training.cfg darknet53.conv.74 -
dont_show
```

Anexo 6. Código de validación.

#Importar las librerías para la validación de las muestras

```
import cv2
import numpy as np
import time
import pyodbc
import pandas as pd
```

Cargar neurona

```
net = cv2.dnn.readNet("yolov3_training_last.weights", "yolov3_testing.cfg")
```

Contador en 0

```
count=0;
enfermedad_detectada=8;
```

Nombre de la clase del objeto a detectar

```
classes = ["Enferma"]
```

#Devuelve el valor a la capa con el identificador o el nombre especificado que utiliza la red.

```
layer_names = net.getLayerNames()
output_layers = [layer_names[i[0] - 1] for i in net.getUnconnectedOutLayers()]
```

Conexión a base de Datos

```
direccion_servidor1 = 'db-tomate.chrs681dyzpu.us-east-2.rds.amazonaws.com'
nombre_bd1 = 'IT_ControlPlaga'
nombre_usuario1 = 'admin'
password1 = 'admin123'
direccion_video= ""
cprd_id_control=0
cprc_id_control=0
confidence_values = []
try:
conexion1 = pyodbc.connect('DRIVER={SQL Server};SERVER=' +
direccion_servidor1+';DATABASE='+nombre_bd1+';UID='+nombre_usuario1+';PWD=
' + password1) except Exception as e:print("Ocurrió un error al conectar a SQL Server: ",
e)
```

#A partir del del objeto conexion 1 llamamos al método cursor

```
cursor1 = conexion1.cursor()
```

#Del objeto cursor1 ejecutamos el método execute y lo pasamos a un parámetro sql

```
cursor1.execute("SELECT top(1) det.* FROM
[IT_ControlPlaga].[pro].[tbl_ControlVuelo_Cab] cab inner join " + "
[IT_ControlPlaga].[pro].[tbl_ControlVuelo_Det] det on
cab.[cprc_id_control]=det.[cprc_id_control] where det.[cprd_estado]='PENDIENTE'" +
" order by [cprc_fecha_inicio_vuelo] asc, [cprd_id_control] asc" )
```

```

for row in cursor1:
    direccion_video= str(row[3])
    cprd_id_control=int(str(row[0]))
    cprc_id_control=int(str(row[1]))
    if cprc_id_control > 0:
        cursor1.execute("update [IT_ControlPlaga].[pro].[tbl_ControlVuelo_Det] set
        [cprd_estado]='PROCESANDO' WHERE [cprd_id_control]="+ str(cprd_id_control)+"
        AND [cprc_id_control]="+ str(cprc_id_control))
        conexion1.commit()

```

#Cerramos la sesión con el servidor de MySQL

```

cursor1.close()

```

#Dato de entrada para ser procesado

```

cap = cv2.VideoCapture(direccion_video)

```

#Estilo de Fuente

```

font = cv2.FONT_HERSHEY_PLAIN
starting_time = time.time()
frame_id = 0

```

#Iteraciones de detección por cada muestra

```

while frame_id < 50:
    _, frame = cap.read()
    frame = cv2.resize(frame, (0,0), fx=0.5, fy=0.5)
    frame_id += 1
    height, width, channels = frame.shape

```

#Detectando

```

blob = cv2.dnn.blobFromImage(frame, 0.0042, (416, 416), (0, 0, 0), True, crop=False)
net.setInput(blob)
outs = net.forward(output_layers)

```

Iniciación

```

class_ids = []
confidences = []
boxes = []

```

para cada detección de cada capa de salida, obtenga la confianza, la identificación de clase,

parámetros de cuadro delimitador e ignorar detecciones débiles (confianza <0.5)

```

for out in outs:
    for detection in out:
        scores = detection[5:]
        class_id = np.argmax(scores)
        confidence = scores[class_id]
        if confidence > 0.5:

```

#Enfermedad detectada

```
center_x = int(detection[0] * width)
center_y = int(detection[1] * height)
w = int(detection[2] * width)
h = int(detection[3] * height)
```

coordenadas del rectángulo

```
x = int(center_x - w / 2)
y = int(center_y - h / 2)
boxes.append([x, y, w, h])
confidences.append(float(confidence))
class_ids.append(class_id)
```

#Aplicar supresión no máxima (nms)

```
indexes = cv2.dnn.NMSBoxes(boxes, confidences, 0.5, 0.5)
```

#Revise las detecciones restantes después de nms y dibuje el cuadro delimitador

```
for i in range(len(boxes)):
    if i in indexes:
```

#print(i)

```
x, y, w, h = boxes[i]
label = str(classes[class_ids[i]])
confidence = confidences[i]
cv2.rectangle(frame, (x, y), (x + w, y + h), (200,100,100), 2)
cv2.putText(frame, " " + str(round(confidence, 2)), (x, y + 30), font, 3, (200,10,10), 3)
elapsed_time = time.time() - starting_time
fps = frame_id / elapsed_time
```

#Valores de confianza

```
confidence_values.append(confidence)
```

Esperar hasta que se presione cualquier tecla y rompe el proceso

```
key = cv2.waitKey(1)
if key == 27:
    break
count+=1
```

#Final del proceso, libera la captura.

```
cap.release()
```

#Liberar Recursos

```
cv2.destroyAllWindows()
try:
    cursor1 = conexion1.cursor()
    secuencial=0
    for i in confidence_values:
        secuencial+=1
```

```
cursor1.execute("INSERT INTO [IT_ControlPlaga].[pro].[tbl_ResultadoVuelo]
(resul_id_control, cprd_id_control, cprc_id_control, cprd_promedio) VALUES (?, ?, ?, ?)",
secuencial, cprd_id_control, cprc_id_control, float(i))
conexion1.commit()
except Exception as e:
print("Ocurrió un problema al insertar datos: ", e)
try:
cursor1.execute("update [IT_ControlPlaga].[pro].[tbl_ControlVuelo_Det] set
[cprd_estado]='PROCESADO' WHERE [cprd_id_control]='"+ str(cprd_id_control)+"
AND [cprc_id_control]='"+ str(cprc_id_control))
conexion1.commit()
except Exception as e:
print("Ocurrió un error al actualizar estado: ", e)
cursor1.close()
conexion1.close()
```