



**Sistema inteligente de aprendizaje automático mediante el uso de un vehículo aéreo no tripulado (UAV) para el monitoreo de *Oidium (sphaerotheca pannosa)* en el cultivo de rosas de exportación en el Ecuador**

Espín Velasco, Luis Iván

Departamento de Ciencias de la Computación

Carrera de Ingeniería de Sistemas e Informática

Trabajo de titulación, previo a la obtención del título de Ingeniero en Sistemas e Informática

Msc. Díaz Zúñiga, Magi Paúl

3 de marzo de 2021

## Document Information

<b>Analyzed document</b>	V6TESIS_ESPIN_VELASCO_LUIS_IVAN.pdf (D99390829)
<b>Submitted</b>	3/23/2021 9:36:00 PM
<b>Submitted by</b>	DIAZ ZUÑIGA PAUL
<b>Submitter email</b>	mpdiaz@espe.edu.ec
<b>Similarity</b>	5%
<b>Analysis address</b>	mpdiaz.espe@analysis.arkund.com



## Sources included in the report

<b>W</b>	URL: <a href="https://repositorio.uisek.edu.ec/bitstream/123456789/3224/2/TESIS%20MTI%20PAUL%20C...">https://repositorio.uisek.edu.ec/bitstream/123456789/3224/2/TESIS%20MTI%20PAUL%20C...</a> Fetched: 7/21/2020 7:39:50 AM		4
<b>W</b>	URL: <a href="https://doi.org/10.18510/ijstrm.2020.831">https://doi.org/10.18510/ijstrm.2020.831</a> Fetched: 3/24/2021 3:05:00 AM		3
<b>SA</b>	<b>Tesis_Final_Choloquiga_Reyes.pdf</b> Document Tesis_Final_Choloquiga_Reyes.pdf (D62420150)		1
<b>W</b>	URL: <a href="https://agroecuador.org/index.php/blog-noticias/item/426-como-funciona-el-manejo-i...">https://agroecuador.org/index.php/blog-noticias/item/426-como-funciona-el-manejo-i...</a> Fetched: 3/24/2021 3:05:00 AM		2
<b>W</b>	URL: <a href="https://repositorio.uta.edu.ec/jspui/bitstream/123456789/22579/1/Tesis-130%20%20In...">https://repositorio.uta.edu.ec/jspui/bitstream/123456789/22579/1/Tesis-130%20%20In...</a> Fetched: 3/24/2021 3:05:00 AM		2
<b>W</b>	URL: <a href="https://www.agrocalidad.gob.ec/wp-content/uploads/2020/05/guia16.pdf">https://www.agrocalidad.gob.ec/wp-content/uploads/2020/05/guia16.pdf</a> Fetched: 3/24/2021 3:05:00 AM		2
<b>W</b>	URL: <a href="https://upcommons.upc.edu/bitstream/handle/2099.3/36157/9788483019962.pdf">https://upcommons.upc.edu/bitstream/handle/2099.3/36157/9788483019962.pdf</a> Fetched: 3/24/2021 3:05:00 AM		1
<b>W</b>	URL: <a href="https://medium.com/soldai/tipos-de-aprendizaje-autom%C3%A1tico-6413e3c615e2">https://medium.com/soldai/tipos-de-aprendizaje-autom%C3%A1tico-6413e3c615e2</a> Fetched: 3/24/2021 3:05:00 AM		3
<b>W</b>	URL: <a href="https://dialnet.unirioja.es/servlet/articulo?codigo=5327394">https://dialnet.unirioja.es/servlet/articulo?codigo=5327394</a> Fetched: 3/24/2021 3:05:00 AM		2
<b>W</b>	URL: <a href="https://aprendiendoarduino.wordpress.com/2018/11/11/arquitecturas-iot/">https://aprendiendoarduino.wordpress.com/2018/11/11/arquitecturas-iot/</a> Fetched: 3/24/2021 3:05:00 AM		1
<b>W</b>	URL: <a href="http://tesis.pucp.edu.pe/repositorio/bitstream/handle/20.500.12404/892/RABANAL_CAR...">http://tesis.pucp.edu.pe/repositorio/bitstream/handle/20.500.12404/892/RABANAL_CAR...</a> Fetched: 3/24/2021 3:05:00 AM		2
<b>W</b>	URL: <a href="https://doi.org/10.3390/s20051487">https://doi.org/10.3390/s20051487</a> Fetched: 3/24/2021 3:05:00 AM		2

URL: <https://core.ac.uk/download/pdf/274021278.pdf>



**DEPARTAMENTO DE CIENCIAS DE LA COMPUTACIÓN CARRERA DE  
INGENIERÍA DE SISTEMAS E INFORMÁTICA**

**CERTIFICACIÓN**

Certifico que el trabajo de titulación, “**Sistema inteligente de aprendizaje automático mediante el uso de un vehículo aéreo no tripulado (UAV) para el monitoreo de Oidium (*sphaerotheca pannosa*) en el cultivo de rosas de exportación en el Ecuador**” fue realizado por el señor **Espín Velasco, Luis Iván** el cual ha sido revisado y analizado en su totalidad por la herramienta de verificación de similitud de contenido; por lo tanto cumple con los requisitos legales, teóricos, científicos, técnicos y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, razón por la cual me permito acreditar y autorizar para que lo sustente públicamente.

Sangolquí, 06 de abril de 2021

Firma:  
  
Firmado electrónicamente por:  
**MAGI PAUL  
DÍAZ**

**Ing. Magi Paúl Díaz Zúñiga, Msc**

C. C. 1707249072



**DEPARTAMENTO DE CIENCIAS DE LA COMPUTACIÓN  
CARRERA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA**

**RESPONSABILIDAD DE AUTORÍA**

Yo, **Espín Velasco, Luis Iván** con cédula de ciudadanía n° 1804110474, declaro que el contenido, ideas y criterios del trabajo de titulación: **“Sistema inteligente de aprendizaje automático mediante el uso de un vehículo aéreo no tripulado (UAV) para el monitoreo de Oidium (*sphaerotheca pannosa*) en el cultivo de rosas de exportación en el Ecuador”** es de mi autoría y responsabilidad, cumpliendo con los requisitos legales, teóricos, científicos, técnicos, y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

**Sangolquí, 06 de abril de 2021**

Firma



.....  
**Espín Velasco, Luis Iván**

C.C.:1804110474



**DEPARTAMENTO DE CIENCIAS DE LA COMPUTACIÓN  
CARRERA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA**

**AUTORIZACIÓN DE PUBLICACIÓN**

Yo, **Espín Velasco, Luis Iván** con cédula de ciudadanía n° 1804110474, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: **Sistema inteligente de aprendizaje automático mediante el uso de un vehículo aéreo no tripulado (UAV) para el monitoreo de Oidium (sphaerotheca pannosa) en el cultivo de rosas de exportación en el Ecuador**” en el Repositorio Institucional, cuyo contenido, ideas y criterios son de mi responsabilidad.

**Sangolquí, 06 de abril de 2021**

Firma



.....  
**Espín Velasco, Luis Iván**

C.C.:1804110474

## Tabla de Contenido

GLOSARIO .....	13
RESUMEN .....	14
ABSTRACT .....	15
Capítulo I.....	16
Antecedentes .....	16
Planteamiento del problema .....	17
Formulación del Problema.....	18
Objetivos .....	18
Objetivo General .....	18
Objetivos Específicos .....	18
Justificación.....	19
Alcance .....	19
Hipótesis .....	22
Variables .....	22
Capítulo II.....	23
Marco Teórico .....	23

Floricultura en Ecuador.....	23
Sistema Inteligente de Aprendizaje automático .....	30
Reseña histórica .....	30
Generalidades.....	32
Clasificación .....	33
Internet en las cosas (IOT) .....	39
Arquitectura IOT.....	41
Vehículo Aéreo no Tripulado (UAV) .....	42
Generalidades.....	42
Aplicaciones y tipos de UAVs.....	42
Principales componentes de un UAV .....	44
Estado del Arte .....	46
Planteamiento del estudio sistemático .....	46
Definición del Grupo de control y obtención de términos .....	46
Construcción de la cadena de búsqueda .....	48
Selección de Estudios Primarios .....	49
Elaboración del Estado del Arte .....	50
EP1 : Neuro-kNN classification system for detecting fungal disease on vegetable crops using local binary patterns .....	50
EP2: Plant disease detection by imaging sensors parallels and specific demands for precision agriculture and plant phenotyping.....	50

EP3 : Detection of Plant Disease Using Threshold, K-Mean Cluster and ANN Algorithm .....	51
EP4: A Performance Assessment of Rose Plant Classification Using Machine Learning .....	52
EP5: Grapes leaves disease detection Through Image Processing ..	52
EP6: Soybean Leaf Diseases Detection and Classification using Recent Image Processing Techniques.....	53
Capítulo III.....	54
Metodología de la Investigación .....	54
Enfoque de investigación: Cuantitativo .....	54
Tipología de investigación .....	54
Diseño y desarrollo de Investigación.....	55
Fase 1 .....	56
Fase 2 .....	66
Fase 3 .....	76
Capítulo IV .....	91
Capítulo V .....	95
Conclusiones.....	95
Recomendaciones .....	97
Referencias .....	98

## Índice de Tablas

<b>Tabla 1</b> Preguntas de investigación .....	21
<b>Tabla 2</b> Enfermedades en cultivo de rosas .....	25
<b>Tabla 3</b> Manejo Integrado de Plagas .....	28
<b>Tabla 4</b> Clasificación del Aprendizaje automático.....	33
<b>Tabla 5</b> Tipos de UAV.....	44
<b>Tabla 6</b> Componentes principales de UAV .....	45
<b>Tabla 7</b> Grupo de Control.....	47
<b>Tabla 8</b> Resultados de las búsquedas.....	48
<b>Tabla 9</b> Estudios Seleccionados.....	49
<b>Tabla 10</b> Algoritmos y características .....	57
<b>Tabla 11</b> Características imágenes.....	59
<b>Tabla 12</b> Imágenes para entrenamiento.....	69
<b>Tabla 13</b> Resultados .....	75
<b>Tabla 14</b> Raspberry Pi3 B+.....	78
<b>Tabla 15</b> Sensor DHT11.....	79
<b>Tabla 16</b> Ficha técnica DJI Mavic Air 2.....	81

## Índice de Figuras

<b>Figura 1</b> Sistema de aprendizaje automático supervisado .....	34
<b>Figura 2</b> Algoritmo de aprendizaje automático supervisado .....	35
<b>Figura 3</b> Ejemplo de Regresión lineal.....	36
<b>Figura 4</b> Agrupación en clústers.....	37
<b>Figura 5</b> Reducción de dimensionalidad no lineal .....	38
<b>Figura 6</b> Arquitectura básica IOT.....	41
<b>Figura 7</b> Proceso de la investigación .....	56
<b>Figura 8</b> Diagrama de flujo de trabajo Sistema de Aprendizaje Automático .....	57
<b>Figura 9</b> Oidio en hoja de rosa.....	60
<b>Figura 10</b> Oidio en hoja de rosa .....	60
<b>Figura 11</b> Oidio en hoja y tallo de rosa.....	61
<b>Figura 12</b> Oidio en hojas de rosa .....	61
<b>Figura 13</b> Oidio en tallo y hojas de rosa.....	62
<b>Figura 14</b> Oidio en tallo y hojas de rosa.....	62
<b>Figura 15</b> Diagrama de flujo de trabajo Sistema de Aprendizaje Automático.....	63
<b>Figura 16</b> Sistema de Interfaz de usuario Labellmg.....	65
<b>Figura 17</b> Líneas de comando para instalación Labellmg en Python 3 .....	65
<b>Figura 18</b> Arquitectura YOLO.....	67

<b>Figura 19</b> Diagrama de flujo de trabajo Sistema de Aprendizaje Automático.....	68
<b>Figura 20</b> Configuración de YOLO para entrenamiento .....	69
<b>Figura 21</b> Comando de verificación de instalación correcta .....	70
<b>Figura 22</b> Comando para ejecutar entrenamiento de la red neuronal.....	71
<b>Figura 23</b> Comando para ejecutar entrenamiento de la red neuronal.....	71
<b>Figura 24</b> Intersect Over Union.....	72
<b>Figura 25</b> Precisión.....	73
<b>Figura 26</b> Recall .....	74
<b>Figura 27</b> Resultados obtenidos al final del entrenamiento de la red neuronal.....	75
<b>Figura 28</b> Gráfico de resultados de entrenamiento de la red neuronal.....	76
<b>Figura 29</b> Arquitectura de Sistema Inteligente .....	77
<b>Figura 30</b> Raspberry Pi 3.....	78
<b>Figura 31</b> Sensor de Humedad y Temperatura DHT11 .....	79
<b>Figura 32</b> Batería recargable Tenenergy NiMH.....	80
<b>Figura 33</b> DJI Mavic Air 2 .....	81
<b>Figura 34</b> Comunicación de software Phyton con Sistema Inteligente .....	82
<b>Figura 35</b> Software Phyton.....	82
<b>Figura 36</b> Servicio Web.....	83
<b>Figura 37</b> Diagrama Base de Datos.....	84
<b>Figura 38</b> Líneas de código del proceso de detección .....	85

<b>Figura 39</b> Dashboard.....	85
<b>Figura 40</b> Interfaz para registro de invernaderos, cultivos .....	86
<b>Figura 41</b> Interfaz Dashboard .....	86
<b>Figura 42</b> Status del despliegue del software basado en Phyton .....	87
<b>Figura 43</b> Prototipo de Dispositivo IOT.....	88
<b>Figura 44</b> Prototipo dispositivo IOT (vista lateral).....	88
<b>Figura 45</b> Preparación de prototipo para vuelo en invernadero .....	89
<b>Figura 46</b> Prueba de vuelo Drone con Sistema IOT a bordo.....	90
<b>Figura 47</b> Resultados Monitoreo en IASA I .....	91
<b>Figura 48</b> Resultados de monitoreo por sección .....	92
<b>Figura 49</b> Visualización de datos en Dashboard .....	93
<b>Figura 50</b> Imagen de hoja con porcentaje de detección de Oidio.....	94
<b>Figura 51</b> Imagen de hoja con porcentaje de detección de Oidio.....	94

## GLOSARIO

**ANN:** redes neuronales artificiales

**CNN:** Red Neuronal Convolutacional es un tipo de red neuronal artificial.

**Dashboard:** Es una herramienta que permite realizar un seguimiento visual que analiza y muestra indicadores clave, métricas y datos clave para inspeccionar el estado de un negocio, departamento o proceso específico.

**KNN:** método de los  $k$  vecinos más cercanos es un método de clasificación supervisada.

**IOT:** se refiere a una interconexión digital de objetos cotidianos con internet, Internet en las cosas

**Oidium sphaerotheca pannosa:** es un hongo que se presenta en cultivo de rosas.

**Raspberry Pi:** Computadora de placa reducida que cumple con una arquitectura de computadores básica considerada como hardware open source.

**SVM:** máquinas de vector soporte, este tipo de algoritmos están relacionados con proceso de regresión y clasificación.

**UAV:** Vehículo Aéreo no Tripulado hace referencia a todos robots aéreos como cuadricópteros más conocidos como drones, hexa-copteros, ala fija, etc.

**YOLO:** es un sistema de código abierto del estado del arte para detección de objetos en tiempo real, el cual hace uso de una única red neuronal convolutacional para detectar objetos en imágenes

## RESUMEN

En el Ecuador el sector florícola constituye uno de los principales sectores de exportaciones; sin embargo, este sector se ve afectado por plagas y enfermedades que limitan su producción y comercialización, causando graves pérdidas económicas para el floricultor; entre las enfermedades más comunes que afectan los cultivos de rosas, está la Oidium (*sphaerotheca pannosa*), la cual posee alta capacidad de adaptación, desarrolla resistencia a fungicidas y los brotes epidemiológicos son rápidos y severos. Para el control de la enfermedad, se aplica el manual de manejo integral de plagas y enfermedades, el cual se realiza de manera manual y no existen técnicas de Aprendizaje Automático que permitan mejorar el monitoreo tradicional a un sistema de monitoreo automatizado de mayor precisión, para el control eficiente de esta enfermedad; ante esta realidad, se crea un sistema inteligente mediante el uso de una técnica de aprendizaje automático, para el caso se utiliza Redes neuronales convolucionales CNN, cuya aplicación ha demostrado un alto rendimiento para la detección de objetos; se genera un modelo de Aprendizaje Automático entrenado a base de imágenes de plantas de rosas con presencia de la enfermedad (oidio); este modelo identifica la enfermedad, con un porcentaje de confianza superior al 80%; además, este Sistema Inteligente cuenta con un dispositivo IOT que a bordo de un vehículo aéreo no tripulado (UAV), captura datos de temperatura y humedad relativa; al mismo tiempo, el Drone captura imágenes y videos de la sección en la que se realiza el monitoreo. Los datos obtenidos se visualizan en un panel de control o dashboard, estos datos permiten realizar el monitoreo de la enfermedad y a su vez que se pueda realizar un análisis más exhaustivo por parte del experto en agricultura para la toma de decisiones.

### **PALABRAS CLAVE**

- **OIDIUM**
- **APRENDIZAJE AUTOMATICO**
- **REDES NEURONALES CONVOLUCIONALES**
- **VEHÍCULO AÉREO NO TRIPULADO**
- **DISPOSITIVO IOT**

## ABSTRACT

In Ecuador, the floriculture sector is one of the main export sectors; however, this sector is affected by pests and diseases that limit its production and marketing, causing serious economic losses for the floriculturist; the most common disease that affects rose crops, is Oidium (*sphaerotheca pannosa*), which has a high capacity for adaptation, develops resistance to a wide variety of fungicides and epidemiological outbreaks are rapid and severe. For the control of the disease, the manual of integrated management of pests and diseases is applied, which is done manually and there aren't Machine Learning techniques that allow improving the traditional monitoring to an automated monitoring system of greater precision for the efficient control of this disease; given this reality, an intelligent system is created through the use of a machine learning technique, for this case CNN Convolutional Neural Networks are used, whose application has demonstrated a high performance for the detection of objects; A Machine Learning (ML) model is generated, trained based on images of rose plants with the presence of the disease Oidium; this model identifies the disease, with a confidence percentage higher than 80%; in addition, this Intelligent System has an IOT device on board an unmanned aerial vehicle (UAV), which captures temperature and relative humidity data; at the same time, the Drone captures images and videos of the section in which the monitoring is performed. The data obtained are displayed on a dashboard, these data allow monitoring the disease and make a more comprehensive analysis by the agricultural expert.

### KEY WORDS

- **OIDIUM**
- **MACHINE LEARNING**
- **CONVOLUTIONAL NEURAL NETWORKS**
- **UNMANNED AERIAL VEHICLE**
- **IOT DEVICE**

## Capítulo I

### Introducción

#### Antecedentes

En la actualidad, es un hecho indiscutible la presencia de nuevas tecnologías (Duarte Hueros, 2000); con la revolución digital, el desarrollo e innovación en ingeniería es esencial para el progreso de la sociedad actual y futura, donde el conocimiento se vuelve indispensable para materializar la oferta de productos y/o servicios que mejoren nuestra calidad de vida, lo que a su vez incrementa la competitividad de las Empresas del mercado global (Vegega, Pytel, & Pollo, 2017).

En este sentido, grandes corporaciones como Google y Facebook han aplicado Inteligencia Artificial para ofrecer nuevos y mejores servicios, dado el éxito que han logrado con el uso de IA, empresas de todo el mundo han empezado a invertir en investigación y desarrollo, donde destaca la importancia de la aplicación de Inteligencia Artificial; cabe mencionar que no se refiere sólo a computadoras pensantes, sino a sistemas de software que presenten algún grado de comportamiento inteligente (Vegega, Pytel, & Pollo, 2017); estos sistemas, según Vegega y otros autores (2017) se denominan Sistemas Inteligentes, los cuales son implementados utilizando algoritmos de Aprendizaje Automático.

Un Sistema Inteligente Autónomo es capaz de descubrir y registrar si una acción efectuada sobre una situación dada, sea beneficiosa para lograr su objetivo (Ierache, Naiouf, García, & De Giusti, 2008). Según Kononenko (2001), el Aprendizaje Automático proporciona varias herramientas necesarias para el análisis de datos inteligente; sin embargo, es de vital importancia recolectar datos representativos del problema que se quiere resolver (Vegega, Pytel, & Pollo, 2017).

En este contexto, el presente proyecto consiste en implementar una arquitectura IOT abordo de un vehículo aéreo no tripulado (UAV) que permita recolectar datos; con los que se pretende aplicar una técnica de aprendizaje automático para el monitoreo de enfermedades en cultivo de rosas.

### **Planteamiento del problema**

En Ecuador el sector florícola ha ido evolucionando desde la década de los años 80 (Gómez Rea, 2014) siendo en la actualidad uno de los principales sectores de exportaciones no tradicionales; y uno de los países que posee mayor diversidad de flores, como las rosas con más de 300 variedades, registrándose al 2019, 4984 hectáreas de producción de flores, de los cuales el 71 % corresponde a cultivo de rosas (Expoflores, 2019).

Sin embargo, este sector se ve afectado por plagas y enfermedades que limitan su producción y comercialización, causando graves pérdidas económicas para el floricultor (Urbano Salazar, 2017). Para (Agrocalidad, 2015) que una rosa pueda ser exportable, no debe tener síntomas o signos de ataque de plagas y/o enfermedades (Sandoval Pillajo, Sandoval Pillajo, & Castillo Cabascango, 2019); por tanto es de vital importancia para agricultores y floricultores, su diagnóstico y detección temprana; para lo cual implementan el Manejo integral de plagas y enfermedades, que según Agroecuador (2016), consiste en la supervisión constante del cultivo, con la finalidad de impedir de forma efectiva los inicios del ataque de cualquier insecto o plaga.

Entre las enfermedades más comunes que afectan los cultivos de rosas, está la Oidium (*sphaerotheca pannosa*), causada por un hongo que produce esporas que afectan la parte tierna del vegetal; y que si no se controla a tiempo, resulta en disminución de la producción, incremento de costes e incluso la pérdida del cultivo (Aponte Guano, 2015).

En la actualidad, el manejo integral de plagas y enfermedades se realiza de manera manual y no existen técnicas de Aprendizaje Automático que permitan mejorar el monitoreo tradicional a un sistema de monitoreo automatizado de mayor precisión para el control eficiente de Oidium (*sphaerotheca pannosa*) en el cultivo de rosas.

### **Formulación del Problema**

¿Qué técnicas de Aprendizaje automático permiten monitorear el Oidium (*sphaerotheca pannosa*) en el cultivo de rosas?

### **Objetivos**

#### ***Objetivo General***

Implementar técnicas de aprendizaje automático en la extracción de datos provenientes de un vehículo aéreo no tripulado (UAV) que permita monitorear Oidium (*sphaerotheca pannosa*) en el cultivo de rosas de exportación.

#### ***Objetivos Específicos***

- a. Realizar el análisis del estado del arte mediante un mapeo sistemático de la literatura.
- b. Implementar una arquitectura IOT abordo de un (UAV) para captación de datos con fines de monitoreo de la presencia de Oidium (*sphaerotheca pannosa*) en cultivo de rosas.
- c. Determinar e implementar una técnica de aprendizaje automático que permita identificar Oidium (*sphaerotheca pannosa*) en el cultivo de rosas.
- d. Visualizar los datos obtenidos mediante el uso de dashboard.

## **Justificación**

Según Yanchapaxi, Calvache y Lalama (2010), para que el manejo integral de plagas sea efectivo, es necesario monitorear y analizar qué agente está afectando el cultivo; así también determinar la intensidad del daño; pero para ello es necesario tener conocimientos como: tipo de agente dañino, su clasificación taxonómica, ciclo de vida, síntomas de daño y su control, limitando así este proceso a los conocimientos de un experto; así como al ser extensas las áreas de cultivo, la recolección de datos se realiza por muestreo y de manera manual, lo que impide optimización del tiempo; y en muchos de los casos el factor económico también constituye un limitante.

Ante esta realidad, es preciso realizar esfuerzos para automatizar el monitoreo de cultivo de rosas, por lo que muchos floricultores se enfocan en realizar investigaciones (Proecuador, 2018) que les permita mejorar los procesos con nuevas opciones tecnológicas; en este sentido, y considerando la amplia extensión de los cultivos de rosas; y, siendo que actualmente los UAV o drones se encuentran en diferentes áreas como en la ingeniería, agricultura, operaciones de rescate; constituye un medio importante para la recolección de datos, dada su rapidez para obtener los mismos, de manera que permite optimizar tiempo y recursos.

Posteriormente, al aplicar técnicas de aprendizaje automático, se pretende contribuir a la toma de decisiones estratégicas que permitan mejorar el monitoreo de Oidium (*sphaerotheca pannosa*) en cultivo de rosas, con el fin de impedir de forma efectiva, el ataque de cualquier enfermedad o plaga.

## **Alcance**

Esta investigación propone la implementación de una arquitectura IOT abordo de un (UAV) para obtención de datos utilizando sensores que permitan obtener datos como; temperatura, humedad e imágenes, los cuales servirán como base de conocimiento para la implementación de una técnica

de aprendizaje automático que mejore el monitoreo tradicional de cultivo de rosas.

El proyecto en su primera fase, inicia con la implementación de una arquitectura hardware, la cual está compuesta de sensores y una computadora de placa reducida; a su vez con la implementación de software que permita la comunicación de datos de los sensores a través de internet. Este dispositivo se integrará a bordo de un vehículo aéreo no tripulado para la obtención de datos.

Dentro de la propuesta del presente proyecto, se abarca lo siguiente:

1. Extracción de datos a través de una arquitectura IoT a bordo de un (UAV) utilizando sensores que permitan obtener datos como; temperatura, humedad y fotografías.
2. Preparación de los datos e identificación de variables que serán consideradas para la implementación del aprendizaje automático.
3. Determinar y aplicar una técnica de Aprendizaje Automático que mejore el monitoreo de la enfermedad.
4. Analizar la información para la toma de decisiones estratégicas
5. Presentar un dashboard interactivo que permita la visualización de datos de interés.

Sin embargo, para delimitar de forma adecuada el alcance de la investigación planteada, se proponen varias preguntas de investigación asociadas a los objetivos específicos tal como se muestra en la tabla 1.

**Tabla 1***Preguntas de investigación*

Objetivo específico	Pregunta de investigación
Realizar el análisis del estado del arte mediante un mapeo sistemático de la literatura	RQ1: ¿Qué investigaciones existentes se relacionan con el tema planteado?
Implementar una arquitectura IoT en UAV para captación de datos climatológicos con fines de monitoreo de la presencia de <i>Oidium sphaerotheca pannosa</i> en cultivo de rosas.	RQ2: ¿Qué técnicas de aprendizaje automático se tomaron en cuenta en los estudios relacionados?  RQ3: ¿Qué tipo de arquitectura IoT se puede integrar a bordo de un UAV?
Determinar e implementar una técnica de aprendizaje automático que permita identificar <i>Oidium sphaerotheca pannosa</i> en el cultivo de rosas.	RQ4: ¿Qué configuraciones permiten este tipo de integraciones?
Visualizar los datos obtenidos mediante el uso de dashboard.	RQ5: ¿Qué técnicas de aprendizaje automático ya se han utilizado en monitoreo de cultivo de rosas?  RQ5: ¿Cuál es la importancia de la visualización de datos a través de un Dashboard?

## **Hipótesis**

Un sistema inteligente de aprendizaje automático permite realizar el monitoreo de Oidium (*sphaerotheca pannosa*) en el cultivo de rosas.

## **Variables**

***Independiente:*** Oidium (*sphaerotheca pannosa*) en el cultivo de rosas

***Dependiente:*** Sistema inteligente de aprendizaje automático

## Capítulo II

### Marco Teórico y Estado del Arte

#### Marco Teórico

##### *Floricultura en Ecuador*

La floricultura, es una actividad agrícola que ha ido evolucionando a través del tiempo y cuya demanda mundial de flores, según Pizano (2001), se relaciona con el desarrollo económico de un país; ésta demanda se concentra mayormente en países de Europa, América del Norte y Asia.

En el Ecuador las exportaciones de flores iniciaron en la década de los 80 y a partir del 2012 con el cambio de la matriz productiva, se fomentó la diversificación de las exportaciones nacionales con el fin de desarrollar sectores productivos emergentes (Tucker Yépez, 2019), como la floricultura que en la actualidad representa uno de los principales sectores de exportaciones no tradicionales (Ministerio de Comercio Exterior e Inversiones, 2018).

En este contexto, la floricultura ecuatoriana es una importante fuente de divisas y uno de los sectores primordiales y activos que sirve de apalancamiento al desarrollo de la economía nacional (Sozoranga Sandoval & Vélez Velásquez, 2016); siendo el cultivo de rosas, la que destaca como principal producto de exportación, con un 71% de las 4984 hectáreas de producción de flores registradas hasta 2019 (Expoflores, 2019).

#### **Producción de Rosas.**

En el Ecuador existe diversidad de especies de flores, su ubicación geográfica y condiciones climáticas, sin variaciones extremas de temperatura

favorecen el cultivo de rosas (Sozoranga Sandoval & Vélez Velásquez, 2016) cuya producción se caracteriza por su calidad, y según menciona Zieslin (1996), poseen prestigio y reconocimiento en el mercado internacional, siendo que la exportación de rosas ecuatorianas se comercializa el 60% en Estados Unidos y el 40% Rusia, Europa, y otros.

Para implementar una hectárea del cultivo de rosa, es necesario realizar un análisis exhaustivo de factores técnicos, económicos, infraestructura, entre otros; ya que requiere de un alto nivel de inversión y cumplir con estándares de calidad (Pizano, 2001); además, según menciona Calvache Ulloa (2017), es importante tomar en cuenta que la producción de rosas se requiere diariamente de 6 a 8 horas luz, humedad relativa entre el 60 y 80 %, temperatura de 24 °C, concentración de anhídrido carbónico en el aire de 1200 ppm, suelos de textura Franca con profundidad mínima de 40 cm, buen drenaje, porcentaje de Oxígeno en el suelo de 10 a 21 %, balance adecuado entre macro y micro elementos a más del Carbono, Hidrógeno y Oxígenos que provienen del Aire y del Agua, contenido adecuado de bacterias, hongos, protozoos y lombrices que aseguren la descomposición de materia orgánica y regulen la comunidad bacteriana y favorezcan la aireación del suelo.

### **Enfermedades y Plagas.**

Según Urbano Salazar (2017), el sector floricultor se ve afectado por plagas y enfermedades que, si no se controlan a tiempo, limitan su producción y comercialización, causando graves pérdidas económicas para el floricultor. Cabe recalcar, que para que una rosa pueda ser exportable, debe cumplir con estrictos estándares de calidad; es decir, entre otras cosas, no debe tener síntomas o signos de ataque de plagas y/o enfermedades (Sandoval Pillajo, Sandoval Pillajo, & Castillo Cabascango, 2019).

Las enfermedades pueden ser causadas como consecuencia de excesiva o escasa humedad, poca aireación, daños mecánicos, ataque de hongos, bacterias, virus, deficiencias nutricionales, entre otros; lo cual puede

afectar a toda la planta, desde las raíces, tallo, hojas, flores. Por otro lado, las plagas generan problemas más complejos que implica a un gran número de plantas (Yong, 2004).

Entre las enfermedades más comunes se pueden nombrar las siguientes:

**Tabla 2**

*Enfermedades en cultivo de rosas*

Hongos	Bacterias	Virus
Mildiu del rosal	Cáncer del rosal	Mosaico
Oidio		Rose Streak
Botritis		Marchitez
Mancha negra		u8u8
Roya del rosal		
Coniothyrium o chancro		
Diplodia		
Verticillium		
Cercospora		
Alternaria		
Fumagina		

Fuente: Yong, A. (2004). *El cultivo del rosal y su propagación*. Cultivos tropicales, 25(2), 53-67.

### **Oidium (*sphaerotheca pannosa*).**

Para efectos de esta investigación, se requiere conocer acerca de la enfermedad Oidio (*Sphaerotheca pannosa*), para lo cual se describen aspectos relevantes.

Según Aponte Guano (2015), la primera referencia de oídio en rosal se registra 300 años (a.C.); aunque el primer nombre específico de un oídio como organismo se da en 1753, y en 1951 fue asignado al género *Sphaerotheca*. El agente causal del oídio del rosal es un hongo identificado como *Sphaerotheca pannosa*, y en la actualidad se reconocen dos variedades.

Infoagro (2015), señala que esta enfermedad se ve favorecida por alta humedad relativa y altas temperatura, los primeros síntomas que presenta la planta, son manchas blancas en las hojas más jóvenes; y conforme se va extendiendo la enfermedad, se produce la deformación, arrugamiento y caída de dichas hojas. También afecta a los tallos tiernos y a los botones florales, aunque por lo general, los pétalos de las flores una vez abiertas no se ven afectados.

El hongo que causa esta enfermedad, se dispersa a través del viento y se deposita en las hojas de la planta, germina introduciendo unas pequeñas raíces que absorben los nutrientes de la planta, lo cual la debilita; además de las manchas blancas, presenta retorcimiento de las hojas y deformación de brotes y falta de floración. Finalmente, sin control ni tratamiento, la planta muere. (Cárdenas,C., Pozo, W., Rojas, M., Roque, A., & Mihai, R., 2016).

Esta enfermedad en rosales, según señala Orellana (2013) es considerada la más perjudicial, debido a que afecta a la estética de la rosa, por los efectos dañinos que produce en sus órganos, quitándole así su valor comercial; por tanto, el control preventivo, control de temperatura y humedad

son indispensables con respecto a esta enfermedad, siendo que las infecciones severas son costosas y difíciles de erradicar. Así también, es importante eliminar tejidos infectados, desinfectar herramientas, etc.

### **Manejo Integral de Plagas y Enfermedades.**

Dada la importancia que supone la producción de rosas en la economía del Ecuador, es de vital importancia para agricultores y floricultores, su diagnóstico, detección temprana, y saber cómo contrarrestarlas; para lo cual implementan el Manejo integral de plagas y enfermedades, que consiste en la supervisión constante del cultivo, con la finalidad de impedir de forma efectiva los inicios del ataque de cualquier insecto o plaga (Agroecuador , 2016).

En el marco de Buenas Prácticas Agropecuarias (BPA), cuyo objetivo es asegurar la inocuidad del material vegetal, en este caso de uso ornamental, con el fin de disminuir el impacto ambiental y salvaguardar la salud de las personas que intervienen en esta actividad; se define al Manejo Integrado de Plagas (MIP) como todas las decisiones que se toman para controlar las plagas que afectan un cultivo, respetando el ambiente, integradas en un sistema que combine prácticas culturales, biológicas y químicas (Agrocalidad, 2017)

La aplicación del Manejo Integral de Plagas, conduce a obtener excelentes resultados y a mejorar la eficiencia del negocio; por ello, un aspecto importante es que el productor debe recoger información y aprender a usarla; las plagas y enfermedades del cultivo deben documentarse, con el fin de establecer estrategias para reducirlas y prevenirlas. Se presenta la tabla 3 con los principales componentes del MIP; cabe mencionar que cada uno de los componentes no funciona por sí solo, por lo que su combinación proporciona un nivel de control suficiente para combatir eficazmente plagas y enfermedades; cabe recalcar que según Pizano (2001), el MIP aplicado al sector floricultor está probado en muchos países, los cuales han reportado menos pérdidas.

### Tabla 3

#### *Manejo Integrado de Plagas*

---

#### Principales Componentes

---

##### **1. Monitoreo**

Recursos humanos: Personal entrenado que pueda detectar e identificar problemas en el campo

Mapeo: identificación de áreas afectadas y de plagas o enfermedades presentes

Recolección de Información: determinación de un umbral de acción

Evaluación y toma de decisiones: determinar, aplicar medidas de control

##### **2. Control por exclusión**

Cuarentenas vegetales e inspecciones

Material vegetal libre de plagas y enfermedades

##### **3. Control Cultural**

Evitar malezas y otras plantas que sirvan de hospederos alternos

Rotación de cultivos

Mantener ventilación adecuada

Mantener en buenas condiciones cubierta de invernaderos<sup>3</sup>

Elegir prácticas de riego y fertilización

Restringir paso de operarios y vehículos entre zonas enfermas y sanas

##### **4. Control Físico**

Trampas para insectos

Mallas y otras barreras que restringen ingreso de insectos

Aspiradores para atrapar insectos

Destrucción de plantas enfermas y tratamiento de focos

Esterilización de suelos con vapor antes de la siembra

Desinfección de calzado, herramientas y otros

Sustratos sin tierra

Solarización

##### **5. Control Biológico**

Biopesticidas

Agentes de Control biológico

Incorporación de compost y/o organismos benéficos al suelo

##### **6. Control Genético**

Varietades resistentes, disponibles para algunas plagas y enfermedades

##### **7. Control Químico**

Fumigantes de suelo y otros pesticidas

Desinfectantes

---

Fuente: Pizano, M. (2001). Floricultura y medio ambiente. Producción de Flores sin Bromuro de Metilo.

Para el desarrollo del presente trabajo de titulación, dentro el MIP se revisará los principales conceptos referentes al Monitoreo. En este sentido Para Pizano (2001), el monitoreo es la base para el Manejo Integral de Plagas y enfermedades, y consta de:

**Capacitación:** es importante que operarios o personal designado, tenga un proceso de aprendizaje que le permitan incrementar conocimientos para que puedan ser capaces de distinguir los síntomas de las enfermedades o ataques de plagas, en etapas tempranas, así como evaluar y calificar el nivel de daño observado (Pizano, 2001).

**Mapeo:** se refiere a registrar el resultado de sus observaciones en un plano o mapa de la zona en revisión, ya que es de vital importancia saber cuándo y dónde ocurre una enfermedad o ataque de plagas, y así tratar las zonas afectadas de manera localizada. La información que se obtiene de documentar el monitoreo permite al productor tomar decisiones estratégicas a corto y largo plazo (Pizano, 2001).

**Recolección de información:** es importante determinar un umbral de acción para las principales plagas y enfermedades; es decir los productores establecen un nivel de tolerancia por encima del cual será necesario acciones de control (Pizano, 2001).

**Evaluación de información y toma de decisiones:** Toda la información obtenida durante el monitoreo es esencial para tomar decisiones y valorar niveles de riesgo, que permitan establecer medidas de control preventivo o correctivo, aplicar o no un pesticida o fumigante, que variedades utilizar en resiembra, prever problemas que puedan ocasionarse, etc. (Pizano, 2001).

La Agencia de Regulación y Control Fito y Zoonosanitario exige que se lleve un Manejo Integrado de Plagas, con protocolos para reducción de plagas, el cual consiste en monitoreo semanal de las plagas; se establezca un plan de contingencia en caso de que se eleve la población de plagas; y se establezcan períodos de capacitación para trabajadores (Agrocalidad, 2017).

Según (Flint, 2012), los sistemas de manejo de plagas son dinámicos, ya que la amenaza de una plaga o enfermedad en un cultivo cambia de un área a otra, y de un año a otro; así también la economía puede cambiar el rendimiento del MIP, por lo que para un manejo efectivo del mismo, involucra que constantemente se desarrollen nuevas estrategias y técnicas para recoger y recopilar información a través del monitoreo; en la actualidad el empleo de desarrollo tecnológico, es primordial para obtener información en tiempo real que permita la toma de decisiones, con el fin de mejorar la productividad del cultivo.

## **Sistema Inteligente de Aprendizaje automático**

### ***Reseña histórica***

El origen del aprendizaje automático, viene de otras áreas afines como la biología, psicología y filosofía, áreas que desde sus inicios se han interesado en investigar la naturaleza de la habilidad de aprender, entendiéndose a ésta última como un proceso a través del cual se adquiere conocimiento, habilidades, aptitudes; cuya distinción hace al ser humano capaz de mejorar su actuación en un amplio conjunto de tareas como resultado de haber solucionado un problema y aplicar lo aprendido en solucionar problemas semejantes (Béjar Alonso, Cortés García, & Sánchez Marré, 1998).

En este contexto, un agente autónomo debe ser capaz de realizar una misma tarea de varias maneras dependiendo de las circunstancias; lo cual requiere que el sistema pueda tomar decisiones de lo que debe hacer para resolver un problema, y debe ser capaz de modificar dichas decisiones dependiendo de las condiciones.

En la década de los cincuenta, surge la idea que crear sistemas capaces de aprender, y se desarrollan algoritmos de búsqueda y resolución de problemas, los cuales utilizaban como herramientas de aprendizaje el cotejamiento de patrones, auto-organización y autoestabilización, pero los sistemas de esta época se caracterizan por la falta de conocimiento inicial o conocimiento de respaldo. El desarrollo de investigaciones en esta época sobre aprendizaje automático son: Aprendizaje sin conocimiento de respaldo, Neural Modeling y Aprendizaje evolutivo (Moreno, et al., 1994).

Según Béjar Alonso, Cortés García y Sánchez Marré (1998), señalan que posteriormente, en la década de los sesenta, entre 1965 y 1976, se buscó obtener esquemas de representación que permitan asegurar la correcta obtención de nuevos conocimientos; se utilizó representación basadas en la lógica, destacan la adquisición simbólica y adquisición del lenguaje.

Entre 1976 y 1986, aparecen nuevas perspectivas, como la generación de reglas a partir de ejemplo dentro del aprendizaje simbólico; en esta época destaca el sistema ID3 como paradigma de sistema de generación de reglas. También aparece el sistema COBWEB, que empieza a incluir representaciones no basadas en la lógica del aprendizaje simbólico, aparecen también modelos que integran de resolución de problemas que buscan reglas de control que mejoren la eficiencia de los sistemas (Béjar Alonso, Cortés García, & Sánchez Marré, 1998). Además, en esta época se explora como combinar técnicas simbólicas de aprendizaje para mejorar la calidad de lo aprendido (Moreno, et al., 1994); se encuentran nuevos modelos de aprendizaje no simbólico, como aprendizaje neuronal, modelos inspirados en la selección natural y genética.

Actualmente se desarrollan varias líneas de investigación en torno al aprendizaje automático, como en modelos neuronales y genéticos, modelos computacionales teóricos, sistemas basados en agentes, aprendizaje inductivo, aproximaciones híbridas, programación lógica inductiva, Data mining, entre otros. Todos aquellos trabajos que han aparecido a través del tiempo han contribuido a una amplia diversidad de investigaciones y ha resultado en sistemas efectivos que continuamente se van desarrollando, y en un futuro se pueden obtener mayores resultados (Béjar Alonso, Cortés García, & Sánchez Marré, 1998).

### **Generalidades**

En la segunda mitad del siglo XX, el aprendizaje automático evolucionó como subcampo de la Inteligencia Artificial (IA), innovando el autoaprendizaje en algoritmos que derivan de conocimientos de los datos para hacer predicciones (Raschka & Mirjalili, 2017).

El aprendizaje automático o aprendizaje artificial, es un área de IA muy desarrollada y de gran interés (Moreno, et al., 1994); un sistema que aprende podría definirse como un programa o conjunto de algoritmos que toma decisiones para resolver problemas, en base a la experiencia acumulada. Un sistema artificial que aprende emplea diversas técnicas, que incluyen métodos matemáticos, métodos de búsqueda en bases de datos, etc. Tratar un rango amplio de tipo de datos de entrada, que pueden ser incompletos, inciertos, inconsistentes, para resolver problemas permite que estos sistemas puedan trabajar en entornos reales.

Según Raschka & Mirjalili (2017), en la era tecnológica en la que vivimos abundan datos, la aplicación y ciencia de algoritmos dan sentido a los datos, ya que utilizando algoritmos de aprendizaje automático, se pueden convertir esos datos en conocimiento y hacer predicciones sobre eventos futuros; en este sentido el aprendizaje automático ofrece una alternativa más

eficiente para capturar conocimiento de datos, para mejorar gradualmente el rendimiento de modelos predictivos y tomar decisiones basadas en los datos.

El desarrollo de aprendizaje automático se está volviendo cada vez más importante no solo en la informática, sino también en nuestra vida diaria (Raschka & Mirjalili, 2017), ya que se está integrando en modelos económicos, políticos, legales, médicos (Plasek, 2016), así también gracias al aprendizaje automático hoy en día, disfrutamos de correo electrónico, filtros spam, software de reconocimiento de texto y voz, motores de búsqueda confiables; y conforme sigue evolucionando, en un futuro podríamos disfrutar de autos autónomos seguros y eficientes, entre otros.

### **Clasificación**

Dependiendo de las necesidades del problema, el ambiente y los factores que afectarán la toma de decisiones, se pueden encontrar distintos tipos de algoritmos de aprendizaje (Luna, 2018); existen tres tipos: aprendizaje supervisado, aprendizaje no supervisado y aprendizaje reforzado, los cuales se detallan en la tabla 4 (Raschka & Mirjalili, 2017).

**Tabla 4**

*Clasificación del Aprendizaje automático*

Tipos	Características
<b>Aprendizaje Supervisado</b>	Datos etiquetados
	Retroalimentación directa
	Predecir salidas/ futuro
<b>Aprendizaje no supervisado</b>	Sin etiquetas/ objetivos
	Sin retroalimentación
	Encontrar estructuras escondidas en datos
<b>Aprendizaje Reforzado</b>	Proceso de decisión
	Sistema de recompensas
	Aprender una serie de acciones

Fuente: Raschka, S., Mirjalili, V. (2017). Giving computers the ability to learn from data. Python Machine Learning (pp.1-15). India: Packt, 2ed

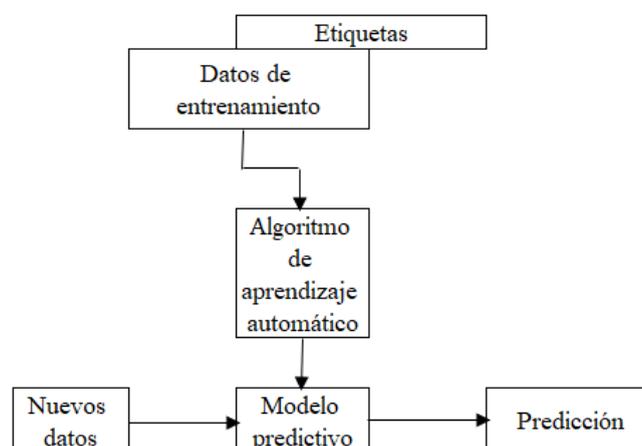
### Aprendizaje automático supervisado.

El principal objetivo del aprendizaje supervisado es aprender a modelar desde datos de entrenamiento etiquetados que nos permiten hacer predicciones; es decir se genera un modelo predictivo, basado en datos de entrada y salida. El término supervisado se refiere a un conjunto de muestras donde ya se conocen las señales de salida deseadas (etiquetas), (Raschka & Mirjalili, 2017); o en otras palabras, se refiere a tener un conjunto de datos previamente etiquetado y clasificado, del cual ya se sabe a qué grupo, valor o factor, pertenecen los ejemplos (Luna Gonzalez, 2018).

Con estos datos de entrenamiento, el algoritmo va aprendiendo a clasificar la muestra, por ejemplo, para filtrar correo no deseado, se puede entrenar un modelo usando un algoritmo de sistema de aprendizaje automático, sobre un cuerpo de correos etiquetados, marcados como spam o no spam, para predecir si un nuevo correo pertenece a cualquiera de estas dos categorías. Una tarea con etiquetas de clase discretas, es también llamada tarea de clasificación; otra subcategoría de esta clase de aprendizaje automático, es la regresión (Raschka & Mirjalili, 2017).

**Figura 1**

*Sistema de aprendizaje automático supervisado*



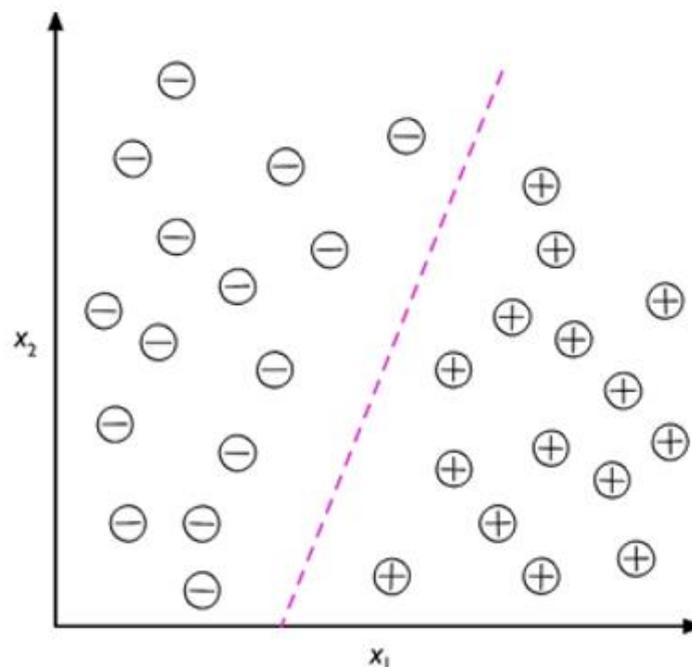
Fuente: Raschka, S., Mirjalili, V. (2017). Giving computers the ability to learn from data. Python Machine Learning (pp.1-15). India: Packt, 2ed

### **Clasificación para predecir etiquetas de clase.**

Según señala Raschka & Mirjalili (2017), es una subcategoría del aprendizaje de sistema automático supervisado, mediante el cual se predice una categoría a la que pertenecen los datos; el algoritmo aprende una serie de reglas con el fin de distinguir entre dos o más posibles clases. Se puede asignar cualquier etiqueta de clase del conjunto de datos de entrenamiento a una nueva instancia sin etiqueta; por ejemplo una tarea de clasificación multiclase es el reconocimiento de caracteres escritos a mano, donde cada letra del alfabeto representará una categoría como etiquetas de datos que queremos predecir, estos datos son parte del conjunto de datos de entrenamiento, así al proporcionar un nuevo carácter escrito a mano, el modelo predictivo podrá predecir con cierta precisión, la letra correcta del alfabeto, por otro lado nuestro modelo no podrá reconocer un carácter si no forma parte del conjunto de datos de entrenamiento.

**Figura 2**

*Ejemplo de Algoritmo de aprendizaje automático supervisado para aprender una regla*



Nota: El límite de decisión representado como una línea discontinua

Fuente: Raschka, S., Mirjalili, V. (2017). Giving computers the ability to learn from data. Python Machine Learning (pp.1-15). India: Packt, 2ed

### **Regresión.**

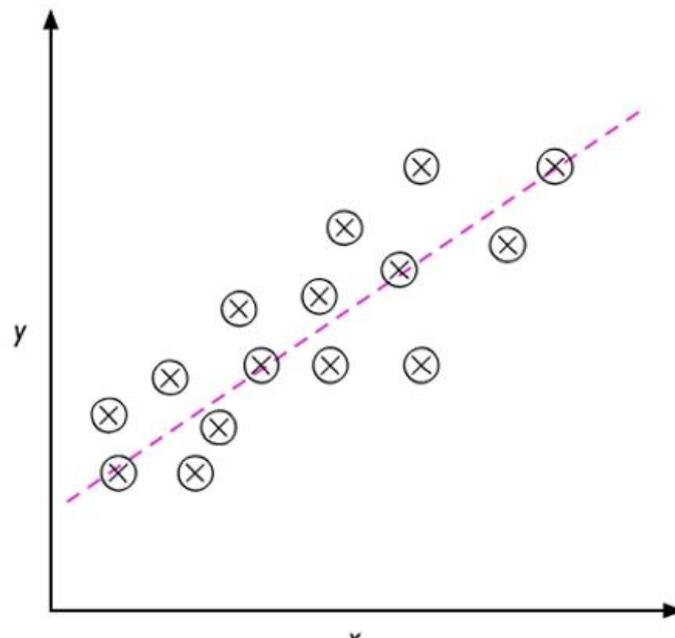
Otro tipo de aprendizaje automático supervisado, es la predicción de datos continuos, denominado análisis de regresión, que según Lind , Marchal y Wathen (2008), se define como una ecuación que expresa la relación lineal entre dos variables, donde se desea estimar el valor de la variable dependiente “y” con base a un valor de la variable independiente “x”; según Render y Heizer (2007), la regresión es un modelo matemático de línea recta para describir relaciones funcionales entre variables dependiente e independiente.

Raschka y Mirjalili (2017), mencionan que, para el análisis de regresión, se nos da una serie de variables predictoras o explicativas y una variable de respuesta continua, mediante la cual tratamos de encontrar una relación entre las variables que nos permita predecir un resultado. En el aprendizaje automático comúnmente las variables predictoras se denominan características, y las variables de respuesta se llaman variables de destino.

La siguiente figura muestra el concepto de regresión lineal:

#### **Figura 3**

##### *Ejemplo de Regresión lineal*



Nota: Dada una variable de característica x y una variable de destino y. Fuente: Raschka, S., Mirjalili, V. (2017). Giving computers the ability to learn from data. Python Machine Learning (pp.1-15). India: Packt, 2ed

## Sistema de aprendizaje automático no supervisado.

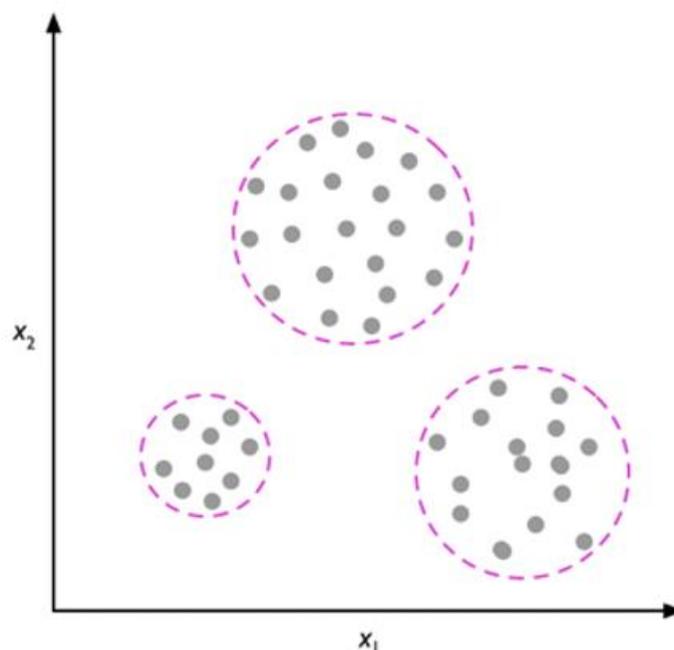
En el aprendizaje automático no supervisado, se utilizan datos que no están etiquetados o con datos de estructura desconocida, al utilizar técnicas en este tipo de aprendizaje, podemos explorar la estructura de los datos para extraer información significativa sin la guía de una variable de resultado conocida o una función de recompensa (Raschka & Mirjalili, 2017).

### *Agrupación en clústers.*

Es una técnica exploratoria de análisis de datos, mediante la cual se organiza un conjunto de información en clústers o subgrupos significativos, sin tener conocimiento previo de su pertenencia; cada grupo que surge durante el análisis define un grupo de objetos que comparten cierta similitud; por ejemplo, en marketing permite descubrir grupos de clientes en función de sus intereses, gustos o preferencias (Raschka & Mirjalili, 2017).

### **Figura 4**

*Agrupación en clústers*



Nota: Se organiza datos sin etiquetar en tres grupos distintos según similitud de características,  $x_1$  y  $x_2$ . Fuente: Raschka, S., Mirjalili, V. (2017). Giving computers the ability to learn from data. Python Machine Learning (pp.1-15). India: Packt, 2ed

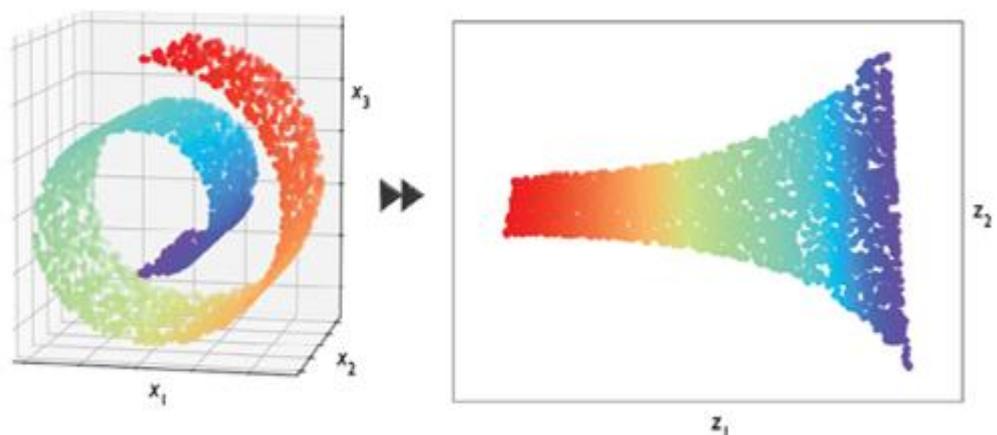
### ***Reducción de dimensionalidad.***

Este tipo de aprendizaje automático no supervisado, se refiere a algoritmos que mapean el conjunto de los datos a subespacios derivados del espacio original, que permiten hacer una descripción de los datos; son ampliamente utilizados en procesos de asociación de máquina (Hernández, 2016).

Según Raschka y Mirjalili (2017), la reducción de la dimensionalidad también puede ser útil para visualizar datos, por ejemplo: un conjunto de características de alta dimensión se puede proyectar en espacios de características unidimensionales, bidimensionales o tridimensionales para visualizarlos a través de histogramas o diagramas de dispersión; cabe mencionar, que trabajar con datos de alta dimensionalidad, cada observación viene con gran cantidad de mediciones, lo que por el espacio de almacenamiento y rendimiento computacional constituye un limitante, o dicho de otra manera, constituye un desafío para los algoritmos de aprendizaje automático.

**Figura 5**

*Reducción de dimensionalidad no lineal*



Nota: Se comprime un rollo suizo en 3D en un nuevo subespacio de características 2D. Fuente: Raschka, S., Mirjalili, V. (2017). Giving computers the ability to learn from data. Python Machine Learning (pp.1-15). India: Packt, 2ed

### **Sistema de aprendizaje automático de reforzamiento.**

Raschka y Mirjalili (2017), mencionan que el objetivo del aprendizaje por refuerzo, es desarrollar un sistema o agente que mejore su desempeño en función de las interacciones con el entorno. Este tipo de aprendizaje difiere del aprendizaje supervisado en que la retroalimentación no es el valor de la etiqueta, sino una medida de que tan bien se midió la acción mediante una función de recompensa. A través de su interacción con el entorno, un agente puede aprender mediante este tipo de aprendizaje, para aprender una serie de acciones que maximizan esta recompensa mediante un enfoque exploratorio de prueba y error.

Un esquema general de aprendizaje automático por reforzamiento, es que el agente en el aprendizaje intenta maximizar la recompensa a través de una serie de interacciones con el entorno, donde cada recompensa puede definirse como el logro de un objetivo general; por ejemplo un motor de ajedrez, donde un agente decide sobre una serie de movimientos dependiendo del estado del tablero, que en este caso vendría a ser el entorno y la recompensa se define como ganar o perder el juego (Raschka & Mirjalili, 2017).

### **Internet en las cosas (IOT)**

En la actualidad, con el desarrollo de la tecnología, la conectividad y generación de información, representa un pilar fundamental en diversos campos, como empresariales, políticos, médicos, etc (Mahedero Biot, 2020); en este sentido el Internet en las cosas, o más conocido como IOT, que en sus siglas en inglés significa "Internet of Things", se refiere al conjunto e interconexión de dispositivos y objetos a través de una red local o una red de internet. El IOT puede estar en cualquier objeto o dispositivo, y puede interactuar sin la necesidad de intervención humana, es decir, se trata de una interacción máquina a máquina ( Delloite , 2020).

El sistema funciona conectando a sensores en un dispositivo como Arduino o Raspberry, el cual recogerá los datos y mediante la conexión a internet se almacenan en una base de datos que se conecta a un Dashboard, mediante el cual se visualizan los datos recogidos; para que el sistema sea viable, la arquitectura debe cumplir requerimientos que permitan distribuir la tecnología a los objetos para que puedan interactuar entre sí, de manera eficiente, segura y flexible. Estos requerimientos son: conectividad y comunicación, gestión y control de dispositivos; y, recolección y análisis de datos (Mahedero Biot, 2020).

Según Delloite (2020), la tecnología utilizada para la comunicación del sistema IOT para dispositivos no próximos, es a través de una red WiFi, la cual permite la interconexión inalámbrica entre dispositivos, que aunque permite una alta transferencia de datos, tiene bajo alcance y alto consumo; otro tipo de red que se puede utilizar es una red móvil 3G, 4G, donde el alcance es mayor, ya que envían y reciben datos más rápido y su consumo es bajo.

Específicamente para IOT existen otros tipos de redes que se pueden utilizar, como Sigfox, que es un operador de red global, el cual implementa redes inalámbricas para conectar dispositivos; o Lora, que es una tecnología inalámbrica, que emplea radiofrecuencia, diseñada para dispositivos de bajo consumo de alimentación que operan redes de alcance local, regional, global ( Delloite , 2020).

La tecnología IOT, tiene diversas aplicaciones y continuamente evoluciona; es decir, se puede utilizar para una serie de soluciones propuestas, pero esta tecnología no es única, y en este sentido hay que analizar tanto la tecnología como la arquitectura, para adaptarlas a una solución concreta que se requiera desarrollar ( Delloite , 2020).

### **Arquitectura IOT**

Una arquitectura basada en tecnología de Internet en las cosas (IOT), permite que dispositivos hiperconectados recojan y procesen información de distintos entornos; la arquitectura IOT debe cumplir ciertos requerimientos como: conectividad y comunicación, gestión de control de dispositivos, recolección y análisis de datos, escalabilidad, flexibilidad, disponibilidad, integración (Aprendiendo Arduino, 2018); a continuación, en la figura 6 se muestran las características y requisitos en resumen de una arquitectura definida en el IOT.

**Figura 6**

*Arquitectura básica IOT*



Fuente: Cobos, A. (2016). Diseño e implementación de una arquitectura IoT basada en tecnologías Open Source. *Trabajo Fin de Máster, Escuela Técnica Superior de Ingeniería Universidad de Sevilla.*

La Capa de percepción (Perception Layer), es la responsable de recoger las propiedades físicas de los objetos (temperatura, humedad, localización...) mediante sensores y convertir la información en señales digitales para poder transmitir las por la red. De esta forma, los sensores, la tecnología RFID, códigos de barras o GPS, entre otras, son las tecnologías claves en esta capa (Cobos, 2016).

La Capa de red (Network Layer), tiene como función principal enviar los datos recogidos por la capa de percepción, hacia su destino, mediante la red a través de tecnologías como la 3G, 4G, WiFi, Bluetooth, ZigBee u otras (Cobos, 2016).

La Capa de aplicación (Application Layer), es la capa que tiene como función, el desarrollo de todo tipo de aplicaciones en función del objetivo que tenga y de los datos recogidos por la capa de percepción. Es el nivel más importante en cuanto al papel que juega en el desarrollo del IOT (Cobos, 2016).

## **Vehículo Aéreo no Tripulado (UAV)**

### ***Generalidades***

Se utiliza el termino UAV (Unmanned Aerial Vehicle) para hacer referencia a la ausencia de tripulación en el vehículo; es decir, una aeronave no tripulada capaz de realizar una misión sin la necesidad de tener tripulación embarcada; cabe mencionar que no necesariamente se refiere a tener autonomía, así como no excluye la condición de tener un piloto o controlador, quien trabaja desde tierra (Barrietos, et al., 2007).

Los UAVs también suelen ser llamados “drones”, cuyas funciones de control se clasifican de la siguiente manera: 1) On-board mediante radio control y Off-board mediante control remoto; 2) controlados desde una ubicación remota o controlados mediante planes de vuelo pre-programado (Rabanal Carretero, 2011).

### ***Aplicaciones y tipos de UAVs***

A través de la historia, los vehículos aéreos no tripulados se desarrollaron principalmente en un contexto militar y su uso en ésta área sigue siendo muy común (Custers, 2016); sin embargo en la actualidad los vehículos aéreos no tripulados (UAV) o robots aéreos tienen amplia aplicación en

diferentes áreas de la ingeniería y la investigación, por ejemplo son utilizados para para realizar trabajos de fotogrametría, cartografía y levantamientos topográficos, o en agricultura para detección de plagas y enfermedades en cultivos con cámaras multiespectrales; incluso son utilizados en la industria cinematográfica para realizar tomas en diferentes ángulos.

Específicamente en la agricultura, según George, Tiwan, Yadav, Peters y Sadana (2013), los UAVs proporcionan un método rápido y eficiente de analizar las condiciones de campo en grandes terrenos, puesto que son sistemas altamente ágiles, permitiendo el despliegue en casi cualquier entorno. Así también proporcionan al operador datos que se pueden utilizar para evaluar la salud y estado del campo. En este sector, los UAVs son utilizados para el monitoreo y recolección de datos, para análisis y toma de decisiones.

Existen diferentes tipos de vehículos aéreos no tripulados (UAV), se diferencian por grado de autonomía, tamaño, peso, fuente de energía, duración de vuelo, capacidad de carga, tipos de sensores como cámaras, rastreadores, sensores meteorológicos, etc, (Custers, 2016).

El desarrollo de la tecnología para UAVs ha mejorado respecto a la capacidad de control aéreo y sus funcionalidades, por ejemplo algunos mecanismos de control automático han sido ejecutados para establecer planes de vuelo preestablecidos; sin embargo hay limitaciones relacionadas con tamaño y peso en los dispositivos utilizados (Ramasamy, Sabatini, Gardi, & Liu, 2016); y, proporcionar una buena conectividad entre el UAV y enlaces a los usuarios y a cualquier estación terrestre, es desafiante (Gupta, Jain, & Vaszkun, 2016).

**Tabla 5***Tipos de UAV*

Criterio de clasificación	Tipos
Tamaño	Pequeños, medianos, grandes
Tipo de misión	Reconocimiento, observación, salvamento, etc.
Origen de la misión	Militar, civil
Duración de la misión	Larga, mediana o corta duración
Tipo de sustentación	Ala fija: Planeadores; a la rotativa: multicópteros

---

Fuente: Chicaiza, F & Chuchico, P.(2015).

***Principales componentes de un UAV***

La mayoría de UAVs se caracterizan por ser helicópteros de tres o más hélices de sustentación vertical, es decir, son multirotores, cuya ventaja principal es sobrevolar cualquier entorno de forma estática y relativamente estable, lo que se logra por un sistema compuesto por tecnología avanzada, cuyos componentes principales se detallan a continuación en la Tabla 6.

**Tabla 6***Componentes principales de UAV*

Componente	Detalle
Frame	Es la estructura física
Motores brushless	Compuestos por una parte móvil (rotor) y una parte fija (carcasa)
Hélices	Elemento que transforma la energía mecánica (generada por el motor) en energía propulsadora
Computadora de vuelo	Dispositivo electrónico encargado de gestionar los movimientos del drone en todos los ejes y estabilizar el vuelo
Control remoto	Permite comandar el UAV en tiempo real o mediante una ruta trazada
Batería	Dispositivo que convierte energía química almacenada en electricidad, fuente de voltaje
GPS	Dispositivo de posicionamiento global
Sensores	Dispositivos que aumentan la capacidad de control del UAV, o para obtener una resolución espacial y espectral

## **Estado del Arte**

Para analizar el estado del arte acerca de sistemas a bordo de un vehículo aéreo no tripulado (UAV), para detección de la enfermedad Oidium (*sphaerotheca pannosa*) en cultivo de rosas utilizando herramientas de aprendizaje automático, se realizó un proceso de revisión de la literatura inicial, utilizando las guías de revisión sistemática de la literatura propuestas por (Kitchenham, et al., 2009). Las actividades consideradas para este proceso se describen a continuación:

- a) Planteamiento del estudio sistemático
- b) Definición del Grupo de control y obtención de términos.
- c) Construcción de la cadena de búsqueda
- d) Selección de Estudios Primarios
- e) Elaboración del Estado del Arte

### ***Planteamiento del estudio sistemático***

En esta fase se realizó una breve descripción del problema de investigación para proporcionar un contexto para la búsqueda de estudios científicos; posteriormente se procedió a definir un objetivo de búsqueda y plantear preguntas de investigación para alinear la búsqueda en relación al problema de investigación y finalmente se definieron los criterios de inclusión y exclusión.

### ***Definición del Grupo de control y obtención de términos***

Según Franco, Espinoza y Maceda (s.f), un paso fundamental de un mapeo sistemático de literatura es definir o delimitar los artículos que se consideran relevantes para la investigación, eliminando aquellos que solo mencionan un enfoque sustancial de la temática principal.

Fue necesaria la participación de al menos cuatro investigaciones; cada investigación propuso estudios que podrían ser parte del grupo de control. Posteriormente se realizó una validación cruzada donde se estableció finalmente el grupo de control, el cual se indica en la tabla 7.

**Tabla 7**

*Grupo de Control*

Título	Cita	Palabras Clave
Plant Disease Detection by Imaging Sensors Parallels and Specific Demands for Precision Agriculture and Plant Phenotyping	(Mahlein, 2016)	Disease severity, Digital technologies, Machine learning, Deep learning, Precision agriculture.
An identification of crop disease using image segmentation	(Kumar y Jaysankar, 2019)	Agriculture, Crop, Deformable model, Segmentation method, Crop diseases, K-means algorithm
Creating and Improving Machine Learning Algorithms for Plant Disease Identification	(Lindgren, 2020)	Computer Science, Image Analysis, Machine Learning, IT, Information Technology.
A Framework for Agricultural Pest and Disease Monitoring Based on Internet-of-Things and Unmanned Aerial Vehicles	(Gao, Sun, Hu, y Zhang, 2020)	agricultural pests and diseases, internet of things (IOT), unmanned aerial vehicle.

Después de analizar los estudios del grupo de control, se seleccionaron las palabras más relevantes respecto al objetivo de búsqueda, en este caso fueron: "Diseases", "Machine Learning", "Agriculture". Las palabras descritas tienen similitudes, semejanzas o relaciones que pueden variar según el caso de búsqueda.

### ***Construcción de la cadena de búsqueda***

Con las palabras clave que fueron obtenidas de los artículos científicos del grupo de control se conformó la cadena de búsqueda:

- "Diseases", "Machine Learning", "Agriculture"

Sin embargo, esta cadena obtuvo un gran número de investigaciones incluso aquellas que fueron descartadas. Después de realizar varias pruebas con distintas combinaciones de cadenas, se ejecutaron las siguientes:

- "Diseases", "Roses", "Crops", "UAV", "Machine Learning"
- "Diseases", "Roses", "Crops", "UAV", "Deep Learning"

Los resultados obtenidos se muestran en la tabla 8.

**Tabla 8**

### *Resultados de las búsquedas*

Base Digital	"Diseases", "Roses", "Crops", Base Digital "UAV", "Machine Learning	"Diseases", "Roses", "Crops"
ScienceDirect	15	11
Springer	48	40
ProQuest	89	24
IEEE Xplore	26	19

### **Selección de Estudios Primarios**

Al aplicar las cadenas de búsqueda en las bases digitales, se obtuvo alrededor de 544 resultados relacionados con el tema, el cual se consideró un número de artículos manejable; adicionalmente los artículos apuntan y se encuentra dentro del grupo de control. Sin embargo, de todas las bases digitales presentadas en la tabla 7, se escogieron las cadenas de búsqueda con los resultados más bajos y se analizaron de acuerdo al grupo de control.

De los resultados obtenidos, se seleccionaron los estudios realizados a partir del año 2010. Debido a que no existen investigaciones relacionadas con la detección de enfermedades en cultivos de rosas utilizando vehículos aéreos no tripulados (UAV) y el uso de herramientas de aprendizaje automático, los artículos que más se ajustan a la temática se muestran en la tabla 9.

**Tabla 9**

#### *Estudios Seleccionados*

Código	Título	Palabras Clave
EP1	Neuro-kNN classification system for detecting fungal disease on vegetable crops using local binary patterns	Fungal disease, vegetable crops, Artificial Neural Network.
EP2	Plant disease detection by imaging sensors parallels and specific demands for precision agriculture and plant phenotyping	Plants, Disease, Detection.
EP3	Detection of Plant Disease Using Threshold, K-Mean Cluster and ANN Algorithm	Image processing, Thresholding algorithm, K-Means cluster.
EP4	A Performance Assessment of Rose Plant Classification Using Machine Learning	Machine learning, Flower classification.
EP5	Grapes leaves disease detection Through Image Processing	Image processing, intelligent viticulture, segmentation.
EP6	Soybean Leaf Diseases Detection and Clasification using Recent Image Processing Techniques	Segmentation. Soybean, Plant Disease, Image Processing.

## Elaboración del Estado del Arte

### ***EP1 : Neuro-kNN classification system for detecting fungal disease on vegetable crops using local binary patterns***

En este artículo los autores Pujari, Yakkundimath y Byadgi (2014), describen el comportamiento de los clasificadores para la identificación y clasificación de síntomas de enfermedades que se encuentran en cultivos de hortalizas. Los síntomas de enfermedades fúngicas, a saber, antracnosis, mildiú polvoriento, roya, mildiú de Downey, tizón temprano y tizón tardío que se encuentran en un tipo específico de cultivo de hortalizas, se consideran para su reconocimiento y clasificación. Se ha abordado la forma en que se realiza el análisis de la enfermedad considerando ambos lados (porciones frontal y posterior) de las hojas. El análisis de la enfermedad fúngica presente en las hojas, se realiza en una etapa temprana antes de que dañe toda la hoja y posteriormente la planta. Los Patrones Binarios Locales (LBP) extraídos de las hojas afectadas por la enfermedad se utilizan como entrada para los clasificadores. Se ha propuesto un sistema de clasificación integrado Neuro-kNN, del cual se utiliza un clasificador BPNN multicapa con fines de entrenamiento y un clasificador de k-vecino más cercano (k-NN) con fines de prueba. La precisión del reconocimiento se observa utilizando métodos de clasificación de redes neuronales artificiales (ANN) y Neuro-kNN. Se encuentra que la precisión de clasificación promedio es del 84,11% para las muestras de prueba que utilizan ANN. La precisión de clasificación promedio ha aumentado al 91,54 utilizando el clasificador Neuro-kNN. El trabajo encuentra aplicación en el reconocimiento automático de enfermedades fúngicas encontradas en cultivos de hortalizas.

### ***EP2: Plant disease detection by imaging sensors parallels and specific demands for precision agriculture and plant phenotyping***

En esta investigación el autor Mahlein (2016), menciona la importancia de la detección temprana y el diagnóstico preciso de enfermedades en las plantas, ya que son factores clave en la producción de

plantas y la reducción de pérdidas en el rendimiento de los cultivos. Las técnicas ópticas, como las imágenes RGB, los sensores multiespectrales e hiperespectrales, la termografía o la fluorescencia de clorofila, han demostrado su potencial en sistemas de detección automatizados, objetivos y reproducibles para la identificación y cuantificación de enfermedades de las plantas en los primeros momentos de las epidemias. Recientemente, también se ha agregado el escaneo 3D como un análisis óptico que proporciona información adicional sobre la vitalidad de las plantas de cultivo. Se encuentran disponibles diferentes plataformas, desde la detección proximal hasta la remota, para el monitoreo multiescala de órganos de cultivos individuales o campos completos. La detección precisa y confiable de enfermedades, se ve facilitada por métodos de análisis de datos altamente sofisticados e innovadores que conducen a nuevos conocimientos derivados de los datos de los sensores para sistemas complejos de patógenos vegetales. Los métodos no destructivos basados en sensores, apoyan y amplían los enfoques visuales o moleculares para la evaluación de enfermedades de las plantas. Las áreas de aplicación más relevantes de los análisis basados en sensores, son la agricultura de precisión.

### ***EP3 : Detection of Plant Disease Using Threshold, K-Mean Cluster and ANN Algorithm***

En el presente artículo, sus autores Tete y Kamlu (2017), mencionan la importancia de la agricultura en su país, la India; y se enfocan en la detección de enfermedades, el cual juega un papel importante para obtener resultados favorables en la agricultura; también hablan de lo natural que es tener enfermedades en las plantas y mencionan que se puede usar una gran cantidad de técnicas monitoreo y detección autónoma. Este artículo discute diferentes procesos para la técnica de segmentación que se pueden aplicar para la detección de enfermedades. Se realizan algoritmos de agrupamiento de umbrales y K-Mean para detectar diferentes enfermedades en las hojas de las plantas.

#### ***EP4: A Performance Assessment of Rose Plant Classification Using Machine Learning***

El aprendizaje automático enriquece el campo de la inteligencia artificial. La identificación de flores es muy importante y relevante para los científicos de plantas; realizarlo de forma manual no solo es una tarea tediosa sino también propensa a errores debido a la gran cantidad de tipos de flores. El uso de algoritmos de aprendizaje automático para identificar flores es atractivo, para este propósito, dos observaciones sobre las hojas de las flores son relevantes y aprovechan la identificación de las flores: uno, las plantas de flores tienen un conocimiento clave en sus hojas, lo que permite su distinción; dos, las hojas tienen una vida mucho más larga en las plantas que las flores y los frutos. En este artículo, los autores Malik, Ikram, Batool y Aslam (2018), han propuesto un enfoque de aprendizaje automático basado en (k-NN) para identificar los tipos de rosas. Los siguientes pasos se llevan a cabo durante el proceso de identificación. Primero, se toman imágenes de plantas de rosas con una cámara de 23 MP, lo que garantiza la uniformidad de temperatura durante el experimento; en segundo lugar, las características de textura e histograma se extraen de las imágenes capturadas; en tercer lugar, el algoritmo k-NN se aplica a estas características con k tomando valores entre 1 y 10. La investigación destaca la utilidad de características seleccionadas para la identificación del tipo de rosa con características de histograma y textura que alcanzan una precisión máxima del 65% y 45,50% respectivamente.

#### ***EP5: Grapes leaves disease detection Through Image Processing***

En este artículo el autor Gómez Rea (2014), utiliza la detección automática de Downey Mildew de los viñedos, basada en técnicas de procesamiento de imágenes. Esta técnica puede detectar el ataque en las hojas, incluso en la fase de inicio y puede prevenir la propagación de la infección por todo el viñedo; además, esta técnica se puede aplicar en campos relativamente gigantes, requiere una cantidad de tiempo reducida, costos más bajos e identifica la enfermedad de manera rápida y precisa. En

este trabajo, los autores monitorean el grado de ataque de dos cultivares de cepa del cultivo, las imágenes tomadas se cargaron en la aplicación Matlab. En la primera etapa, las hojas se pre-procesan con un filtro mediano; en el siguiente paso, para detectar las manchas típicas, transformamos las imágenes en espacios de color: RGB, YcbCr, HSV y CieLab; en estos espacios de color aplicamos las técnicas de segmentación de imágenes basadas en métodos de umbral. Los resultados experimentales obtenidos muestran que en el espacio modelo del VHS, la enfermedad se reconoció correctamente y la variedad Sauvignon Blanc fue la más afectada.

#### ***EP6: Soybean Leaf Diseases Detection and Classification using Recent Image Processing Techniques***

En esta investigación los autores Rajput, Shukla y Thakur (2020), mencionan que en su país de origen, India es un país agrícola y la producción de soja es una de las principales fuentes de ingresos. Debido a factores importantes como enfermedades, ataques de plagas y cambios repentinos en las condiciones climáticas, la productividad del cultivo de soja disminuye. La detección automática de enfermedades de la planta de soja es esencial para detectar los síntomas de las enfermedades de la soja tan pronto como aparecen en la etapa de crecimiento. Este artículo propuso una metodología para el análisis y detección de enfermedades de las hojas de la planta de soja utilizando técnicas recientes de procesamiento de imágenes digitales. En este artículo, los resultados experimentales demuestran que el método propuesto puede detectar y clasificar con éxito la principal enfermedad de la soja.

## Capítulo III

### Metodología y Desarrollo de la Investigación

#### Metodología de la Investigación

##### ***Enfoque de investigación: Cuantitativo***

Hernández-Sampieri y Mendoza Torres (2018), mencionaron que la investigación es un conjunto de procesos sistemáticos y empíricos que se aplican al estudio de un fenómeno, en este proceso, el enfoque cuantitativo tiene orientación hacia la descripción, predicción y explicación; además, utiliza la recolección de datos para probar hipótesis con base a mediciones numéricas y análisis estadísticos para establecer pautas de comportamiento y probar teorías; en este sentido, la presente investigación maneja un enfoque de tipo cuantitativo, ya que utiliza datos medibles y observables, que sometidos a un análisis, se pretende transformar estos datos en resultados cuantificables.

En la investigación cuantitativa se destaca el desarrollo de programas computacionales que han permitido mejorar procesos; así mismo, se han realizado numerosas investigaciones que, mediante el enfoque cuantitativo, se han obtenido resultados más objetivos y precisos (Hernández-Sampieri & Mendoza Torres, 2018).

##### ***Tipología de investigación***

###### **Por su finalidad: Aplicada.**

Al aplicar el enfoque cuantitativo se desarrollará el estudio de manera secuencial y desde una perspectiva objetiva, es decir que implica el conocimiento de la realidad tal y como es; se pretende generalizar los resultados obtenidos a una colectividad mayor; es decir, que una vez obtenido el modelo con el entrenamiento de la red neuronal, y aplicado para el monitoreo de Oidio (*Sphaerotheca pannosa*) en la plantación de rosas, se espera que dichos resultados, puedan replicarse y ser usados en futuras investigaciones.

**Por el control de las variables: No experimental.**

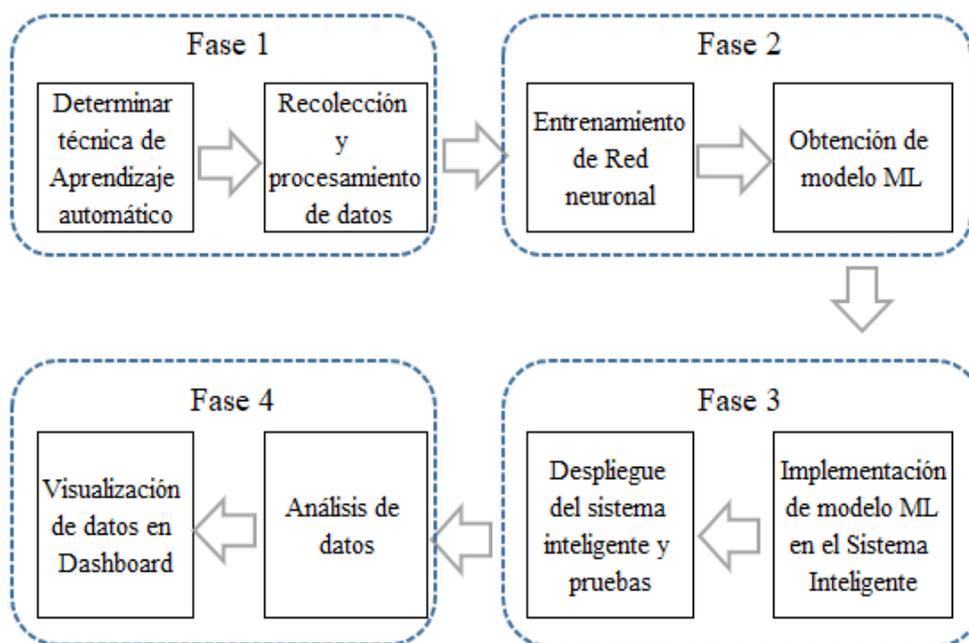
El diseño de la investigación es no experimental, ya que el estudio de las variables se realizará sin manipulación deliberada de las mismas en su ambiente natural; es decir se obtienen datos de situaciones existentes, para el caso del presente estudio, se obtienen datos de la enfermedad Oidio (*Sphaerotheca pannosa*), que no ha sido provocada intencionalmente ni se manipulada.

**Por el alcance: Exploratoria.**

El alcance de este estudio es exploratorio, ya que se indaga desde una perspectiva innovadora; tal es el caso de la presente investigación, que pretende implementar una técnica de aprendizaje automático que permita identificar *Oidium sphaerotheca pannosa* en el cultivo de rosas, para posteriormente implementar una arquitectura IOT en UAV para la captación de datos con fines de monitoreo de la enfermedad en mención.

**Diseño y desarrollo de Investigación**

Hernández-Sampieri y Mendoza Torres (2018), mencionaron que el diseño es un plan o estrategia, que se desarrolla para realizar una investigación; en este contexto, para el desarrollo de la presente investigación se establece el siguiente proceso, como se muestra en la Figura 7.

**Figura 7***Proceso de la investigación***Fase 1****Técnica de Aprendizaje automático.**

En los últimos años, las técnicas de aprendizaje automático han sido consideradas en el sector agrícola para el reconocimiento automático de enfermedades o plagas en las plantas, lo cual tiene el potencial de convertirse en valiosa fuente de información para la toma de decisiones (Bhange & Hingoliwala, 2015).

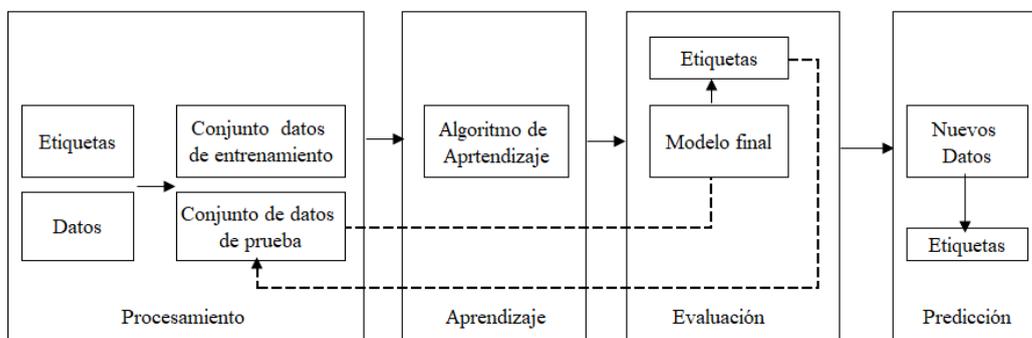
Se han desarrollado algoritmos de aprendizaje automático que se aplican para resolver diferentes problemas, cada algoritmo de clasificación tiene sus sesgos inherentes (Ortega, Biswal, & De la Cruz, 2019); en la Tabla 10 se muestran los algoritmos y sus particularidades:

**Tabla 10***Algoritmos y características*

Algoritmo	Características
Fuzzy Logic	Se basa en reglas heurísticas, se utiliza para procesos no lineales.
SVM	Busca un hiperplano que funciona como separador
Bayes	No requiere de gran cantidad de datos para su entrenamiento
KNN	Busca observaciones más cercanas a la que está tratando de predecir y clasifica el punto de interés basado en la mayoría de los datos de entrenamiento
ANN	Clasificación eficiente, alto costo computacional
CNN	Tiende a ser más preciso, puede requerir un número considerable de imágenes para producir resultados fiables.

Fuente: Ortega, B. R., Biswal, R. R., & Delacruz, E. S. (2019). Detección de enfermedades en el sector agrícola utilizando Inteligencia Artificial. *Research in Computing Science*, 148, 419-427.

Para la clasificación de enfermedades, autores se basan en metodologías probadas que han permitido obtener resultados asertivos (Ortega, Biswal, & De la Cruz, 2019); en el siguiente diagrama, se muestra el flujo de trabajo para usar el aprendizaje automático:

**Figura 8***Diagrama de flujo de trabajo Sistema de Aprendizaje Automático*

Fuente: Raschka, S., Mirjalili, V. (2017). Giving computers the ability to learn from data. *Python Machine Learning* (pp.1-15). India: Packt, 2ed

En la investigación de Ortega , Biswal y De la Cruz (2019), realizan una revisión de trabajos significativos relacionados con la utilización de diferentes algoritmos de aprendizaje automático para la detección de enfermedades en diferentes tipos de plantas, del cual concluyen que los estudios que obtuvieron mejores resultados, son aquellos en los que se utilizó redes neuronales convolucionales; así también Barbedo (2019), en su investigación en la que utilizó este tipo de redes neuronales, concluye que es la mejor forma de hacer este tipo de estudios, donde la única limitante es la disponibilidad de grandes cantidades de datos para poder entrenar la red.

Para el desarrollo de la presente Investigación, se utilizará la Técnica de Aprendizaje Automático supervisado con la clasificación de imágenes por medio del uso de redes convolucionales profundas o conocidas como CNNs por su nombre en inglés: Convolutional Neural Networks.

Las redes neuronales convolucionales CNN son modelos que se inspiraron en el funcionamiento de la corteza visual del cerebro humano al reconocer objetos, cuyo desarrollo se remonta a la década de los años noventa, con la investigación de Yann LeCun para clasificar dígitos escritos a mano a partir de imágenes, quien recientemente ganó el premio Turing, por sus contribuciones a los conocimientos de Inteligencia Artificial (IA) (Raschka & Mirjalili, 2017).

Debido al desempeño sobresaliente de las CNN para la clasificación de imágenes, su uso es cada vez más tendente para este tipo de investigaciones, puesto a que se obtienen diagnósticos más cercanos a los que un experto humano determinaría, sus únicas limitaciones son el alto costo computacional y la cantidad de datos que requiere para el entrenamiento de la red neuronal (Ortega, Biswal, & De la Cruz, 2019).

### Recolección de datos.

La información se recopila mediante el uso de cámaras digitales, de resolución 16MP, con la cual se recopila imágenes de las hojas y partes de la planta, donde es visible el daño causado por la enfermedad.

Las imágenes adquiridas, fueron capturadas en condiciones reales de campo, en el invernadero de cultivo de rosas del campus IASA I de la Universidad de las Fuerzas Armadas ESPE.

De la recolección de datos realizada, se obtienen 1061 imágenes con las siguientes características:

**Tabla 11**

*Características imágenes*

Característica	Detalle
Tipo de Imagen	jpeg(JPEG)
Ancho	4032 px
Alto	3016 px
Tamaño en disco	Desde 2,2 MB (2.218.101 bytes) a 6,3MB (6.269.444 bytes)

A continuación, se muestran en las figuras algunos de los ejemplos de las imágenes recolectadas:

**Figura 9**

*Oidio en hoja de rosa*



Nota: Toma de Oidio en hojas de rosal

**Figura 10**

*Oidio en hoja de rosa*



Nota: Toma de Oidio en hojas de rosal

**Figura 11**

*Oidio en hoja y tallo de rosa*



Nota: Toma de Oidio en hojas, receptáculo, tallo de rosal

**Figura 12**

*Oidio en hojas de rosa*



Nota: Toma de Oidio en hojas de rosal

**Figura 13**

*Oidio en tallo y hojas de rosa*



Nota: Toma de Oidio en tallo de rosal

**Figura 14**

*Oidio en tallo y hojas de rosa*



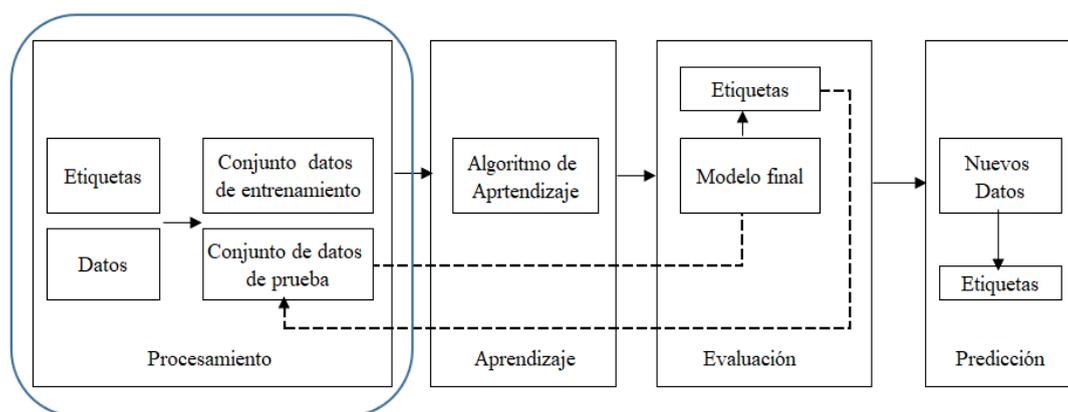
Nota: Toma de Oidio en hojas, receptáculo, tallo de rosal

### Procesamiento de datos.

Dentro del Procesamiento de datos y según señala Raschka y Mirjalili (2017), en el diagrama de flujo de trabajo para usar el sistema de aprendizaje automático, los datos brutos se revisan y se descartan aquellas imágenes con ruido y que podrían ocasionar fallas en el entrenamiento de la red neuronal.

**Figura 15**

*Diagrama de flujo de trabajo Sistema de Aprendizaje Automático*



Nota: Se señala en recuadro azul la parte de Procesamiento, fase que se describe en esta sección. Fuente: Raschka, S., Mirjalili, V. (2017). Giving computers the ability to learn from data. Python Machine Learning (pp.1-15). India: Packt, 2ed

En esta investigación, como **pre-procesamiento** se descartan las imágenes de manera manual, no de manera computacional, para lo cual, del total de imágenes capturadas, como primer paso se revisan y descartan aquellas que tienen ruido. Se entiende por ruido digital, a la variación aleatoria del brillo o color en una imagen digital, que hace que pierda su calidad y desenfoque; esto sucede al momento de capturar la imagen.

Como segundo paso, con el apoyo de la Dra. Elizabeth Urbano, Docente del Departamento de Ciencias de la Vida y Agricultura de la Universidad de las Fuerzas Armadas ESPE; y encargada del invernadero de rosas del IASA I, se descartan las imágenes según los siguientes criterios:

- No tienen relevancia
- No se visualiza la enfermedad
- Tienen otras enfermedades que no corresponden a oídio
- Se confunde la enfermedad con manchas de un químico

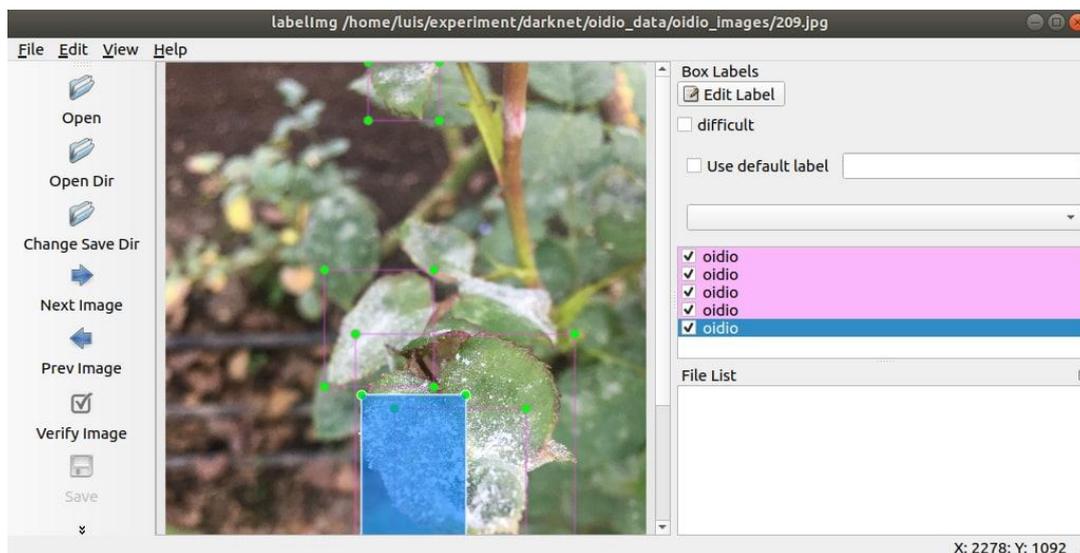
Una vez descartadas las imágenes, se obtiene como resultado un total de 413 imágenes viables. Como siguiente paso se realiza el **etiquetado** mediante el cual, se identifica la enfermedad en las imágenes.

Existen herramientas que ayudan a etiquetar, marcar cajas delimitadas de objetos y crear archivos de anotaciones, los software más utilizados actualmente, según señalan Yu, Chen, Lee, Chen y Hsiao (2019), son: LabelMe, Labellmg. Para la presente investigación, se utiliza **Labellmg**, una herramienta de anotación de imágenes gráficas, escrito en Python y usa Qt para su interfaz gráfica (Tzutalin, 2015).

Labellmg, es un software de código abierto en Github, desarrollado para proporcionar una muestra para el entrenamiento en aprendizaje automático (Yu, Chen, Lee, Chen, & Hsiao, 2019); este software de código abierto (opensource) proporciona una interfaz amigable para que el usuario anote la muestra, la modifique y se seleccione la muestra que se necesita.

**Figura 16**

*Sistema de Interfaz de usuario LabelImg para etiquetar odio en rosal*



Cabe recalcar, que el desarrollo del sistema inteligente propuesto en esta investigación, fue construido en sistema operativo Linux, por lo que para la instalación de LabelImg, se requiere Python 2.6; sin embargo, se recomienda Python 3 o superior (Tzutalin, 2015); para el caso se utilizó Python 3.

**Figura 17**

*Líneas de comando para instalación LabelImg en Python 3*

**Ubuntu Linux**

Python 3 + Qt5

```
sudo apt-get install pyqt5-dev-tools
sudo pip3 install -r requirements/requirements-linux-python3.txt
make qt5py3
python3 labelImg.py
```

Nota: Sistema Operativo Ubuntu Linux 18.04

Una vez etiquetadas las imágenes en LabelImg, las anotaciones se guardan como archivos TXT, con estándar de etiquetado YOLO, framework que posteriormente se utiliza para el entrenamiento de la red neural.

## **Fase 2**

### **Entrenamiento de Red Neuronal.**

Existen sistemas de detección, que trabajan tomando un clasificador para un objeto y evalúan en varias ubicaciones y escalas una imagen de prueba, otros sistemas como modelos (DPM) utilizan un enfoque donde el clasificador se ejecuta en ubicaciones espaciadas uniformemente en toda la imagen (Redmon, Darknet: Open Source Neural Networks in C , 2016), este modelo de pieza deformable (DMP), antes del surgimiento de la red neuronal convolucional, ha sido utilizado como detector durante varios años; recientemente, por el alto rendimiento demostrado, las CNN, se han aplicado en la detección de imágenes, se han propuesto varios métodos para la detección de objetos, como el uso de R-CNN; sin embargo, la mayoría de técnicas se centran en lograr alta precisión en la detección de objetos, pero conlleva un alto costo computacional (Putra, Yussof , Lim, & Salim, 2018), además, el R-CNN utiliza complejas canalizaciones que son lentas y difíciles de optimizar, ya que cada componente individual debe entrenarse por separado.

En este contexto, un enfoque diferente de detección de imágenes basada en CNN llamada YOLO, logra alta precisión en la detección de objetos y operación en tiempo real; el uso de este framework fue propuesto por Redmon, Divvala, Girshick y Farhadi (2016); el cual, a diferencia de R-CNN, predice los cuadros delimitadores y la clase de probabilidades directamente de las imágenes completas en una sola evaluación (Putra, Yussof , Lim, & Salim, 2018).

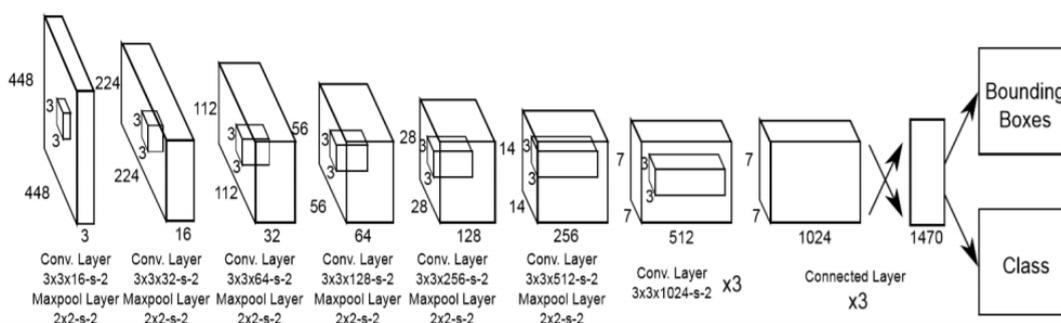
Como se mencionó anteriormente, para el entrenamiento de la red neuronal, en esta investigación, se va a utilizar el **Framework YOLO** (You Only

Look Once). Yolo entrena imágenes completas y optimiza el rendimiento de detección, una sola red convolucional predice simultáneamente múltiples cuadros delimitadores y probabilidades de clase para esos cuadros; este modelo tiene varios beneficios por sobre otros métodos de detección de objetos, por ejemplo es rápido y no necesita una canalización compleja y logra mayor precisión a comparación de otros sistemas en tiempo real (Redmon, Divvala, Girshick, & Farhadi, 2016).

La arquitectura YOLO, está compuesta por 27 capas CNN: 24 capas convolucionales, 2 capas completamente conectadas y 1 capa de detección final.

**Figura 18**

*Arquitectura YOLO*



Fuente: Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 779-788).

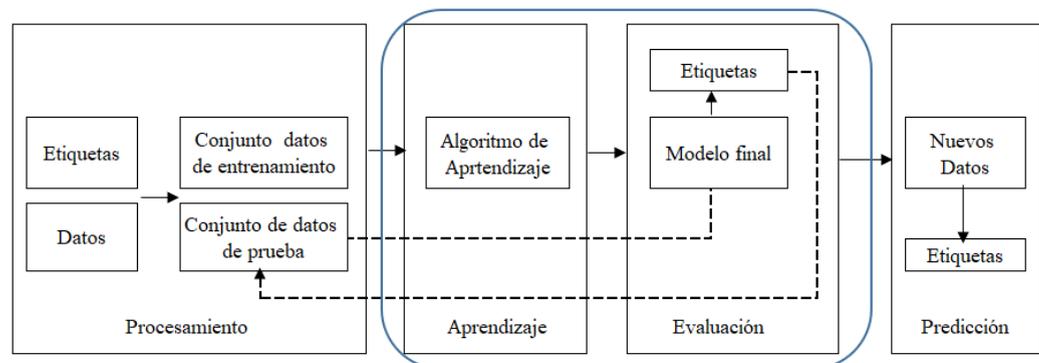
Este sistema, divide la imagen de entrada en una cuadrícula  $S \times S$  y dentro de cada celda de la cuadrícula predice  $B$  cuadros delimitadores y una puntuación para cada una de las clases  $C$ ; cada cuadro delimitador consta de 5 predicciones que son centro  $x$ , centro  $y$ , ancho, alto y confianza del cuadro delimitador. Para cada celda de la cuadrícula, habrá un solo conjunto de puntuaciones de clase  $C$  para todos los cuadros delimitadores en esa región; por tanto, la salida YOLO será un vector de números  $S \times S \times (5B+C)$  para cada imagen (Putra, Yussof, Lim, & Salim, 2018).

Las capas completamente conectadas utilizan las características extraídas de las capas convolucionales y utilizan la información para predecir probabilidades del objeto y al mismo tiempo para construir el cuadro delimitador; la capa de detección final de YOLO, es una regresión que mapea la salida de la última completamente capa conectada, al cuadro delimitador final y las asignaciones de clase (Putra, Yussof , Lim, & Salim, 2018).

Este modelo se ejecuta a 45 fotogramas por segundo en nVidia Titan X; un fotograma por segundo (fps), es la frecuencia a la cual un dispositivo muestra imágenes llamadas fotogramas o cuadros; la GPU y una versión más rápida funcionan a más de 150 fps (Putra, Yussof , Lim, & Salim, 2018).

**Figura 19**

*Diagrama de flujo de trabajo Sistema de Aprendizaje Automático*



Nota: Se señala en recuadro azul, el diagrama de flujo para el entrenamiento y evaluación de la red neuronal. Fuente: Raschka, S., Mirjalili, V. (2017). Giving computers the ability to learn from data. Python Machine Learning (pp.1-15). India: Packt, 2ed

Para el entrenamiento, se utilizó la configuración predeterminada de YOLO, estableciendo los directorios donde se encuentran las imágenes, el número de imágenes para entrenamiento y número de imágenes de prueba. Se definió una clase de nombre "oidio" que lleva el mismo nombre que el etiquetado de las imágenes.

**Tabla 12***Imágenes para entrenamiento*

Nombre	Cantidad
Imágenes totales	413
Imágenes para entrenamiento	235
Imágenes para pruebas	178

Nota: Datos de número de Imágenes viables

En la Figura 18, se muestra el archivo de configuración de Yolo, para el entrenamiento de la red neuronal.

**Figura 20***Configuración de YOLO para entrenamiento*

```
classes=1
train = oidio_data/oidio_training.txt
valid = oidio_data/oidio_testing.txt
names = oidio_data/oidio.names
backup= backup
```

Posteriormente, se desplegó el framework YOLO en el sistema operativo Ubuntu 18.04, y se instalaron las dependencias necesarias para el funcionamiento del mismo, Redmon, Darknet: Open Source Neural Networks in C (2016), sugiere que, una vez configurado el framework YOLO, se despliegue un comando de prueba, para verificar que dicho framework se encuentra instalado correctamente.

## Figura 21

### Comando de verificación de instalación correcta

Test - Framework

```

▶ !./darknet detector test cfg/coco.data cfg/yolov4.cfg yolov4.weights data/person.jpg
☐ CUDA-version: 10010 (10010), cuDNN: 7.6.5, GPU count: 1
  OpenCV version: 3.2.0
  0 : compute_capability = 600, cudnn_half = 0, GPU: Tesla P100-PCIE-16GB
  net.optimized_memory = 0
  mini_batch = 1, batch = 8, time_steps = 1, train = 0
  layer  filters  size/strd(dil)  input  output
  0 conv  32  3 x 3/ 1  608 x 608 x 3 -> 608 x 608 x 32 0.639 BF
  1 conv  64  3 x 3/ 2  608 x 608 x 32 -> 304 x 304 x 64 3.407 BF
  2 conv  64  1 x 1/ 1  304 x 304 x 64 -> 304 x 304 x 64 0.757 BF
  3 route 1
  4 conv  64  1 x 1/ 1  304 x 304 x 64 -> 304 x 304 x 64 0.757 BF
  5 conv  32  1 x 1/ 1  304 x 304 x 64 -> 304 x 304 x 32 0.379 BF
  6 conv  64  3 x 3/ 1  304 x 304 x 32 -> 304 x 304 x 64 3.407 BF
  7 Shortcut Layer: 4, wt = 0, wn = 0, outputs: 304 x 304 x 64 0.006 BF
  8 conv  64  1 x 1/ 1  304 x 304 x 64 -> 304 x 304 x 64 0.757 BF
  9 route 8 2
 10 conv  64  1 x 1/ 1  304 x 304 x 128 -> 304 x 304 x 64 1.514 BF
 11 conv 128  3 x 3/ 2  304 x 304 x 64 -> 152 x 152 x 128 3.407 BF
 12 conv  64  1 x 1/ 1  152 x 152 x 128 -> 152 x 152 x 64 0.379 BF
 13 route 11
 14 conv  64  1 x 1/ 1  152 x 152 x 128 -> 152 x 152 x 64 0.379 BF
 15 conv  64  1 x 1/ 1  152 x 152 x 64 -> 152 x 152 x 64 0.189 BF
 16 conv  64  3 x 3/ 1  152 x 152 x 64 -> 152 x 152 x 64 1.703 BF
 17 Shortcut Layer: 14, wt = 0, wn = 0, outputs: 152 x 152 x 64 0.001 BF
 18 conv  64  1 x 1/ 1  152 x 152 x 64 -> 152 x 152 x 64 0.189 BF
 19 conv  64  3 x 3/ 1  152 x 152 x 64 -> 152 x 152 x 64 1.703 BF
 20 Shortcut Layer: 17, wt = 0, wn = 0, outputs: 152 x 152 x 64 0.001 BF
 21 conv  64  1 x 1/ 1  152 x 152 x 64 -> 152 x 152 x 64 0.189 BF

```

Una vez se comprueba que el framework está bien instalado, se ejecuta el comando para iniciar el proceso de entrenamiento de la red neuronal.

Para el entrenamiento de esta red neuronal se utilizó los pesos de las capas convolucionales del framework yolov4, el uso de estos pesos ayuda a que la detección de objetos sea mucho más precisa y el tiempo de entrenamiento no sea extenso.

## Figura 22

Comando para ejecutar entrenamiento de la red neuronal

```

[ ] !rm /content/darknet/backup/ -r

[ ] !ln -s /content/drive/MyDrive/oidio_weights/backup/ /content/darknet/

$pwd

' /content/darknet'

[ ] !./darknet detector train oidio_data/oidio.data oidio_yolov4.cfg yolov4.conv.137 -map -dont_show

Streaming output truncated to the last 5000 lines.
Last accuracy mAP@0.5 = 41.25 %, best = 55.11 %
1907: 2.342351, 2.061134 avg loss, 0.000013 rate, 4.624338 seconds, 114420 images, 0.662615 hours left
Loaded: 5.620093 seconds - performance bottleneck on CPU or Disk HDD/SSD
v3 (iou loss, Normalizer: (iou: 0.07, obj: 1.00, cls: 1.00) Region 139 Avg (IOU: 0.805134), count: 29, class_loss = 1.194070, iou_loss = 45.951099, total_loss = 46.145169) %
v3 (iou loss, Normalizer: (iou: 0.07, obj: 1.00, cls: 1.00) Region 150 Avg (IOU: 0.859837), count: 90, class_loss = 0.736138, iou_loss = 36.925545, total_loss = 37.661683) %
v3 (iou loss, Normalizer: (iou: 0.07, obj: 1.00, cls: 1.00) Region 161 Avg (IOU: 0.828078), count: 30, class_loss = 0.225232, iou_loss = 3.128982, total_loss = 3.354214) %
total_bbox = 3745211, rewritten_bbox = 0.544802 %
v3 (iou loss, Normalizer: (iou: 0.07, obj: 1.00, cls: 1.00) Region 139 Avg (IOU: 0.903853), count: 11, class_loss = 0.723265, iou_loss = 26.472866, total_loss = 27.196131) %
v3 (iou loss, Normalizer: (iou: 0.07, obj: 1.00, cls: 1.00) Region 150 Avg (IOU: 0.886434), count: 65, class_loss = 0.750583, iou_loss = 24.421894, total_loss = 25.172477) %
v3 (iou loss, Normalizer: (iou: 0.07, obj: 1.00, cls: 1.00) Region 161 Avg (IOU: 0.881728), count: 33, class_loss = 0.265692, iou_loss = 3.221661, total_loss = 3.487353) %
total_bbox = 3745320, rewritten_bbox = 0.544787 %
v3 (iou loss, Normalizer: (iou: 0.07, obj: 1.00, cls: 1.00) Region 139 Avg (IOU: 0.826555), count: 16, class_loss = 0.430829, iou_loss = 22.743643, total_loss = 23.174472) %
v3 (iou loss, Normalizer: (iou: 0.07, obj: 1.00, cls: 1.00) Region 150 Avg (IOU: 0.883534), count: 64, class_loss = 0.946355, iou_loss = 30.896387, total_loss = 31.842742) %
v3 (iou loss, Normalizer: (iou: 0.07, obj: 1.00, cls: 1.00) Region 161 Avg (IOU: 0.888868), count: 23, class_loss = 0.005458, iou_loss = 2.734756, total_loss = 2.740214) %
total_bbox = 3745423, rewritten_bbox = 0.544798 %
v3 (iou loss, Normalizer: (iou: 0.07, obj: 1.00, cls: 1.00) Region 139 Avg (IOU: 0.879334), count: 22, class_loss = 0.283711, iou_loss = 41.604683, total_loss = 41.888394) %
v3 (iou loss, Normalizer: (iou: 0.07, obj: 1.00, cls: 1.00) Region 150 Avg (IOU: 0.877406), count: 71, class_loss = 1.339222, iou_loss = 29.262463, total_loss = 30.601685) %
v3 (iou loss, Normalizer: (iou: 0.07, obj: 1.00, cls: 1.00) Region 161 Avg (IOU: 0.860932), count: 27, class_loss = 0.413089, iou_loss = 3.217389, total_loss = 3.630478) %
total_bbox = 3745543, rewritten_bbox = 0.544781 %

```

Nota: Screen completo

## Figura 23

Comando para ejecutar entrenamiento de la red neuronal

```

!./darknet detector train oidio_data/oidio.data oidio_yolov4.c

Streaming output truncated to the last 5000 lines.
v3 (iou loss, Normalizer: (iou: 0.07, obj: 1.00, cls: 1.00) Re
v3 (iou loss, Normalizer: (iou: 0.07, obj: 1.00, cls: 1.00) Re
total_bbox = 4037530, rewritten_bbox = 0.031356 %

```

El tiempo de procesamiento en el entrenamiento de la red neuronal, puede variar según la capacidad de hardware, donde se haya ejecutado; para este caso, se ejecutó en la plataforma Google Colab, la cual cuenta con una tarjeta gráfica Nvidia Tesla P100-16GB.

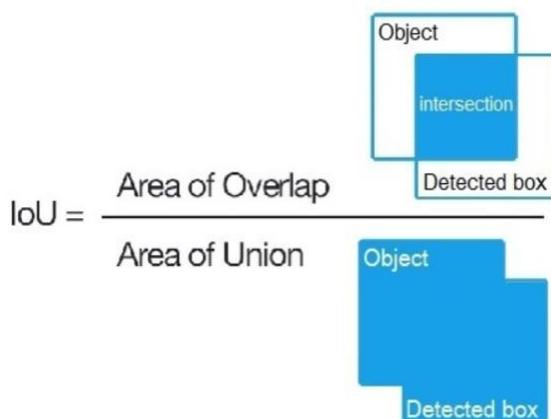
### Obtención del Modelo de Aprendizaje Automático.

Para entender los resultados que se muestran en la Tabla 13, a continuación, se describe una breve explicación de los siguientes parámetros:

**Intersect Over Union (IoU)** o Intersección sobre la Unión, se puede entender como el área de intersección dividida sobre el área de unión de dos cajas delimitadoras, el IoU debe ser  $\geq 0$  y  $\leq 1$ ; es importante observar la precisión del IoU para garantizar que YOLO está siendo entrenado adecuadamente (Redmon, Darknet: Open Source Neural Networks in C , 2016).

**Figura 24**

*Intersect Over Union*



Fuente: Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016).

La **Precisión** se puede definir como la proporción de verdaderas predicciones positivas (TP) o true predictions y el número total de predicciones positivas, la fórmula es la siguiente:

$$\text{Precisión} = \frac{TP}{TP + FP} = \frac{TP}{N}$$

Donde:

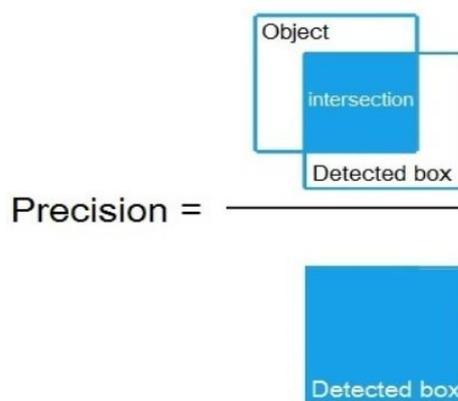
TP: True positives (verdaderos positivos)

FP: False positives (Falsos positivos)

N: Es igual al número total de objetos recuperados

### Figura 25

*Precisión*



Fuente: Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016).

El **Recall** o recuperación es un parámetro que mide la proporción de detecciones positivas (TP) o true predictions correctamente etiquetadas (Redmon, Darknet: Open Source Neural Networks in C , 2016), la fórmula es la siguiente:

$$\text{Recuperación} = \frac{TP}{TP + FN}$$

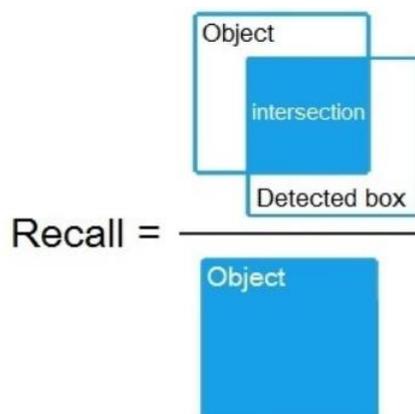
Donde:

TP: True positives (verdaderos positivos)

FN: False negatives (Falsos negativos)

**Figura 26**

*Recall*



Fuente: Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016).

**Mean Average Precision (mAP)** es una métrica para medir la precisión de detectores de objetos, calcula el valor de precisión promedio para el valor de recuperación por encima de 0 a 1, es el área bajo la curva de precisión – recuperación (Redmon, Darknet: Open Source Neural Networks in C , 2016); la fórmula es la integral de precisión:

$$mAP = \int_0^1 p(r)dr$$

Al finalizar el entrenamiento de la red neuronal, utilizando el framework YOLO v4, se obtuvieron los siguientes resultados:

**Tabla 13***Resultados*

Interacciones	mAP	TP	FP	FN	IoU
2000	73,1%	250	28	133	79,70%

Nota: Resultados obtenidos del modelo entrenado.

**Figura 27***Resultados obtenidos al final del entrenamiento de la red neuronal*

```
+ Code + Text

Resizing to initial size: 416 x 416 try to allocate additional workspace_size = 62.30 MB
CUDA allocate done!

calculation mAP (mean average precision)...
Detection layer: 139 - type = 28
Detection layer: 150 - type = 28
Detection layer: 161 - type = 28
48
detections_count = 456, unique_truth_count = 383
class_id = 0, name = oidio, ap = 73.07% (TP = 250, FP = 28)

for conf_thresh = 0.25, precision = 0.90, recall = 0.65, F1-score = 0.76
for conf_thresh = 0.25, TP = 250, FP = 28, FN = 133, average IoU = 79.70 %

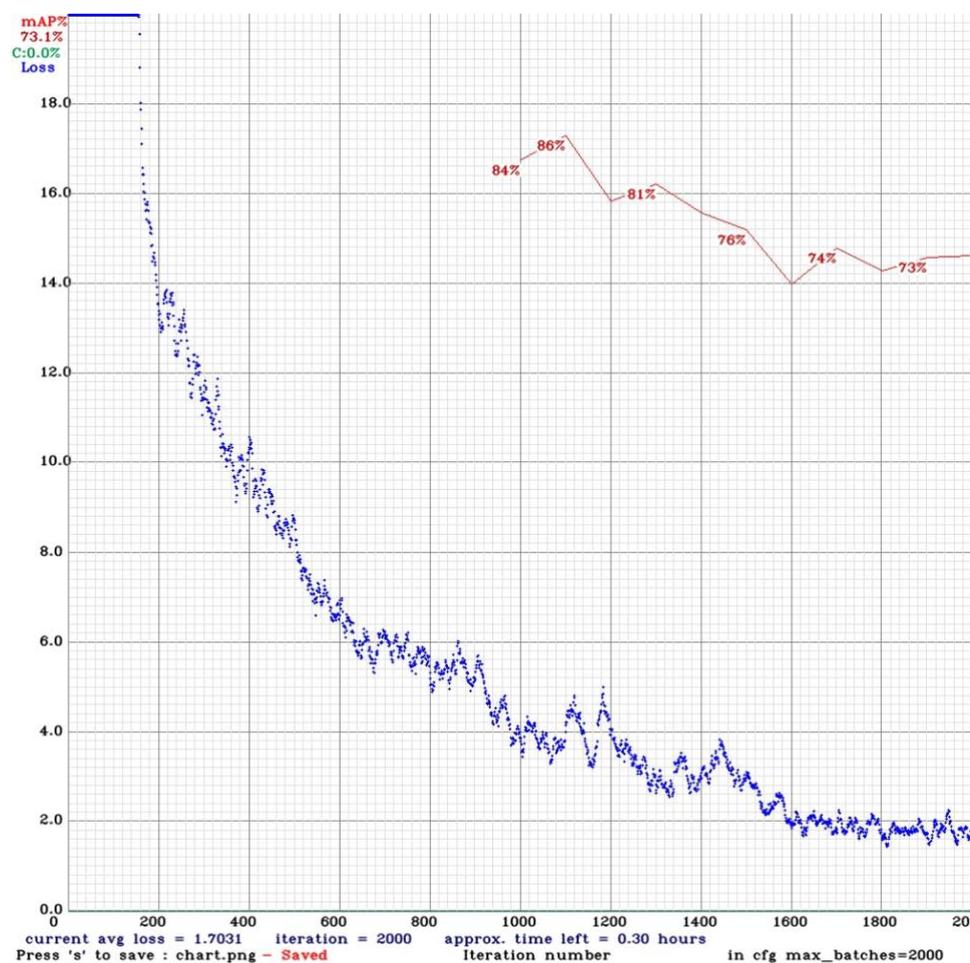
IoU threshold = 50 %, used Area-Under-Curve for each unique Recall
mean average precision (mAP@0.50) = 0.730724, or 73.07 %
Total Detection Time: 7 Seconds

Set -points flag:
`-points 101` for MS COCO
`-points 11` for PascalVOC 2007 (uncomment `difficult` in voc.data)
`-points 0` (AUC) for ImageNet, PascalVOC 2010-2012, your custom dataset

mean_average_precision (mAP@0.5) = 0.730724
Saving weights to backup/oidio_yolov4_2000.weights
Saving weights to backup/oidio_yolov4_last.weights
Saving weights to backup/oidio_yolov4_final.weights
If you want to train from the beginning, then use flag in the end of training command: -clear
```

Figura 28

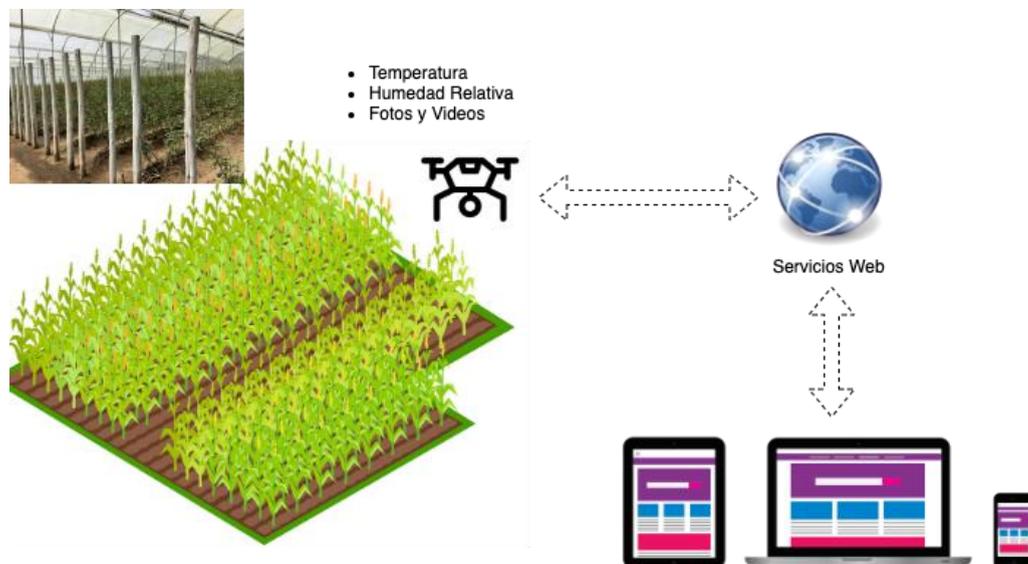
Gráfico de resultados de entrenamiento de la red neuronal



### Fase 3

#### Implementación de modelo de Aprendizaje de Sistema Automático.

Una vez obtenido el modelo de aprendizaje automático, se desarrolló un Sistema Inteligente, el cual fue implementado en **Phyton**, lenguaje de programación orientado a objetos con una sintaxis bastante clara, posee diferentes módulos, clases y excepciones, con datos y escritura dinámica; este lenguaje también es utilizado como un lenguaje de extensión para aplicaciones escritas en otros lenguajes (Holden, 2018).

**Figura 29***Arquitectura de Sistema Inteligente*

El Sistema Inteligente, que se muestra en la figura, está compuesto por la arquitectura IOT (hardware y software), servicio web, base de datos y dashboard. Para la arquitectura IOT, se utiliza un Raspberry Pi, un sensor de humedad y temperatura; cabe mencionar que sistema va a bordo de una UAV. En este sentido se especifican los siguientes conceptos y ficha técnica de las herramientas y partes electrónicas utilizadas:

**Raspberry Pi** es una computadora de placa reducida, formada por una arquitectura de un computador clásico, como un CPU, memoria RAM, puertos serial y entradas análogas, las cuales están administradas por un sistema operativo; es un ordenador flexible que se puede integrar en proyectos electrónicos y tareas básicas que haría cualquier ordenador, y puede compilar diferentes tipos de lenguajes de programación (Richardson & Wallace, 2012).

**Tabla 14***Raspberry Pi3 B+*

---

**Características**

---

CPU + GPU: Broadcom BCM2837B0, Cortex-A53 (ARMv8) 64-bit SoC @ 1.4GHz.

RAM: 1GB LPDDR2 SDRAM.

Wi-Fi + Bluetooth: 2.4GHz y 5GHz IEEE 802.11. b/g/n/ac, Bluetooth 4.2, BLE.

Ethernet: Gigabit Ethernet sobre USB 2.0 (300 Mbps)

GPIO de 40 pines.

HDMI.

4 puertos USB 2.0.

Puerto CSI para conectar una cámara.

---

**Figura 30***Raspberry Pi 3*

El **sensor DHT11** es un módulo de sensor de humedad y temperatura, pequeño y sencillo de utilizar, ya que permite obtener información utilizando un pin del Raspberry Pi 3; y existen librerías que permiten obtener las lecturas, para este caso se utilizó la librería Adafruit DHT11. En la Tabla 15 se muestran las especificaciones técnicas del sensor en mención.

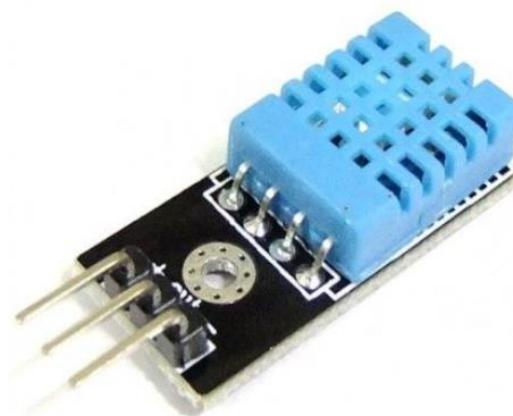
**Tabla 15**

*Sensor DHT11*

Características	
Alimentación	3,3V a 5V
Consumo	2,5 mA
Señal de salida	Digital
Temperatura	
Rango	de 0C a 50C
Precisión	a 25C +/- 2C
Resolución	1C
Humedad	
Rango	de 20% al 90% HR
Precisión	+/- 5%
Resolución	1%

**Figura 31**

*Sensor de Humedad y Temperatura DHT11*



Se utiliza una **Batería recargable Tenergy NiMH** de 6v de potencia, de alta durabilidad, funciona con receptores RC, pesa 5onzas, fabricado con 5 pilas AA, como fuente de voltaje para el Raspberry Pi.

**Figura 32**

*Batería recargable Tenergy NiMH*



El UAV utilizado para este estudio, es el **DJI Mavic Air 2**, Drone de segunda generación que representa una versión mejorada del DJI Mavic Air, en cuanto a características de cámara y autonomía; el tiempo de vuelo oscila entre 25 a 34 minutos, posee sensores delanteros y traseros que permiten evitar obstáculos; en cuanto a la cámara, permite capturar imágenes de 12MP a 48MP; con resolución de 8000 x 6000 pixeles (8K). En la Tabla 16 se muestra la ficha técnica de este UAV:

**Tabla 16***Ficha técnica DJI Mavic Air 2*

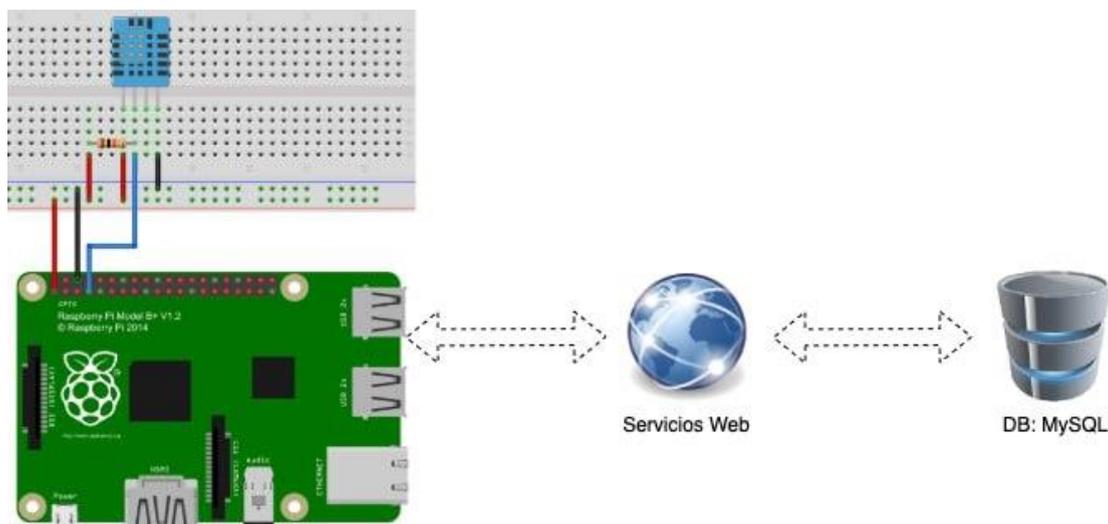
Especificaciones	
Peso	570 gr
Dimensiones	Plegado: 180 x 97 x 84 mm ; Desplegado: 183 x 253 x 77 mm
Velocidad máxima	68,4 Km/h en modo Sport
Altura máxima de servicio	5.000 m sobre nivel del mar
Tiempo de vuelo máximo	34 minutos
Conectividad	Alcance máximo de 6 km regulado por CE
Cámara	1/2" CMOS con sensor 12MP y 48 MP
Lente	FOV 84° 24mm f/2.8
Vídeo	Hasta 4K a 60 fps y 1080p a 240 fps
Almacenamiento	8 GB ampliables por microSD hasta 256 GB

**Figura 33***DJI Mavic Air 2*

El Software Python, se comunica con el Sistema Inteligente a través de servicios web, recolectando datos de un invernadero seleccionado; una vez definida la sección a ser monitoreada, captura los datos como temperatura y humedad relativa, captura las imágenes; todos estos datos son enviados por un servicio web cada 3,5 segundos, para posteriormente ser analizados.

**Figura 34**

*Comunicación de software Python con Sistema Inteligente*



**Figura 35**

*Software Python*

```

- Process List
[ 1] smart-sensors Mem: 20
[ 0] startup Mem: 33 MB

smart-sensors Logs
smart-sensors > 201
smart-sensors > {"humidity":"65.00000000","temperature":"21.00000000","section":
smart-sensors > {"crop": '2', 'section': '16'}
smart-sensors > {"temperature": 21, 'humidity': 64, 'crop': '2', 'section':
smart-sensors > 201
smart-sensors > {"humidity":"64.00000000","temperature":"21.00000000","section":
smart-sensors > {"crop": '2', 'section': '16'}
smart-sensors > {"temperature": 21, 'humidity': 64, 'crop': '2', 'section':
smart-sensors > 201
smart-sensors > {"humidity":"64.00000000","temperature":"21.00000000","section":
smart-sensors > {"crop": '2', 'section': '16'}
smart-sensors > {"temperature": 21, 'humidity': 64, 'crop': '2', 'section':
smart-sensors > 201
smart-sensors > {"humidity":"64.00000000","temperature":"21.00000000","section"

Custom Metrics
Metadata
App Name smart-sensors
Namespace default
Version N/A
Restarts 0

left/right: switch boards | up/down/mouse: scroll | Ctrl-C: exit
To go further check out https://pm2.io/
    
```

El **Servicio Web**, está desarrollado en Python como lenguaje de Programación y se encarga de recibir los datos enviados por el Raspberry Pi; para el funcionamiento se utilizan las siguientes tecnologías: *Flask 1.1.2*, framework de aplicación web, capaz de escalar a aplicaciones más complejas, y con el cual se recibe las peticiones http; *Open Cv 4.5.1*, librería de código abierto que incluye varios algoritmos de visión por computadora, se utiliza para el funcionamiento del modelo de Aprendizaje Automático, con el archivo de configuración utilizado previamente en YOLO; Base de datos *MySQL8.0*, sistema de gestión de base de datos relacionadas de código abierto; y como Servidor de Aplicaciones, se utiliza *NGINX 1.18.0*.

**Figura 36**

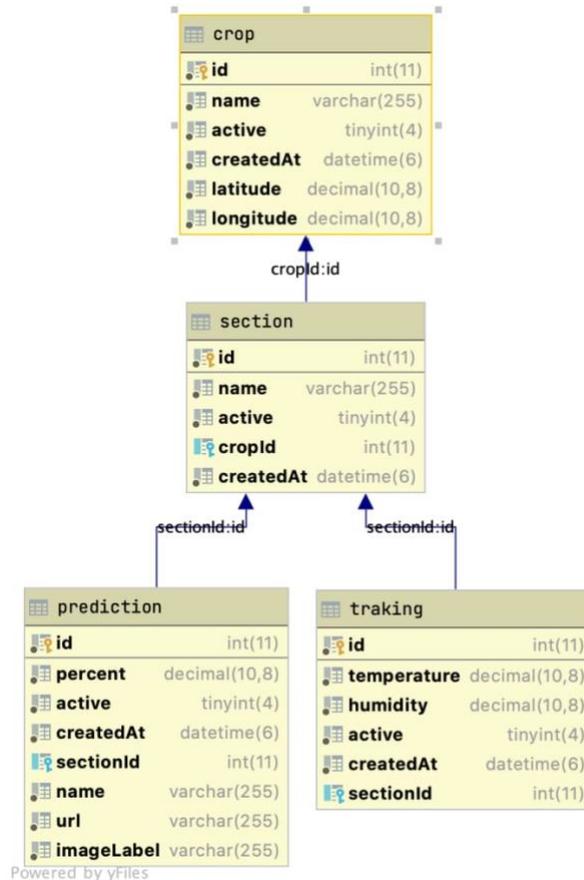
*Servicio Web*



La información de los cultivos y las secciones, se almacenan en la base de datos; la tabla tracking almacena los datos de temperatura y humedad relativa, y la tabla predicción almacena los porcentajes de predicción de las imágenes y videos captados por el Drone.

Figura 37

## Diagrama Base de Datos



Este software recibe los datos captados por el Raspberry Pi, el cual analiza la imagen utilizando el modelo de Aprendizaje Automático generado previamente, el cual una vez que se carga el modelo y se configura el color para el etiquetado y nombre de clase, para el caso “oidio”, la imagen se somete a un proceso de detección donde es evaluada con un porcentaje de confianza del 50%, donde aquellas imágenes con porcentaje de predicción superior, son etiquetadas y almacenadas en la base de datos, junto con los datos de humedad y temperatura relativa, para su posterior análisis.

## Figura 38

### Líneas de código del proceso de detección

```

for object_detection_layer in obj_detection_layers:

    for object_detection in object_detection_layer:

        all_scores = object_detection[5:]
        predicted_class_id = np.argmax(all_scores)
        prediction_confidence = all_scores[predicted_class_id]

        # tomar solo predicciones con una confianza superior al 50%
        if prediction_confidence > 0.50:
            #obtener la etiqueta predicha
            predicted_class_label = class_labels[predicted_class_id]
            #obtener las coordenadas del cuadro delimitador para la imagen real a partir del tamaño de la imagen redimensionada
            bounding_box = object_detection[0:4] * np.array([img_width, img_height, img_width, img_height])
            (box_center_x_pt, box_center_y_pt, box_width, box_height) = bounding_box.astype("int")
            start_x_pt = int(box_center_x_pt - (box_width / 2))
            start_y_pt = int(box_center_y_pt - (box_height / 2))
            end_x_pt = start_x_pt + box_width
            end_y_pt = start_y_pt + box_height

            #obtener un color de máscara aleatorio de la gran variedad de colores
            box_color = class_colors[predicted_class_id]

            #convierta la matriz numérica de colores como una lista y aplíquela al texto y al cuadro
            box_color = [int(c) for c in box_color]

            # imprimir la predicción en la consola
            predicted_class_label = "{}: {:.2f}%".format(predicted_class_label, prediction_confidence * 100)
            print("predicted object {}".format(predicted_class_label))

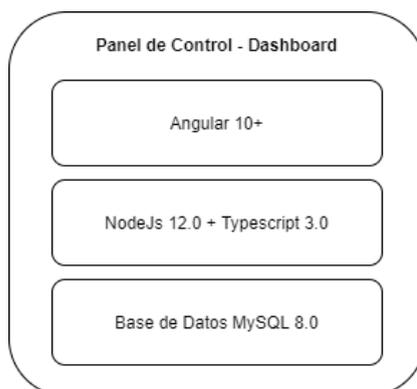
            # dibujar rectángulo y texto en la imagen
            cv2.rectangle(img_to_detect, (start_x_pt, start_y_pt), (end_x_pt, end_y_pt), box_color, 1)
            cv2.putText(img_to_detect, predicted_class_label, (start_x_pt, start_y_pt-5), cv2.FONT_HERSHEY_SIMPLEX, 0.5, box_color, 1)

```

Consecuentemente se elabora el Dashboard o Panel de Control, que permite visualizar los datos de interés del invernadero y sus respectivas secciones, para realizar el monitoreo de la enfermedad oidio en cultivo de rosas, para la posterior toma de decisiones; cabe mencionar que para la elaboración de este Dashboard, se utilizó Angular 10+, framework para desarrollo de la interfaz; NodeJs 12.0 + Typescript 3.0 que se utiliza como servidor de aplicaciones y para comunicación entre base de datos e interfaz gráfica.

## Figura 39

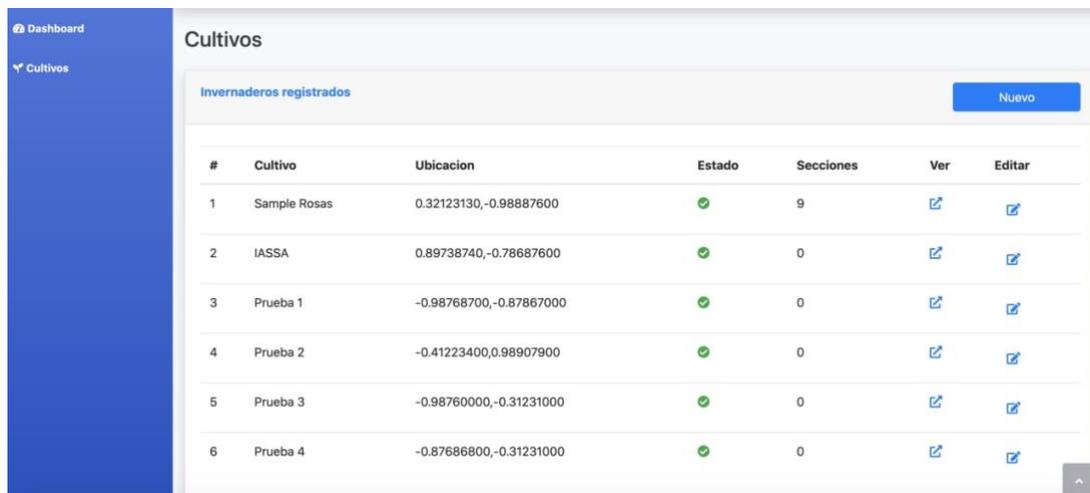
### Dashboard



Además, el Dashboard tiene un módulo donde se pueden registrar los cultivos con sus secciones, para llevar a cabo el monitoreo, se muestra en la figura.

**Figura 40**

*Interfaz para registro de invernaderos, cultivos*



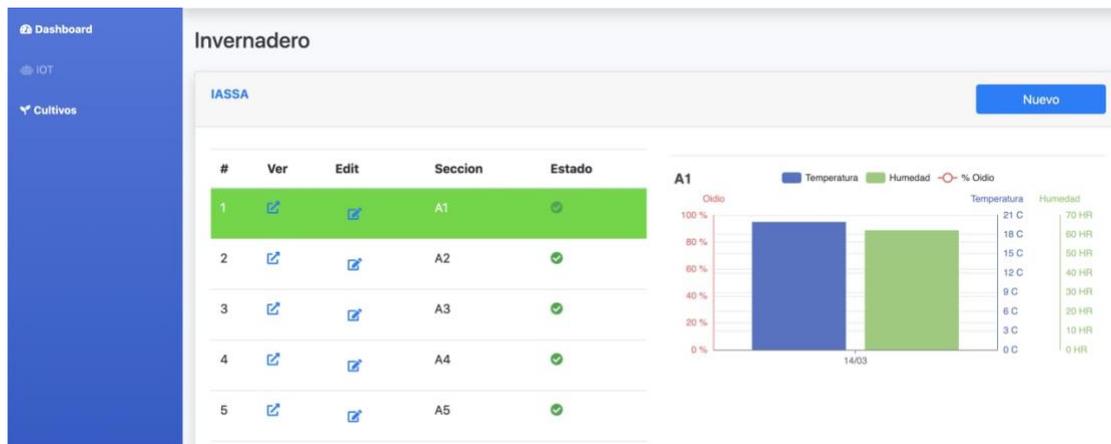
**Cultivos**

Invernaderos registrados Nuevo

#	Cultivo	Ubicacion	Estado	Secciones	Ver	Editar
1	Sample Rosas	0.32123130,-0.98887600	✓	9	<a href="#">Ver</a>	<a href="#">Editar</a>
2	IASSA	0.89738740,-0.78687600	✓	0	<a href="#">Ver</a>	<a href="#">Editar</a>
3	Prueba 1	-0.98768700,-0.87867000	✓	0	<a href="#">Ver</a>	<a href="#">Editar</a>
4	Prueba 2	-0.41223400,0.98907900	✓	0	<a href="#">Ver</a>	<a href="#">Editar</a>
5	Prueba 3	-0.98760000,-0.31231000	✓	0	<a href="#">Ver</a>	<a href="#">Editar</a>
6	Prueba 4	-0.87686800,-0.31231000	✓	0	<a href="#">Ver</a>	<a href="#">Editar</a>

**Figura 41**

*Interfaz Dashboard*



## Despliegue del Sistema Inteligente.

Para el despliegue, una vez desarrollado la plataforma, se procede a configurar los servicios web en los servidores:

**Servicio Web 1:** Este servicio requiere del sistema operativo Ubuntu 18.04 LTS, el cual necesita de Python en la versión 3.6.x; las librerías que permiten el funcionamiento de este servicio son: Open CV para el funcionamiento del modelo obtenido de Aprendizaje Automático; Flask como framework de aplicaciones web de código abierto, la configuración requiere del Servidor de Aplicaciones NGINX, el cual permite la comunicación a través del protocolo http.

### Figura 42

*Status del despliegue del software basado en Python*

```

av_ivanluis16@iot:/var/www/html$ sudo systemctl status myproject
● myproject.service - Gunicorn instance to serve myproject
   Loaded: loaded (/etc/systemd/system/myproject.service; enabled; vendor preset: enabled)
   Active: active (running) since Thu 2021-03-11 04:04:36 UTC; 21h ago
     Main PID: 1665 (gunicorn)
        Tasks: 10 (limit: 4915)
   CGroup: /system.slice/myproject.service
           └─1665 /var/www/html/myprojectenv/bin/python3.6 /var/www/html/myprojectenv/bin/gunicorn --workers 3 --bind unix:myproject.sock -m 007 wsgi:app
             └─1699 /var/www/html/myprojectenv/bin/python3.6 /var/www/html/myprojectenv/bin/gunicorn --workers 3 --bind unix:myproject.sock -m 007 wsgi:app
             └─1705 /var/www/html/myprojectenv/bin/python3.6 /var/www/html/myprojectenv/bin/gunicorn --workers 3 --bind unix:myproject.sock -m 007 wsgi:app
             └─4554 /var/www/html/myprojectenv/bin/python3.6 /var/www/html/myprojectenv/bin/gunicorn --workers 3 --bind unix:myproject.sock -m 007 wsgi:app

Mar 11 22:10:10 iot gunicorn[1665]: delete: /var/www/html/images/img770351622041779.jpg
Mar 11 22:10:10 iot gunicorn[1665]: ('label': '/var/www/html/images/img4198331630368035.jpg', 'url': 'https://storage.googleapis.com/precisionagriculture.appspot.com/images/img4198331630368035.jpg')
Mar 11 22:10:10 iot gunicorn[1665]: 201
Mar 11 22:10:10 iot gunicorn[1665]: delete: /var/www/html/images/img4198331630368035.jpg
Mar 11 22:10:10 iot gunicorn[1665]: ('label': '/var/www/html/images/img1482304446501317.jpg', 'url': 'https://storage.googleapis.com/precisionagriculture.appspot.com/images/img1482304446501317.jpg')
Mar 11 22:10:10 iot gunicorn[1665]: 201
Mar 11 22:10:10 iot gunicorn[1665]: delete: /var/www/html/images/img1482304446501317.jpg
Mar 11 22:10:10 iot gunicorn[1665]: ('label': '/var/www/html/images/img9741996100063938.jpg', 'url': 'https://storage.googleapis.com/precisionagriculture.appspot.com/images/img9741996100063938.jpg')
Mar 11 22:10:10 iot gunicorn[1665]: 201
Mar 11 22:10:10 iot gunicorn[1665]: delete: /var/www/html/images/img9741996100063938.jpg
av_ivanluis16@iot:/var/www/html$

```

### **Prototipo del Sistema Inteligente.**

En la figura se visualiza el prototipo del dispositivo de monitoreo de oídio en cultivo de rosas, con sus componentes electrónicos; es importante mencionar que, la recolección de datos se realiza de manera manual, y con este Sistema Inteligente se pretende contribuir a que la recolección de datos se automatice y que los datos se puedan visualizar fácilmente de tal manera que permita la toma de decisiones.

**Figura 43**

*Prototipo de Dispositivo IOT*



**Figura 44**

*Prototipo dispositivo IOT (vista lateral)*



**Pruebas de captación de datos.**

Las pruebas de funcionamiento del Sistema Inteligente, se realizaron en el invernadero de rosas de la Universidad de las Fuerzas Armadas ESPE, IASA I, ubicado en la Hacienda “El Prado”, provincia de Pichincha, cantón Rumiñahui.

**Figura 45**

*Preparación de prototipo para vuelo en invernadero de rosas IASA I*



**Figura 46**

*Prueba de vuelo Drone con Sistema IOT a bordo*



## Capítulo IV

### Análisis de Resultados y Visualización de datos

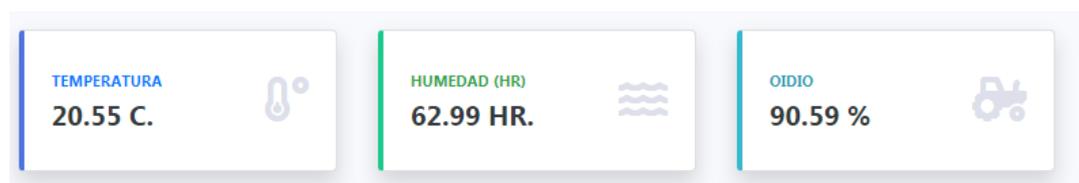
Una vez realizadas las pruebas del sistema inteligente, captando datos con el dispositivo IOT a bordo del UAV, se realiza el monitoreo en secciones específicas del invernadero de rosas, para determinar las funcionalidades del sistema inteligente.

Al sobrevolar las secciones del invernadero, se obtuvieron los datos de temperatura, humedad relativa y los porcentajes de predicción de oidio obtenidos del procesamiento de imágenes y videos tomados por el Drone (UAV), al realizar el monitoreo de secciones específicas, los cuales fueron analizados por el modelo de Aprendizaje Automático previamente entrenado.

Se obtiene los siguientes resultados:

#### Figura 47

##### *Resultados Monitoreo en IASA I*



Nota: Se muestra el promedio de temperatura, humedad y porcentaje de predicción de oidio en invernadero de rosas IASA I.

El promedio de la temperatura del invernadero con los datos captados de la sección 1, 2 y 3 es de 20.55°C, de humedad relativa 62.99; y el porcentaje de predicción de Oidio es de 90.59%. Cabe mencionar que los datos se van actualizando conforme se va realizando el monitoreo, información que se procesa con el Sistema Inteligente.

En la siguiente figura se muestra el promedio humedad, temperatura y porcentaje de predicción por sección monitoreada.

### Figura 48

*Resultados de monitoreo por sección*

<b>Secciones</b>			
<b>Seccion</b>	<b>Humedad</b>	<b>Temperatura</b>	<b>Oidio</b>
A1	62.16 HR	19.95 C	0.0%
A2	48.34 HR	28.45 C	90.69%
A3	66.16 HR	19.76 C	90.55%

Finalmente, se pudo visualizar y evidenciar que existe presencia de oidio, con un porcentaje aproximado de 90.59%; este porcentaje indica que existe un alto índice de que en las plantas en cada sección del invernadero monitoreado, pueda contener la enfermedad.

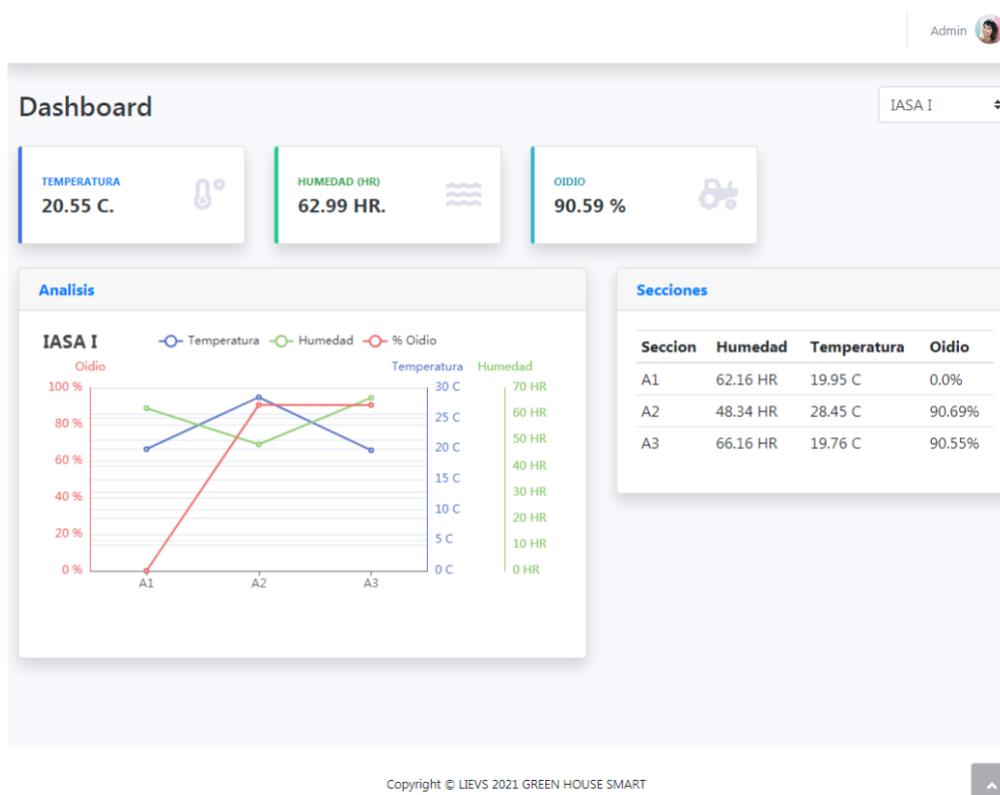
Este porcentaje se valida con los rangos de temperatura y humedad relativa, en los cuales la formación e infección de la enfermedad es más alta; es decir, las condiciones de temperatura que favorecen el desarrollo de la enfermedad se encuentran entre los 20°C – 30°C, y humedad relativa 30 – 40 HR (Grupo Empresarial VOS, 2020).

Este tipo de información, es importante y valiosa, ya que ayuda para el monitoreo del cultivo de rosas en el invernadero, considerando que la

enfermedad “oidio” posee alta capacidad de adaptación, desarrolla resistencia a fungicidas, los brotes epidemiológicos son rápidos y severos, y es fácilmente transportable por el viento, trabajadores, material vegetativo, herramientas, ácaros o insectos ,entre otros; éstos datos, para la toma de decisiones, que permitan mitigar la enfermedad, es fundamental.

**Figura 49**

*Visualización de datos en Dashboard*

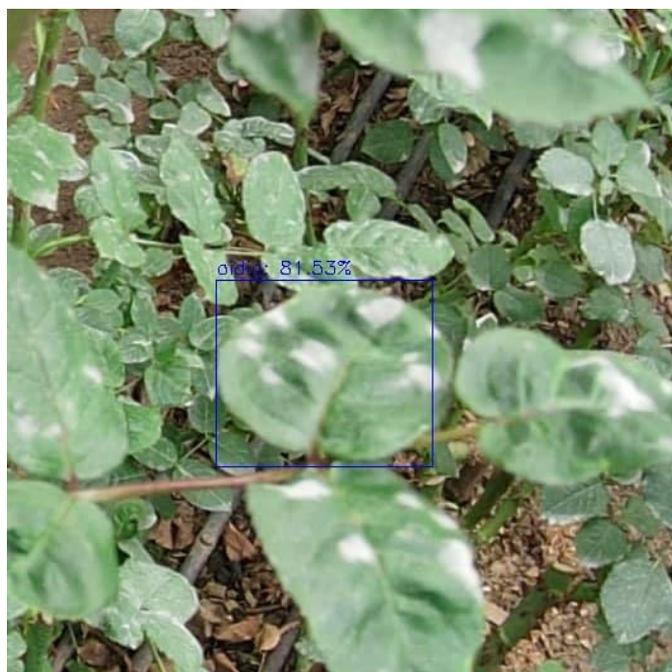


**Figura 50**

*Imagen de hoja con porcentaje de detección de Oidio*

**Figura 51**

*Imagen de hoja con porcentaje de detección de Oidio*



## Capítulo V

### Conclusiones y Recomendaciones

#### Conclusiones

En Ecuador el sector florícola ha ido evolucionando en el transcurso del tiempo, siendo hoy en día, uno de los principales sectores de exportaciones no tradicionales; sin embargo, este sector se ve afectado por plagas y enfermedades que limitan su producción y comercialización, causando graves pérdidas económicas para el floricultor; entre las enfermedades más comunes que afectan los cultivos de rosas, está la Oidium (*sphaerotheca pannosa*).

En la actualidad, el manejo integral de plagas y enfermedades se realiza de manera manual y no existen técnicas de Aprendizaje Automático que permitan mejorar el monitoreo tradicional a un sistema de monitoreo automatizado de mayor precisión para el control eficiente de Oidium (*sphaerotheca pannosa*) en cultivo de rosas; ante esta realidad, es preciso realizar investigaciones, desarrollar herramientas y propuestas con nuevas opciones tecnológicas, que permitan para automatizar el monitoreo de cultivo de rosas y mejorar los procesos.

Con el avance tecnológico y el aumento del uso del internet a nivel global para comunicarnos, es importante desarrollar la capacidad de poder acceder y compartir información de interés para mejorar la producción rosas utilizando nuevas propuestas tecnológicas como: robots aéreos (UAV) , sistemas IOT de captación de datos y la implantación de sistemas inteligentes que utilizan técnicas aprendizaje automático, que contribuyan al monitoreo de enfermedades como el oidio y resulte beneficioso en cuanto a optimización de tiempo y recursos.

La idea de implementar el uso de una técnica de aprendizaje automático como CCN (Rede neuronales convolucionales) para generar un

modelo de Aprendizaje Automático o ML (Machine Learning), que aprenda a identificar la enfermedad, a base de imágenes de plantas de rosas con presencia de la enfermedad (oidio), permite crear un sistema inteligente que contribuye a determinar un porcentaje de predicción en el que pueda existir la enfermedad (oidio), el cual apoyado con los datos de temperatura y humedad relativa, ayuda a realizar el monitoreo de la enfermedad y a su vez, se pueda realizar un análisis más exhaustivo por parte del experto en agricultura para la toma de decisiones.

El uso de redes neuronales convolucionales o CNN, ha demostrado un alto rendimiento para la detección de imágenes; para la presente investigación, la precisión de detectores de objetos obtenida (map) es de 73.1%; pero conlleva un alto costo computacional; por otro lado, el uso de dispositivos IOT permite la comunicación entre dispositivos y la captación de datos en tiempo real y con el uso de un UAV, se acorta el tiempo que normalmente tomaría realizar recolección de datos de manera manual.

La creación de un sistema inteligente que contribuye al monitoreo de la enfermedad oidio, provee información valiosa, tanto para la toma de decisiones como para el desarrollo de nuevas líneas de investigación en el ámbito de los sistemas e informática, para lograr mayor precisión, y en el ámbito de la agricultura, para desarrollo de estrategias eficientes y efectivas para mitigar la enfermedad; e incluso otras áreas como conservación ambiental, aspectos económicos, recursos humanos, etc.

Finalmente, se puede concluir que la implementación de un sistema inteligente mediante el uso de un drone (UAV) para captación de datos con fines de monitoreo de la enfermedad oidio, es una contribución de investigación y desarrollo al mejoramiento del cultivo de rosas.

## Recomendaciones

El desarrollo de esta investigación, presentó algunos retos y desafíos, entre los más notables fue el acceso a internet, ya que para los sobrevuelos el dron (UAV) y el dispositivo IOT, necesitan de una conexión constante de internet, para enviar los datos captados por los sensores de temperatura y humedad relativa, a través de los servicios web utilizando una red wifi, por lo que se recomienda tener un proveedor de internet.

En el proceso de captación de datos con el dron (UAV), se recomienda contar con al menos 3 baterías y una conexión de energía eléctrica para poder sobrevolar todo el invernadero, mientras que las baterías utilizadas se cargan nuevamente.

La precisión de vuelo del (UAV) en el interior de invernadero, constituye un desafío, ya que existen diferentes estructuras metálicas y cables, que exigen de un piloto con experiencia para evitar posibles accidentes; además, la captura de imágenes con el Dron en vuelo, se limita a tomas desde un ángulo superior; por tanto, se sugiere utilizar un robot autónomo o semi-autónomo, que permita realizar el monitoreo capturando imágenes desde distintos ángulos.

Para la captura de imágenes y videos, se recomienda utilizar una cámara de 48 mega pixeles o superior, además de un gimbal o estabilizador de cámara, para que las imágenes y videos captados mantengan nitidez y eviten desenfoques, esto beneficiará a la posible detección de la enfermedad oídio, mejorando el monitoreo de la misma.

Se recomienda que se realice el monitoreo al menos 3 veces al día, para poder recabar información y determinar variaciones en los datos, ya que los cambios de temperatura fluctúan durante el día y dependen también de factores climatológicos.

## Referencias

- Delloite . (25 de Octubre de 2020). *IoT-Internet Of Things*. Obtenido de Delloite España: <https://www2.deloitte.com/es/es/pages/technology/articles/loT-internet-of-things.html>
- Agrocalidad. (2015). *Buenas Prácticas Agrícolas para Ornamentales*. Obtenido de <https://www.agrocalidad.gob.ec/wp-content/uploads/2020/05/guia16.pdf>
- Agrocalidad. (2017). *Guía de Inspección*. Obtenido de <http://www.Agrocalidad.gob.ec/wp-content/uploads/2015/guía-actualizada-para-inspecciones-09-03-2014.pdf>
- Agroecuador . (2016). *¿Cómo Funciona El Manejo Integrado De Plagas?* Obtenido de Blog de Noticias: <https://agroecuador.org/index.php/blog-noticias/item/426-como-funciona-el-manejo-integrado-de-plagas>
- Aponte Guano, D. (2015). *El oído (Sphaerotheca pannosa) con su método de control biológico en el cultivo de la rosa (Rosa sp.)*. Ambato: Bachelor's thesis. Obtenido de <https://repositorio.uta.edu.ec/jspui/bitstream/123456789/22579/1/Tesis-130%20%20Ingenier%C3%ADa%20Agron%C3%B3mica%20-CD%20397.pdf>
- Aprendiendo Arduino. (2018). *Aprendiendo Arduino*. Obtenido de Arquitecturas IoT: <https://aprendiendoarduino.wordpress.com/2018/11/11/arquitecturas-iot/>
- Barbedo, J. (2019). Plant disease identification from individual lesions and spots using deep learning. *Biosystems Engineering*, 180, 96-107. doi:<https://doi.org/10.1016/j.biosystemseng.2019.02.002>
- Barrietos, A., Del Cerro, J., Gutiérrez, P., San Martín, R., Martínez, A., & Rossi, C.

(2007). *Vehículos aéreos no tripulados para uso civil. Tecnología y aplicaciones*. Madrid: Universidad Politécnica de Madrid.

Béjar Alonso, J., Cortés García, C., & Sánchez Marré, M. (1998). Aprendizaje Automático. *Novática: revista de la Asociación de Técnicos de Informática*, 131, 9-13. Obtenido de <https://upcommons.upc.edu/bitstream/handle/2117/192998/B%C3%A9jar-Cort%C3%A9s-Sánchez.pdf>

Bhange, M., & Hingoliwala, H. (2015). Smart Farming: Pomegranate Disease Detection Using Image Processing. *Procedia Computer Science*, 58, 280-288. Obtenido de <https://doi.org/10.1016/j.procs.2015.08.022>

Calvache Ulloa, A. (2017). Cultivo de Rosas para Exportación. *Agricultura Sostenible*. Obtenido de [https://www.researchgate.net/publication/325481851\\_AGRICULTURA\\_SOSTENIBLE\\_EN\\_ECUADOR](https://www.researchgate.net/publication/325481851_AGRICULTURA_SOSTENIBLE_EN_ECUADOR)

Cárdenas, C., Pozo, W., Rojas, M., Roque, A., & Mihai, R. (2016). Antifungal Activity of two Botanical Extracts on Rose Crop (*Rosa L. Sp.*), Against *Sphaerotheca Pannosa* Var. *Rosae*. *Agriculture and Agricultural Science Procedia*, 16, 465-474. doi:<https://doi.org/10.1016/j.aaspro.2016.09.017>

Chicaiza Claudio, A., & Chuchico Arcos, C. (2015). *Implementación de un sistema de piloto automático basado en una plataforma FPGA para la navegación autónoma del vehículo aéreo no tripulado de la Universidad de las Fuerzas Armadas ESPE – Extensión Latacunga*. Latacunga. Obtenido de <http://repositorio.espe.edu.ec/handle/21000/9303>

Cobos, A. (2016). *Diseño e implementación de una arquitectura IoT basada en tecnologías Open Source*. Trabajo Fin de Máster, Escuela Técnica Superior de

Ingeniería Universidad de Sevilla, Sevilla.

Custers, B. (2016). *Future of Drone use*. TMC Asser Press. Springer.

Duarte Hueros, A. M. (2000). Innovación y nuevas tecnologías: implicaciones para un cambio educativo. *Revista de Educación*, 129-146.

Expoflores. (2019). *Información Económica*. Obtenido de <https://expoflores.com/inteligencia-de-mercados/>

Flint, M. (2012). *IPM in practice: principles and methods of integrated pest management* (2 ed., Vol. 3418). California: University of California Agriculture and Natural Resources. Obtenido de [https://books.google.com.ec/books?hl=es&lr=&id=4MtgeUgjuwNcC&oi=fnd&pg=PP2&dq=Flint.+M.,+Gouveia,+P.+\(2001\).+IPM+in+Practice+Principles+and+Methods+of+Integrated+Pest+Management,+University+of+California+Statewide+Integrated+Pest+Management+Project,+Agricul](https://books.google.com.ec/books?hl=es&lr=&id=4MtgeUgjuwNcC&oi=fnd&pg=PP2&dq=Flint.+M.,+Gouveia,+P.+(2001).+IPM+in+Practice+Principles+and+Methods+of+Integrated+Pest+Management,+University+of+California+Statewide+Integrated+Pest+Management+Project,+Agricul)

Franco, P. V., Espinoza., A., & Maceda, H. C. (s.f.). Software Development Process for Teams with Low Expertise, High-Rotation and No-Architect: A Systematic Mapping Study. Obtenido de [http://enc2014.cicese.mx/Memorias/paper\\_67.pdf](http://enc2014.cicese.mx/Memorias/paper_67.pdf)

Franco, P., Espinoza, A., & Cervantes, H. (s.f.). Software Development Process for Teams with Low Expertise, High-Rotation and No- Architect: A Systematic Mapping Study. Obtenido de [http://enc2014.cicese.mx/Memorias/paper\\_67.pdf](http://enc2014.cicese.mx/Memorias/paper_67.pdf)

Gao, D., Sun, Q., Hu, B., & Zhang, S. (2020). A framework for agricultural pest and disease monitoring based on internet-of-things and unmanned aerial vehicles. *20(5)*, 1487. doi:<https://doi.org/10.3390/s20051487>

- George, E. A., Tiwan, G., Yadav, R. N., Peters, E., & Sadana, S. (2013). UAV systems for parameter identification in agriculture. *IEEE Global Humanitarian Technology Conference: South Asia Satellite (GHTC-SAS)*, 270-273. doi:10.1109/GHTC-SAS.2013.6629929.
- George, E. A., Tiwari, G., Yadav, R. N., Peters, E., & Sadana, S. (2013, August). UAV systems for parameter identification in agriculture. (s.f.). 270-273.
- Gómez Rea, C. (2014). *Análisis histórico del sector florícola en el Ecuador y estudio del mercado para determinar su situación actual*. Quito: Tesis de Licenciatura.
- Gupta, L., Jain, R., & Vaszkun, G. (2016). Survey of important issues in UAV communication networks. *IEEE Communications Surveys & Tutorials*, 18(2), 1123-1152. doi:10.1109/COMST.2015.2495297
- Hernández, J. (2016). Hernández, J. A. (2016). Métodos de reducción de dimensionalidad: Análisis comparativo de los métodos APC, ACPP y ACPK. *Uniciencia*, 30(1), 115-122. Obtenido de <https://dialnet.unirioja.es/servlet/articulo?codigo=5327394>
- Hernández-Sampieri, R., & Mendoza Torres, C. (2018). *Metodología de la investigación* (Vol. 4). México: McGraw-Hill Interamericana.
- Holden, S. (2018). *Why Github?* Obtenido de <https://github.com/holdenweb>
- Ierache, J., Naiouf, M., García, R., & De Giusti, A. (2008). Un modelo de arquitectura para el aprendizaje y compartición de conocimiento entre sistemas inteligentes autónomos distribuidos. *JII/SIC*, 179-188.
- Infoagro. (05 de Mayo de 2015). *Infoagro*. Obtenido de Cultivo de rosas para corte. : <Http://www.infoagro.com/flores/flores/rosas.htm>
- Kitchenham, B., Brereton, P., Budgen, D., Turner, M., Bailey, J., & Linkman, S. (Enero

- de 2009). Systematic literature reviews in software engineering – A systematic literature review. *Information and Software Technology*, 51(1), 7-15.  
doi:<https://doi.org/10.1016/j.infsof.2008.09.009>
- Kononenko, I. (2001). Machine learning for medical diagnosis: history, state of the art and perspective. *Artificial Intelligence in Medicine*, 23(1), 89-109.  
doi:[https://doi.org/10.1016/S0933-3657\(01\)00077-X](https://doi.org/10.1016/S0933-3657(01)00077-X)
- Kumar, K. V., & Jayasankar, T. (2019). An identification of crop disease using image segmentation. *Int. J. Pharm. Sci. Res*, 10(3), 1054-1064.  
doi:10.13040/IJPSR.0975-8232.10(3).1054-64.
- Leandro, A. (2009). El proceso de internacionalización de empresas. *Tec empresarial*, 3(3), 18-25. Obtenido de [https://revistas.tec.ac.cr/index.php/tec\\_empresarial/article/view/653/580](https://revistas.tec.ac.cr/index.php/tec_empresarial/article/view/653/580)
- Lewin, K. (1992). La investigación-acción y los problemas de las minorías. *La investigación-acción participativa. Inicio y desarrollo, Biblioteca de Educación de Adultos*, 6, 13-25.
- Lind , D., Marchal , W., & Wathen, S. (2008). *Estadística aplicada a los negocios y economía* (13 ed.). México: McGraw Hill.
- Lindgren, S. (2020). *Creating and Improving Machine Learning Algorithms for Plant Disease Identification*. Obtenido de <https://www.diva-portal.org/smash/get/diva2:1434579/FULLTEXT01.pdf>
- Lindgren, S. (2020). *Creating and Improving Machine Learning Algorithms for Plant Disease Identification*.
- Luna Gonzalez, J. (08 de Febrero de 2018). *Tipos de aprendizaje automático*. Obtenido de Soldai: <https://medium.com/soldai/tipos-de-aprendizaje->

autom%C3%A1tico-6413e3c615e2

- Mahedero Biot, F. (2020). *Desarrollo de una aplicación IoT para el envío de imágenes mediante el protocolo MQTT*. Tesis Doctoral, Universidad Politécnica de Valencia.
- Mahlein, A. K. (2016). Plant disease detection by imaging sensors—parallels and specific demands for precision agriculture and plant phenotyping. *Plant disease*, 100(2), 241-251. doi:<https://doi.org/10.1094/PDIS-03-15-0340-FE>
- Malik, M., Ikram, A., Batool, S. N., & Aslam, W. (Octubre de 2018). A Performance Assessment of Rose Plant Classification Using Machine Learning. *Intelligent Technologies and Applications*, 748-756. Obtenido de [https://link.springer.com/chapter/10.1007/978-981-13-6052-7\\_64](https://link.springer.com/chapter/10.1007/978-981-13-6052-7_64)
- Ministerio de Comercio Exterior e Inversiones. (2018). *Ministerio de Comercio Exterior e Inversiones*. Obtenido de <https://www.produccion.gob.ec/?s=floricola>
- Moreno, A., Armengol, E., Béjar, J., Belanche, L., Cortés, U., Gavaldà, R., . . . Sánchez, M. (1994). *Aprendizaje automático*. UPC. Obtenido de <https://upcommons.upc.edu/bitstream/handle/2099.3/36157/9788483019962.pdf>
- Orellana, H. (2013). Principales enfermedades en flores: Vademécum florícola. (Edifarm, Ed.) (8), 31-43.
- Ortega, B., Biswal, R., & De la Cruz, E. (2019). Detección de enfermedades en el sector agrícola utilizando Inteligencia Artificial. *Research in Computing Science*, 148(7), 419-427.
- Pizano, M. (2001). Floricultura y medio ambiente: Producción de flores sin bromuro de metilo. *PNUMA*. Obtenido de

<http://www.unep.fr/ozonaction/information/mmcfiles/3546-s.pdf>

- Plasek, A. (2016). On the cruelty of really writing a history of machine learning. *IEEE Annals of the History of Computing*, 38(4), 6-8.
- Proecuador. (2018). *Proecuador*. Obtenido de Flores y Plantas: <https://www.proecuador.gob.ec/>
- Pujari, J. D., Yakkundimath, R., & Byadgi, A. S. (2014). Neuro-kNN classification system for detecting fungal disease on vegetable crops using local binary patterns. *Agricultural Engineering International : The CIGR e-journal*, 16(4), 299-308.
- Putra, M. H., Yussof , Z. M., Lim, K. C., & Salim, S. I. (2018). Convolutional neural network for person and car detection using yolo framework. *Journal of Telecommunication, Electronic and Computer Engineering (JTEC)*, 10((1-7)), 67-71.
- Rabanal Carretero, D. z. (2011). *Integración de un Sistema UAV con Control autónomo en un equipo aéreo para agricultura de precisión* . Tesis de Grado, Pontificia Universidad Católica de Perú. Obtenido de [http://tesis.pucp.edu.pe/repositorio/bitstream/handle/20.500.12404/892/RABANAL\\_CARRETERO\\_DANNA\\_EQUIPO\\_AEREO\\_AGRICULTURA.pdf?sequence=1&isAllowed=y](http://tesis.pucp.edu.pe/repositorio/bitstream/handle/20.500.12404/892/RABANAL_CARRETERO_DANNA_EQUIPO_AEREO_AGRICULTURA.pdf?sequence=1&isAllowed=y)
- Rajput, A. S., Shukla, S., & Thakur, S. S. (2020). Soybean leaf diseases detection and classification using recent image processing techniques. *International Journal of Students' Research in Technology & Management*. doi:<https://doi.org/10.18510/ijsrtm.2020.831>
- Ramasamy, S., Sabatini, R., Gardi, A., & Liu, J. (2016). LIDAR obstacle warning and avoidance system for unmanned aerial vehicle sense-and-avoid. *Aerospace*

*Science and Technology*, 55, 344-358.

doi:<https://doi.org/10.1016/j.ast.2016.05.020>

Raschka, S., & Mirjalili, V. (2017). *Giving computers the ability to learn from data.*

*Python Machine Learning* (2 ed.). India: Packt. Recuperado el 01 de 2020

Redmon, J. (2016). *Darknet: Open Source Neural Networks in C* . Obtenido de

<http://pjreddie.com/darknet/>

Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified,

real-time object detection. *In Proceedings of the IEEE conference on computer vision and pattern recognition*, 779-788.

Render, B., & Heizer, J. (2007). *Administración de la producción*. México: Hugo Rivera

Oliver.

Obtenido

de

[https://www.academia.edu/22263946/Administracion\\_de\\_la\\_Produccion\\_Render](https://www.academia.edu/22263946/Administracion_de_la_Produccion_Render)

der

Richardson, M., & Wallace, S. (2012). *Getting started with raspberry PI* . *O'Reilly*

*Media, Inc.*

Rivas, E. (1994). Metodología de la investigación bibliográfica. *La investigación*

*bibliográfica y los textos académicos*, 11-14.

Sandoval Pillajo, A., Sandoval Pillajo, L., & Castillo Cabascango, A. (2019).

Diagnóstico inteligente de enfermedades y plagas en plantas ornamentales.

*HOLOPRAXIS Ciencia, Tecnología e Innovación*, 3(2), 134-148. Obtenido de

<https://revistaholopraxis.com/index.php/ojs/article/view/124>

Sozoranga Sandoval, H., & Vélez Velásquez, M. (2016). La Floricultura en Ecuador.

*Caribeña*

de

*Ciencias*

*Sociales*.

Obtenido

de

<https://www.eumed.net/rev/caribe/2016/10/floricultura.html>

- Tete, T. N., & Kamlu, S. (2017). Detection of plant disease using threshold, k-mean cluster and ann algorithm. *Computer Science - In 2017 2nd International Conference for Convergence in Technology (I2CT)*, 523-526. doi:10.1109/I2CT.2017.8226184
- Tucker Yépez, J. J. (2019). *Análisis de competitividad económica del sector floricultor del Ecuador en el período 2015-2018*. Bachelor`s Thesis, Universidad de Guayaquil. Facultad de Ciencias Económicas.
- Tzotalin. (2015). *Labellmg. Git code*. Obtenido de <https://github.com/tzotalin/labellmg>
- Urbano Salazar, R. (2017). *Sustentabilidad de la rosicultura en la subcuenca del río Guayllabamba-Ecuador*. Lima: Tesis Doctorado. Obtenido de <http://repositorio.lamolina.edu.pe/handle/UNALM/2934>
- Vegega, C., Pytel, P., & Pollo, M. (2017). Método basado en el emparejamiento para evaluar los datos aplicables. *Desarrollo e innovación en ingeniería*, 106-137.
- Yanchapaxi, J., Calvache, M., & Lalama, M. (2010). *Elaboración de un manual técnico-práctico del cultivo de Rosas (Rosa sp.) para exportación*. Trabajo de grado, Universidad Central, Quito.
- Yong, A. (2004). El cultivo del rosal y su propagación. *Cultivos tropicales*, 25(2), 53-67.
- Yu, C. W., Chen, Y. L., Lee, K. F., Chen, C. H., & Hsiao, C. Y. (2019). Efficient Intelligent Automatic Image Annotation Method based on Machine Learning Techniques. *IEEE International Conference on Consumer Electronics-Taiwan (ICCE-TW)*, 1-2.
- Zieslin, N. (1996). Influence of Climatic and Socio Economical Factors on mode of Cultivation and research of Rose Plants. *ISHS Acta Horticulturae 424: II*

*International Rose Symposium*, (págs. 21-22).

doi:10.17660/ActaHortic.1996.424.1