

**UNIVERSIDAD PERUANA UNIÓN**  
FACULTAD DE INGENIERÍA Y ARQUITECTURA  
Escuela Profesional de Ingeniería de Sistemas



**Modelo de Deep Learning para reconocimiento de Diplocarpon  
Rosae en rosas Mister Lincoln en zonas altoandinas**

Tesis para obtener el Título Profesional de Ingeniero de Sistemas

**Autor:**

Daniel Andrés Sáenz Shupingahua  
Maycol Cahuana Diaz  
Guido Cristhian Quillimamani Soncco

**Asesor:**

Mg. Abel Ángel Sullon Macalupu

Juliaca, diciembre de 2023

## DECLARACIÓN JURADA DE ORIGINALIDAD DE TESIS

Yo Abel Angel Sullon Macalupu, docente de la Facultad de Ingeniería y Arquitectura Escuela Profesional de Ingeniería de Sistemas, de la Universidad Peruana Unión.

### DECLARO:

Que la presente investigación titulada: **“MODELO DE DEEP LEARNING PARA RECONOCIMIENTO DE DIPLOCARPON ROSAE EN ROSAS MISTER LINCOLN EN ZONAS ALTOANDINAS”** de los autores **Daniel Andrés Sáenz Shupingahua, Maycol Cahuana Díaz y Guido Cristhian Quillimamani Soncco**, tiene un índice de similitud de 13% verificable en el informe del programa Turnitin, y fue realizada en la Universidad Peruana Unión bajo mi dirección.

En tal sentido asumo la responsabilidad que corresponde ante cualquier falsedad u omisión de los documentos como de la información aportada, firmo la presente declaración en la ciudad de Juliaca a los 8 días del mes de febrero del año 2024.



---

Abel Angel Sullon Macalupu

ACTA DE SUSTENTACIÓN DE TESIS



En Puno, Juliaca, Villa Chullunquiari, a 04 día(s) del mes de diciembre del año 2023 siendo las 17:00 horas, se reunieron los miembros del jurado en la Universidad Peruana Unión Campus Juliaca, bajo la dirección del (de la) presidente(a):

Msc. Benigno Francis Herrera Yucra el (la) secretario(a): Ing. Jensen Daniel  
Galambi Aguilar y los demás miembros: Msc. Ferdinand Edgardo Pineda  
Anco - Msc. Freddy Abel Nuanca Torres y el (la) asesor(a) Mg. Abel Angel Sullon  
Macalupu con el propósito de administrar el acto académico de sustentación de la tesis titulado:

Modelo de Deep Learning para reconocimiento de Diplocarpon Rosae en zonas  
híster Lincoln en zonas altoandinas

- del(los) bachiller/es: a) Daniel Andrés Sáenz Shupingahua  
 b) Quido Cristhian Quillimamani Soncco  
 c) Maycol Lahuana Diaz

conducente a la obtención del título profesional de: Ingeniero de Sistemas  
(Denominación del Título Profesional)

El Presidente inició el acto académico de sustentación invitando al (a la) / a (los) (las) candidato(a)s hacer uso del tiempo determinado para su exposición. Concluida la exposición, el Presidente invitó a los demás miembros del jurado a efectuar las preguntas, y aclaraciones pertinentes, las cuales fueron absueltas por al (a la) / a (los) (las) candidato(a)s. Luego, se produjo un receso para las deliberaciones y la emisión del dictamen del jurado.

Posteriormente, el jurado procedió a dejar constancia escrita sobre la evaluación en la presente acta, con el dictamen siguiente:

Bachiller (a): Daniel Andrés Sáenz Shupingahua

CALIFICACIÓN	ESCALAS			Mérito
	Vigesimal	Literal	Cualitativa	
<u>Aprobado</u>	<u>19</u>	<u>A</u>	<u>Excelente</u>	<u>Excelencia</u>

Bachiller (b): Quido Cristhian Quillimamani Soncco

CALIFICACIÓN	ESCALAS			Mérito
	Vigesimal	Literal	Cualitativa	
<u>Aprobado</u>	<u>19</u>	<u>A</u>	<u>Excelente</u>	<u>Excelencia</u>

Bachiller (c): Maycol Lahuana Diaz

CALIFICACIÓN	ESCALAS			Mérito
	Vigesimal	Literal	Cualitativa	
<u>Aprobado</u>	<u>19</u>	<u>A</u>	<u>Excelente</u>	<u>Excelencia</u>

(\*) Ver parte posterior

Finalmente, el Presidente del jurado invitó al (a la) / a (los) (las) candidato(a)s a ponerse de pie, para recibir la evaluación final y concluir el acto académico de sustentación procediéndose a registrar las firmas respectivas.

[Firma]  
 Presidente/a

[Firma]  
 Asesor/a

[Firma]  
 Bachiller (a)

[Firma]  
 Miembro  
[Firma]  
 Bachiller (b)

[Firma]  
 Secretario/a  
[Firma]  
 Miembro  
[Firma]  
 Bachiller (c)

## ÍNDICE

Resumen .....	6
Abstract .....	7
1. Introducción.....	8
2. Proceso Metodológico .....	10
2.1 Recolección de datos.....	10
2.1.1. Obtención de datos .....	10
2.1.2. Creación del Dataset.....	11
2.2. Preparación del Dataset.....	12
2.2.1. Creación del Dataset para Clasificación .....	12
2.2.2. Creación del Dataset para Detección .....	12
2.2.3. Creación del Dataset para Segmentación .....	13
2.3 Construcción de modelo .....	13
2.3.1. Entorno de trabajo .....	13
2.3.2. Modelo de clasificación .....	14
2.3.3. Modelo de detección .....	15
2.3.4. Modelo de segmentación .....	16
3. Pruebas .....	17
3.1. Pruebas realizadas a los modelos de clasificación .....	17
3.1.1. Primera prueba.....	17
3.1.2. Segunda prueba .....	18
3.2. Pruebas realizadas a los modelos de detección .....	18
3.2.1. Primera prueba.....	19

3.2.2. Segunda prueba .....	20
3.2.3. Tercera prueba .....	21
3.3. Pruebas realizadas a los modelos de segmentación .....	21
3.3.1. YOLOV7 .....	21
3.3.2. YOLOV8 .....	23
4. Resultados .....	25
4.1. Resultados del modelo de clasificación.....	25
4.1.1. Primera prueba.....	25
4.1.2. Segunda prueba.....	25
4.2. Resultados del modelo de detección.....	25
4.2.1. Primera prueba.....	25
4.2.2. Segunda prueba.....	26
4.2.3. Tercera prueba.....	26
4.3. Resultados del modelo de segmentación.....	27
4.3.1. YOLOV7 .....	27
4.3.2. YOLOV8 .....	28
5. Conclusiones.....	29
Referencias .....	31
ANEXOS .....	34
Anexo 1. Evidencia de Sumisión. ....	34
Anexo 2. Resolución de Inscripción del Perfil de Proyecto.....	35

# Modelo de Deep Learning para reconocimiento de Diplocarpon Rosae en rosas Mister Lincoln en zonas altoandinas

## Resumen

El trabajo tuvo como objetivo detectar la presencia del hongo Diplocarpon Rosae en rosas en la región de Puno, Perú, utilizando redes neuronales convolucionales. La metodología involucró la recolección y preparación de datos, la construcción y entrenamiento del modelo, y la evaluación de este. Se utilizó un método estructurado basada en la investigación de Marroquin, U. y se recolectó datos utilizando cámaras profesionales y móviles. Los datos fueron preparados para la clasificación, detección y segmentación usando diversas herramientas. El estudio contribuye al reconocimiento de la plaga Diplocarpon Rosae en la región sur del Perú y aporta a la investigación futura. El artículo describe el desarrollo de un modelo de inteligencia artificial para la identificación de plagas en cultivos de rosas en la región de Puno. Los datos se dividieron en conjuntos de entrenamiento, validación y prueba, y se construyeron modelos para la clasificación, detección y segmentación. Los resultados mostraron una alta precisión para los modelos de clasificación con 0.99 y detección con 0.85, pero se encontraron algunas complicaciones en el modelo de segmentación con 0.635. Se logró el objetivo de crear un modelo de IA para la clasificación, detección y segmentación de la plaga en cultivos de rosas.

**Palabras clave:** CNN, Detección de Objetos, Segmentación de Instancias, Rosas, Diplocarpon Rosae.

## **Abstract**

The objective of this work was to detect the presence of the *Diplocarpon Rosae* fungus in roses in the region of Puno, Peru, using convolutional neural networks. The methodology involved data collection and preparation, model construction and training, and model evaluation. A structured approach based on the research of Marroquin, U. was used and data was collected using professional and cell phone cameras. The data were prepared for classification, detection and segmentation using various tools. The study brings to the recognition of the pest *Diplocarpon Rosae* in the southern region of Peru and contributes to future research. The article describes the development of an artificial intelligence model for pest identification in rose crops in the Puno region. The data were divided into training, validation and test sets, and models were built for classification, detection and segmentation. The results showed high precision for the classification models with 0.99 and detection with 0.85, but some complications were found in the segmentation model with 0.635. The objective of creating an AI model for pest classification, detection and segmentation in rose crops was achieved.

**Keywords:** CNN, Object Detection, Instance Segmentation, Roses, *Diplocarpon Rosae*.

## 1. Introducción

El cultivo de rosas es una actividad importante que contribuye a la economía de los productores de las zonas altoandinas de Puno, las cuales son ideales para su cultivo. Según Huaman (2021), Perú no es ajeno a la floricultura, pues en el año 2019 ocupó el puesto 37 entre los exportadores de flores a nivel mundial. En el país se producen 60 especies de flores, incluyendo las rosas, lo que genera empleo y contribuye al desarrollo local y nacional. La aparición de *Diplocarpon rosae* se debe a una enfermedad fúngica que se desarrolla en los campos en zonas con alta precipitación anual (Debener, 2017). Los cultivos de rosas pueden verse afectados por *Diplocarpon rosae*, que tiende a propagarse a través de esporas asexuales bicelulares transmitidas por el agua, la cual llega a las rosas y comienza a germinar (Whitaker et al., 2007). Este hongo causa manchas en las hojas y disminuye la calidad y el rendimiento de las flores. Las lesiones características de esta infección son manchas negras de aproximadamente 2-12 mm de diámetro en el haz de las hojas (Bonillo, 2021).

El cultivo de rosas se ve afectado por enfermedades y plagas debido a la falta de conocimientos en la prevención de estas problemáticas. Los agricultores pueden no detectar los problemas de inmediato, lo que resulta en enormes pérdidas para los productores (Rajbongshi et al., 2020). Es importante considerar las condiciones climáticas y ambientales de la región Puno. Durante el 2017, la temperatura mínima en la región fue de 3°C, lo cual tiene efectos altamente negativos en el rendimiento de los cultivos (Junio y Olivera, 2019). El hongo *Diplocarpon rosae* puede desarrollarse en tan solo entre 5 a 8 días, especialmente en épocas de lluvia, cuando la humedad alcanza aproximadamente el 92% (Charles 2019). Por esta razón, el distrito de Coasa es un ambiente propicio para el desarrollo de este hongo. Consecuentemente, este malicioso hongo genera una disminución en la calidad y cantidad de flores producidas por las plantas de rosas (Dong et al., 2017), lo que a su vez puede ocasionar pérdidas de producción y afectar las finanzas del productor (Marchant et al., 1998). La infección daña la planta de rosas, que reduce su capacidad para sobrevivir y crecer normalmente, lo que la vuelve más susceptible a otras enfermedades (Baysal-Gurel & Philips, 2019).

Existe una necesidad de controlar las plagas y enfermedades en los cultivos de manera eficiente y sostenible. La detección temprana de plagas y enfermedades representa un desafío en muchas partes del mundo debido a la escasez de infraestructura y a los enfoques que consumen mucho tiempo para la identificación de las plagas. Las redes neuronales convolucionales son uno de los métodos más utilizados en el aprendizaje profundo para la

segmentación, detección y clasificación de enfermedades, lo que permite una detección temprana de enfermedades mediante imágenes (Li et al., 2021). La red neuronal convolucional aprende a reconocer patrones específicos en las imágenes (Bai et al., 2021) que indiquen la presencia de la plaga.

Al examinar los estudios y trabajos relacionados con el tema de investigación, se puede observar que se han aplicado diversos modelos para la identificación de enfermedades y plagas. Las redes neuronales artificiales convolucionales son las más utilizadas para el procesamiento de imágenes de hojas en la detección de enfermedades y/o plagas, que tuvo como objetivo mejorar la precisión y eficiencia de la detección de plagas en la agricultura mediante el uso de técnicas de aprendizaje profundo (Liu et al., 2019). En el proyecto, como el de Medina Tobón (2021), se utilizaron arquitecturas de redes neuronales como YOLOV5 y Faster RCNN-ResNet50 para monitorear la cosecha de aguacates y contar flores y frutos. En otro proyecto, como el de Sadia Sazzad et al (2022), se empleó una red neuronal convolucional (CNN) llamada RoseNet para clasificar las enfermedades de las hojas de rosa. Samba Lawra (2021) empleó técnicas de redes neuronales convolucionales para desarrollar un sistema automático de clasificación de enfermedades en hojas de tomate. Du Lei et al., (2022) exploraron técnicas de visualización para detectar y clasificar enfermedades en plantas, señalando brechas en la investigación y que sugirió futuras mejoras en su visualización y detección. Finalmente, Sango Viracucha (2021) desarrolló una aplicación móvil con un algoritmo de red neuronal convolucional para analizar plagas en rosas. Su investigación demostró que la intensidad y severidad del daño de plagas a las rosas Freedom disminuyó significativamente después de la implementación del sistema inteligente.

Los enfoques fundamentados en el aprendizaje profundo han evidenciado una mayor robustez y eficiencia en lo que respecta a la detección y clasificación de enfermedades en las plantas (Albattah et al., 2022). En este contexto, se planteó la formulación de un modelo de redes neuronales que se apoye en la visión por computadora y el aprendizaje profundo para el reconocimiento de plagas (Dalai & Senapati, 2019). Este modelo está enfocado en las rosas Mister Lincoln con la plaga *Diplocarpon Rosae* y utiliza técnicas de clasificación de imágenes con un modelo propuesto y Transfer Learning, detección de objetos con YOLOV5 y segmentación de instancias con la nueva versión de YOLOV8 en lugar de Coasa.

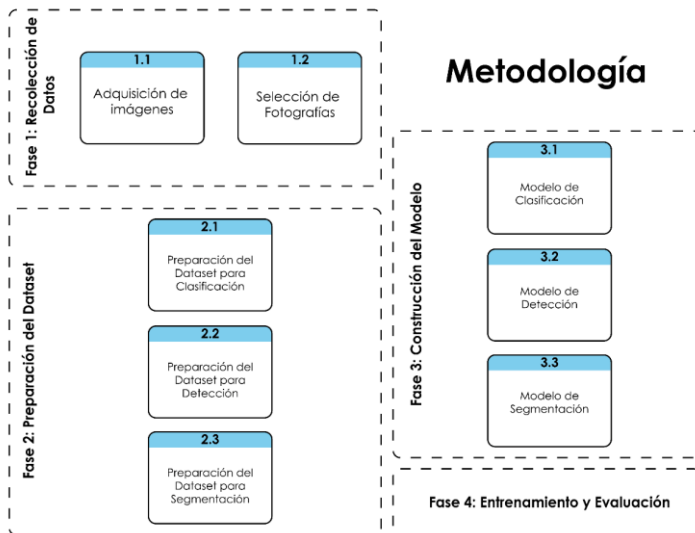
## 2. Proceso Metodológico

El presente estudio se llevó a cabo en el distrito de Coasa, ubicado en la provincia de Carabaya, en la región de Puno. Se utilizó como referencia el trabajo titulado "Machine Learning-based predictive model for the prognosis of human papillomavirus (HPV) vaccination attrition" (Marroquin, Saboya & Sullon 2021), el cual empleó el método CRISP-DM para desarrollar un modelo de Machine Learning con el propósito de predecir la deserción en la vacunación contra el virus del papiloma humano. Este método sirvió como base para nuestro enfoque destinado a la detección de la plaga *Diplocarpon* en hojas de rosas, donde la red neuronal aprenderá a reconocer patrones específicos en las imágenes (Bai et al., 2021) que indiquen la presencia de la plaga.

En este estudio, se aplicó un procedimiento metodológico que se presenta de manera visual en la fig. 1.

**Figura 1**

*Metodología adaptada empleada en el proyecto basada en Marroquin, U*



### 2.1 Recolección de datos

#### 2.1.1. Obtención de datos

En la primera fase del proyecto, se llevó a cabo la recolección de hojas de los rosales ubicados en el distrito de Coasa. Las hojas seleccionadas se obtuvieron en condiciones óptimas: se eligieron tanto hojas sanas como hojas afectadas por la plaga. Con el propósito

de garantizar la calidad y la conservación de las muestras hasta el momento de la toma de fotografías, se almacenaron en un recipiente con humedad controlada. Posteriormente, se tomaron las fotografías en un entorno con fondo blanco como en la investigación de Ngugi, Abelwahab & Abo-Zahhad (2021), para permitir una visualización precisa de las manchas causadas por la plaga.

Para llevar a cabo la recolección de datos y la captura de imágenes, se utilizaron instrumentos específicos que se muestran en la tabla 1.

**Tabla 1**

*Instrumentos de recopilación de datos*


Item	Instrumento
1	Cámara Canon Eos Rebel T3i
2	Cámara Redmi Note 9 Pro

### **2.1.2. Creación del Dataset**

La elaboración del Dataset fue uno de los aspectos clave en la realización del trabajo, ya que se buscaba emplearlo en distintas redes neuronales convolucionales. Sin embargo, existen factores que pueden afectar, como la calidad de la imagen misma o la pérdida de definición. Para ello, fue necesario ajustar las imágenes y prepararlas para que se usen en los entrenamientos. Las imágenes se recopilaron mediante el uso de una cámara celular de 48 MP y una cámara profesional Canon, lo que permitió obtener 1448 fotos de hojas sanas y 1250 fotos de hojas con *Diplocarpon Rosae*, obteniendo así una base de datos de 2698 imágenes podemos ver la muestra en la fig. 2.

**Figura 2**

*Tipo de Hojas sanas e infectadas con la plaga.*



## 2.2. Preparación del Dataset

### 2.2.1. Creación del Dataset para Clasificación

La creación del Dataset fue uno de los aspectos fundamentales en la realización de este proyecto, ya que tenía el propósito de ser utilizado en distintas redes neuronales convolucionales. No obstante, se debieron considerar factores que podrían afectar, como la calidad de las imágenes o la pérdida de definición. Por esta razón, se tomó la medida de ajustar y preparar las imágenes para su uso en los procesos de entrenamiento.


### 2.2.2. Creación del Dataset para Detección

La creación del Dataset para la detección de *Diplocarpon Rosae* se realizó con la asistencia del software MakeSense. Esta herramienta de etiquetado de imágenes en línea, de acceso gratuito, demostró ser sumamente útil para proyectos computacionales de aprendizaje profundo a pequeña escala. Facilitó de manera eficiente y sencilla el proceso de preparación del Dataset (Bai et al., 2021).

Las anotaciones se crearon en un archivo de texto sin formato que contenía los parámetros de la clase de entidad, las coordenadas del centro del cuadrado y su tamaño. Una vez completadas estas anotaciones, se obtuvo un Dataset debidamente preparado, listo para ser empleado en el modelo de detección de la plaga *Diplocarpon Rosae*. Esta etapa resultó fundamental para garantizar la precisión y eficacia del modelo en la identificación de la plaga en las imágenes.

### Figura 3

*Herramienta de etiquetado de imágenes MakeSense ai*



### **2.2.3. Creación del Dataset para Segmentación**

La preparación del Dataset para la segmentación de imágenes de la plaga *Diplocarpon Rosae* se llevó a cabo mediante el uso de Roboflow, una herramienta en línea que permitió crear anotaciones precisas para el entrenamiento del modelo. Roboflow es una plataforma de visión por computadora que ofrece diversas opciones de anotación, que incluye la anotación de polígonos. Con este método, se trazaron coordenadas alrededor de las imágenes para delinear con precisión la ubicación de la plaga.

#### **Figura 4**

*Herramienta Roboflow para anotaciones de imágenes*



## **2.3 Construcción de modelo**

### **2.3.1. Entorno de trabajo**

El trabajo se desarrolló en el Computador Lambda Vector Workstation, proporcionado por la filial de la Universidad Peruana Unión en Juliaca. Dicha computadora estaba equipada con un sistema operativo Linux basado en Ubuntu versión 22, 2 unidades de procesamiento gráfico (GPU) de 10.24 GB cada una, un total de 64 unidades centrales de procesamiento (CPUs) AMD Ryzen Threadripper PRO 5975WX, y una capacidad de memoria RAM de 125 GB. Esta configuración se reveló como especialmente adecuada para llevar a cabo tareas relacionadas con el aprendizaje automático y el análisis de datos, ya que proporcionaba los recursos necesarios para entrenar modelos de clasificación, detección y segmentación de imágenes.

Utilizar el Computador Lambda Vector Workstation ofreció ventajas significativas, entre las que se incluye la disponibilidad de recursos en abundancia, así como la flexibilidad para instalar bibliotecas adicionales según las necesidades específicas del proyecto. Esta

plataforma simplificó notablemente el proceso de desarrollo y experimentación al proporcionar un entorno de trabajo altamente eficiente y adaptable para la implementación de técnicas de aprendizaje automático.

### 2.3.2. Modelo de clasificación

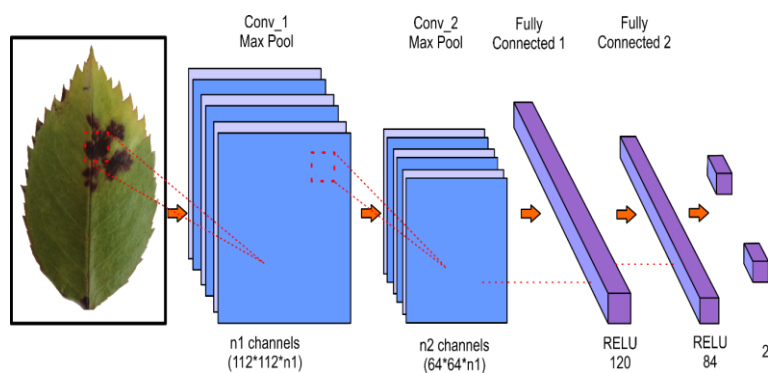
#### 2.3.2.1. Modelo propuesto.

En el proceso de entrenamiento del modelo, se emplearon diversas bibliotecas, entre ellas Pytorch y torchvision. Para diseñar la arquitectura de la red neuronal, se aplicó dos capas convolucionales, después de cada capa se redujo su tamaño de las imágenes con MaxPool. Finalmente, se incorporó una función de activación no lineal que se aplicó a las salidas de las redes neuronales.

Las imágenes de entrada tenían un tamaño de 224x224 píxeles, se aplicó una transformación de redimensionamiento utilizando las bibliotecas de transformación proporcionadas por Pytorch. Esto permitió que las imágenes se ajustaran al formato requerido para el proceso de entrenamiento, que garantizó así una adaptación adecuada a la arquitectura de la red neuronal y al Dataset empleado.

**Figura 5**

*Modelo Propuesto de Clasificación*



#### 2.3.2.2. Transfer learning.

El Transfer Learning es una técnica empleada en el aprendizaje profundo que implica la utilización de un modelo pre-entrenado (Plested & Gedeon, 2022). En esta investigación, se emplearon tres modelos pre-entrenados de Pytorch: VGG16, ResNet50 y AlexNet. ResNet50 contiene 49 capas convolucionales y una capa completamente conectada al final de la red. La

arquitectura ResNet50 se caracteriza por su profundidad y habilidad para aprender representaciones más complejas y profundas de las imágenes. Por otro lado, AlexNet cuenta con 60 millones de parámetros y 650,000 neuronas y se compone de cinco capas convolucionales con tres capas completamente conectadas, lo cual posibilita la captura de patrones y matices complejos presentes en las imágenes (Maeda, 2019).

### **2.3.3. Modelo de detección**

Para la tarea de detección, se optó por implementar la arquitectura YOLOV5, la cual se caracteriza por su eficacia y precisión en la identificación de objetos (Hussain, 2023). Este modelo de detección se basa en una estructura denominada Ultralytics, que se divide en tres componentes fundamentales.


En primer lugar, el "backbone" cumple la función de extraer características de niveles profundos de la imagen. Este componente incorpora elementos como ConvBNSiLU, BottleNeck 1, C3 y SPPF, los cuales desempeñan un papel crucial en la extracción y representación de las características relevantes en la imagen.

Seguido de esto, el componente "neck" se encarga de combinar información proveniente de capas de diferentes profundidades. Este componente está compuesto por ConvBNSiLU, BottleNeck 2, C3, Upsample y Concat. Su objetivo es fusionar y enriquecer la información extraída previamente del "backbone", lo que contribuye a una percepción más completa de los detalles presentes en la imagen.

Finalmente, el componente "head" se dedica a la generación de predicciones. Aquí es donde se lleva a cabo la identificación y localización de los objetos de interés en la imagen. Estas tres partes, "backbone", "neck" y "head", colaboran en conjunto para formar la estructura integral del modelo de detección YOLOV5 basado en Ultralytics, esto se puede ver en la fig. 6.

**Figura 6**

*Diagrama de estructura del modelo YOLOV5*




#### **2.3.4. Modelo de segmentación**

Se implementó la arquitectura YOLO en las versiones 7 y 8, las cuales son muy similares a YOLOV8-Detect, cuya arquitectura está representada en la fig. 7. Sin embargo, se introduce un módulo de salida adicional en el componente principal, encargado de generar coeficientes de máscara. Además, se incorpora una capa completamente convolucional (FCN) adicional llamada módulo Proto, cuyo propósito era generar máscaras específicas relevantes para la tarea de segmentación. En la tarea de segmentación, se utilizó un backbone conocido como extractor de funciones CSPDarknet53. Posteriormente, se incorpora un módulo C2f, seguido por dos cabezales de segmentación. El módulo Proto incluyó una capa SPPF (Feature Pyramid Pooling), junto con cinco capas subsiguientes de convolución. Este modelo cuenta cabezales de detección, los cuales consistían en módulos de detección, capas Upsample, módulos c2f, capas Concat y capas de predicción, estos componentes permitieron la identificación precisa de objetos y la generación de máscaras para la tarea de segmentación de instancias como el trabajo de Yue et al., (2023).

## Figura 7

Diagrama de estructura del modelo de detección YOLOv8. Fuentes Ultralytics



## 3. Pruebas

La asignación del dataset se llevó a cabo de la siguiente manera: un 60% del conjunto total se destinó al propósito de entrenamiento, mientras que un 20% se reservó para las pruebas y otro 20% se empleó en la etapa de validación.

### 3.1. Pruebas realizadas a los modelos de clasificación

Se realizaron pruebas en cuatro modelos diferentes: AlexNet, ResNet50, VGG16 y un modelo personalizado. Estos modelos se evaluaron métricas comunes, como Accuracy, Precision, Recall y F1, que se utilizan ampliamente para medir el rendimiento del modelo. Estas métricas brindan una visión integral del rendimiento de cada modelo, lo que permite una comparación efectiva entre ellos.

#### 3.1.1. Primera prueba

En la primera prueba de los modelos AlexNet, ResNet50, VGG16 y un modelo propuesto, se realizó usando Adam (Adaptive Moment Estimation) este es un algoritmo de optimización utilizado para optimizar los parámetros de un modelo de aprendizaje automático, como una red neuronal, mediante la actualización iterativa de los valores de los parámetros en función del gradiente de la función de pérdida, también se utilizó CosineAnnealingLR, que es un programador de tasa de aprendizaje que utiliza una función de coseno para ajustar cíclicamente la tasa de aprendizaje durante el entrenamiento de la red neuronal. Los resultados de esta primera prueba se pueden observar en la tabla 2.

**Tabla 2***Resultados de la prueba 1 realizada al modelo de clasificación*

<b>Modelo</b>	<b>Accuracy</b>	<b>Presicion</b>	<b>Recall</b>	<b>F1</b>
AlexNet	0.54	0.54	1	0.7
ResNet50	0.93	0.98	0.89	0.93
VGG16	0.54	0.54	1	0.69
Propuesto	0.59	0.57	1	0.72

**3.1.2. Segunda prueba**

Para la segunda prueba de los modelos AlexNet, ResNet50, VGG16 y un modelo personalizado, se realizó usando SGD (Stochastic Gradient Descent) este es un algoritmo fundamental y versátil en el aprendizaje automático, aunque puede requerir un ajuste cuidadoso de la tasa de aprendizaje y otros hiperparámetros. SGD es eficiente y efectivo para entrenar modelos con muchos datos. También se utilizó StepLR, que es un programador de tasa de aprendizaje utilizado en el entrenamiento de redes neuronales. Este programador ajusta la tasa de aprendizaje en función de un programa de pasos predefinido durante el entrenamiento. Los resultados de esta segunda prueba se pueden observar en la tabla 3.

**Tabla 3***Resultados de la prueba 2 realizada al modelo de clasificación*

<b>Modelo</b>	<b>Accuracy</b>	<b>Presicion</b>	<b>Recall</b>	<b>F1</b>
AlexNet	0.95	0.95	0.95	0.95
ResNet50	0.99	0.99	0.98	0.99
VGG16	0.99	0.99	0.98	0.98
Propuesto	0.91	0.91	0.91	0.92

**3.2. Pruebas realizadas a los modelos de detección**

Las pruebas se realizaron en 2 modelos, el modelo YOLOV5m pre-entrenado y no pre-entrenado, los cuales se evaluaron en 4 métricas: precisión, recall, F1 y mAp50. En cada prueba se usaron diferentes hiperparámetros hyp low (hiperparámetro de bajo rendimiento), hyp med (hiperparámetro de mediano rendimiento) y hyp high (hiperparámetro de alto rendimiento), con el fin de obtener el mejor rendimiento y resultados.

Se realizó un análisis detallado y completo de los hiperparámetros utilizados en diversas configuraciones, con el propósito de detectar cualquier diferencia significativa entre los parámetros empleados en cada conjunto de hiperparámetros. Tras examinar minuciosamente los datos, se llegó a la conclusión de que varios de los parámetros utilizados eran idénticos en todas las configuraciones de hiperparámetros evaluadas. Los valores consistentes que se encontraron son los siguientes:

- Tasa de aprendizaje (lr0): 0.01
- Momentum: 0.937
- Weight Decay: 0.0005
- Umbral de confianza para detección: 0.05
- Peso de pérdida de clasificación: 1.0
- Umbral de IoU para detección positiva: 0.20
- Anchor Tamaño: 4.0
- Ajuste de valor de saturación en el espacio de color HSV: 0.015
- Probabilidad de volteo horizontal de la imagen: 0.5
- Probabilidad de aplicar el mosaico durante el entrenamiento: 1.0

Estos parámetros se mantienen constantes en todas las configuraciones evaluadas, lo que puede indicar su importancia y su efecto positivo en el rendimiento del modelo durante el entrenamiento.

### ***3.2.1. Primera prueba***

En la primera prueba del modelo pre-entrenado YOLOV5m y modelo no pre-entrenado se usó "hyp low" (hiperparámetros bajos) Este hiperparámetro se usó con el objetivo de tener una configuración más conservadora y controlada para la prueba inicial del modelo. Además de los parámetros mencionados anteriormente, se incluyeron los parámetros específicos de "hyp low", los cuales son:

- Tasa de aprendizaje (lrf): 0.01
- Peso de pérdida de clasificación (cls): 0.5
- Peso de pérdida de objeto (obj): 1.0
- Escala (scale): 0.5

Los resultados de esta primera prueba con hyp low son los que se observan en la tabla 4.

**Tabla 4**

*Resultados de la prueba 1 realizada al modelo de detección*

<b>Modelo</b>	<b>Presicion</b>	<b>Recall</b>	<b>F1</b>	<b>mAP50</b>
Pre-Entrenado YOLOV5m	0.83	0.8	0.81	0.85
No Pre-Entrenado	0.829	0.81	0.82	0.89

### **3.2.2. Segunda prueba**

En la segunda prueba del modelo pre-entrenado YOLOv5m y modelo no pre-entrenado se usó "hyp med" (hiperparámetros medios) esta configuración busca un equilibrio entre la estabilidad del entrenamiento y un enfoque más arriesgado para obtener mejores resultados. Además de los parámetros mencionados anteriormente, se incluyeron los parámetros específicos de "hyp med, los cuales son:

- Tasa de aprendizaje (lrf): 0.1
- Peso de pérdida de clasificación (cls): 0.3
- Peso de pérdida de objeto (obj): 1.7
- Escala (scale): 0.9
- Mezcla de imágenes (mixup): 0.1

Los resultados de esta segunda prueba con hyp med son los que se observan en la tabla 5.

**Tabla 5**

*Resultados de la prueba 2 realizada al modelo de detección*

<b>Modelo</b>	<b>Presicion</b>	<b>Recall</b>	<b>F1</b>	<b>mAP50</b>
Pre-Entrenado YOLOV5m	0.82	0.76	0.79	0.82
No Pre-Entrenado	0.84	0.83	0.83	0.85

### 3.2.3. Tercera prueba

En la tercera prueba del modelo pre-entrenado y modelo no pre-entrenado se usó "hyp high"(hiperparámetros altos) esta configuración busca un enfoque más arriesgado y agresivo para la optimización del modelo. Además de los parámetros mencionados, se incluyeron los parámetros específicos de "hyp high" , los cuales son:

- Tasa de aprendizaje (lrf): 0.1
- Peso de pérdida de clasificación (cls): 0.3
- Peso de pérdida de objeto (obj): 0.7
- Escala (scale): 0.9
- Mezcla de imágenes (mixup): 0.1

Los resultados de esta tercera prueba con hyp high son los que se observan en la tabla 6.

**Tabla 6**

*Resultados de la prueba 3 realizada al modelo de detección*

Modelo	Presicion	Recall	F1	mAP50
Pre-Entrenado YOLOV5m	0.82	0.76	0.79	0.81
No Pre-Entrenado	0.85	0.78	0.81	0.83

### 3.3. Pruebas realizadas a los modelos de segmentación

#### 3.3.1. YOLOV7

La versión 7.0 es el modelo más reciente y el más rápido de la familia YOLO, con una velocidad promedio de 40 FPS y una precisión promedio del 95%. En este caso, se realizó una comparación exhaustiva de los hiperparámetros utilizados en diferentes configuraciones. El objetivo fue identificar diferencias significativas entre los parámetros utilizados en cada conjunto de hiperparámetros. Después de realizado el análisis, se concluyó que varios parámetros utilizados eran los mismos en todos los conjuntos de hiperparámetros evaluados. Los valores consistentes encontrados son:

- Tasa de aprendizaje (lr0): 0.01
- Momentum: 0.937

- Weight Decay: 0.0005
- Umbral de confianza para detección (box): 0.05
- Peso de pérdida de clasificación (Cls-pw): 1.0
- Umbral de IoU para detección positiva (iou-t): 0.20
- Anchor Tamaño (anchor-t): 4.0
- Ajuste de valor de saturación en el espacio de color HSV (hsv-h): 0.015
- Probabilidad de volteo horizontal de la imagen (fliplr): 0.5
- Probabilidad de aplicar el mosaico durante el entrenamiento (mosaic): 1.0

Estos parámetros son importantes y pueden tener un impacto en el rendimiento del modelo durante el entrenamiento y la inferencia porque son constantes en todas las configuraciones que se evaluaron. Los resultados obtenidos se pueden observar en la tabla 7.

#### **3.3.1.1. Primera prueba.**

En la primera prueba de modelo de segmentación, se empleó un hiperparámetro de bajo rendimiento. Aparte de los parámetros previamente indicados, se introdujeron también los parámetros particulares de la configuración, los cuales son:

- Tasa de aprendizaje (lrf): 0.01
- Peso de pérdida de clasificación (cls): 0.5
- Peso de pérdida de objeto (obj): 1.0
- En Escala (scale): 0.5

Este hiperparámetro se seleccionó con el objetivo de tener una configuración conservadora y controlada para la prueba inicial del modelo.

#### **3.3.1.2. Segunda prueba.**

En la segunda prueba del modelo de segmentación, se aplicó el hiperparámetro de mediano rendimiento. Aparte de los parámetros previamente mencionados, se incorporaron también los parámetros característicos de la configuración, los cuales son:

- Tasa de aprendizaje (lrf): 0.01
- Peso de pérdida de clasificación (cls): 0.5
- Peso de pérdida de objeto (obj): 1.0
- En Escala (scale): 0.5

- Mezcla de imágenes (mixup): 0.1

Con esta configuración, se buscó un equilibrio entre la estabilidad del entrenamiento y un enfoque más arriesgado para obtener mejores resultados.

### 3.3.1.3. Tercera prueba.

En tercera prueba del modelo de segmentación, se empleó el hiperparámetros de alto rendimiento. Además de los parámetros previamente referidos, se agregaron los parámetros característicos de la configuración, los cuales son:

- Tasa de aprendizaje (lrf): 0.01
- Peso de pérdida de clasificación (cls): 0.5
- Peso de pérdida de objeto (obj): 1.0
- En Escala (scale): 0.5
- Mezcla de imágenes (mixup): 0.1

Con esta configuración, se busca un enfoque más arriesgado y agresivo para la optimización del modelo.

**Tabla 7**

*Resultados de las pruebas realizadas al modelo de segmentación en YOLOV7*

<b>Modelo</b>	<b>Precisión</b>	<b>Recall</b>	<b>mAP50</b>	<b>mAP50:95</b>
YOLOV7-low	0.716	0.654	0.678	0.38
YOLOV7-med	0.727	0.631	0.68	0.377
YOLOV7-high	0.727	0.629	0.669	0.37

### 3.3.2. YOLOV8

YoloV8 es la última versión de la familia de modelos de detección de objetos basados en YOLO de Ultralytics, el modelo YoloV8 más rápido y preciso. A la vez, proporciona un marco unificado de entrenamiento de modelos desde detección, segmentación y clasificación de objetos. Existen 5 modelos para cada marco de entrenamiento, primero con YOLOv8n-seg, que es el modelo más pequeño y liviano de la familia YoloV8. Ofrece una mayor velocidad de

procesamiento, adecuado para dispositivos con recursos limitados o aplicaciones en tiempo real. Esto compensa la precisión ligeramente inferior que puede llegar a alcanzar.

Yolov8s-seg es un modelo de tamaño mediano equilibrado entre velocidad y precisión, que proporcionó mejor precisión que Yolov8n-seg, pero con una velocidad de procesamiento ligeramente más lenta.

Yolov8m-seg es un modelo más grande y poderoso que el anterior, que ofrece una mayor precisión en la segmentación de objetos. Compensa su lentitud en la velocidad de procesamiento en comparación con los modelos más pequeños, adecuado para aplicaciones que requieran mayor precisión en segmentación de objetos.

Yolov8l-seg es el modelo más grande y pesado de la familia Yolov8, que proporcionó la mayor precisión en segmentación de objetos, pero más lenta en la velocidad de procesamiento en comparación con el resto de los modelos.

Yolov8x-seg es el modelo más preciso pero el más lento de todos los modelos. Es adecuado para aplicaciones que requieran precisión muy alta en la segmentación y cuenten con recursos computacionales suficientes. Se realizaron las pruebas con todos los modelos mencionados, los resultados obtenidos se encuentran en la tabla 8.

**Tabla 8**

*Resultados de las pruebas realizadas al modelo de segmentación en YOLOV8*

<b>Modelo</b>	<b>Precisión</b>	<b>Recall</b>	<b>mAP50</b>	<b>mAP50:95</b>
YOLOV8n-seg	0.708	0.646	0.647	0.338
YOLOV8s-seg	0.689	0.641	0.629	0.318
YOLOV8m-seg	0.712	0.635	0.646	0.333
YOLOV8l-seg	0.705	0.624	0.619	0.318
YOLOV8x-seg	0.708	0.627	0.617	0.342

## 4. Resultados

### 4.1. Resultados del modelo de clasificación

#### 4.1.1. Primera prueba

En esta primera prueba de clasificación, con los resultados de precisión y F1, obtenemos el mejor modelo, que en este caso sería ResNet50, ya que obtuvo un 0.93 en F1, que a su vez es la combinación de precisión y Recall. También obtuvo un 0.98 en precisión, que mide la exactitud del modelo. Los resultados se pueden observar en la fig. 8.

#### 4.1.2. Segunda prueba

En cuanto a la segunda prueba del modelo de clasificación, se obtuvo un empate entre el modelo ResNet50 y VGG16. Ambos modelos llegan al resultado de 0.99 en las métricas de Accuracy, Precision y hay una leve variación en las métricas de Recall y F1.

### Figura 8

*Clasificación de hoja sana y hoja con Diplocarpon Rosae con ResNet50*



### 4.2. Resultados del modelo de detección

#### 4.2.1. Primera prueba


En la primera prueba en el modelo de detección el mejor modelo es el no-pre-entrenado usando los hiperparámetro de bajo rendimiento, esta logró un resultado en F1 de 0.82 y un mAP50 de 0.89.

#### 4.2.2. Segunda prueba

En la segunda prueba en el modelo de detección, el modelo pre-entrenado consiguió un resultado en F1 de 0.79 y mAP50 de 0.81 inferior al modelo no-pre-entrenado con resultados de F1 de 0.83 y mAP50 de 0.85 superior al modelo pre-entrenado, a diferencia de la primera prueba se utilizó el hiperparámetro de mediano rendimiento, el resultado del modelo pre-entrenado se puede ver en la fig. 9.

**Figura 9**

*Detección de Diplocarpon Rosae el modelo Pre-entrenado YOLOV5m*




#### 4.2.3. Tercera prueba

En esta tercera prueba en el modelo de detección el mejor resultado fue del modelo No-pre-entrenado, Con la diferencia de que en este caso se usó el hiperparámetro de alto rendimiento, esta obtuvo un resultado en F1 de 0.81 y un mAP50 de 0.82 igual que con el hiperparámetro de mediano rendimiento, a diferencia del modelo pre-entrenados que obtuvo un resultado de F1 de 0.79 y un mAP50 de 0.81, el resultado del modelo no-pre-entrenado se pueden visualizar en la fig. 10.

**Figura 10**


*Detección de Diplocarpon Rosae el modelo No Pre-entrenado*



Luego de realizar las pruebas se realizó una comparación entre los mejores resultados de modelos pre-entrenado y no-pre-entrenado, en este caso en el modelo pre-entrenado con hiperparámetro de alto rendimiento donde se obtuvo un resultado de F1 de 0.79 y un mAP50 de 0.81, en caso de el modelo de no-pre-entrenado con hiperparámetro de mediano rendimiento donde se obtuvo un resultado de F1 de 0.83 y mAP50 de 0.85, el resultado de esta comparación se puede visualizar en la fig. 11.

### Figura 11

*Comparación de los modelos de detección Pre-entrenado y No-pre-entrenado*




## 4.3. Resultados del modelo de segmentación

### 4.3.1. YOLOV7

El modelo de segmentación con YOLOV7-hyp-med tiene una precisión similar a las demás pruebas. Estas últimas métricas calculan el promedio de las precisiones promedio para diferentes umbrales de IoU (Intersección sobre Unión), donde IoU es un valor que mide la superposición entre la predicción del modelo y la verdad del terreno. La métrica más importante es la del mAP50 y map50:95, en las cuales es ligeramente superior al resto con 0.68 en mAP50 y 0.377 el modelo YOLOV7 hiperparámetro de alto rendimiento muestra mejores resultados en este caso, debido a las métricas mencionadas anteriormente como se muestra en la tabla 7 y también se muestra una representación de los resultados con las imágenes sometidas al modelo en la fig. 12.

## Figura 12

Segmentación de *Diplocarpon Rosae* mediante el proceso de segmentación y superposición con YOLOv7




### 4.3.2. YOLOV8

El modelo de segmentación realizado con YOLOV8m-seg logró resultados superiores al resto de modelos empleados, YOLOV8s-seg, n-seg, l-seg y x-seg, respectivamente. El modelo obtuvo resultados superiores en Recall y mAP50, el modelo YOLOV8-m obtuvo 0.635 en recall y 0.805 en mAP50, estos los resultados más altos en las pruebas realizadas, solo fue superado en el parámetro de medición Precision por el modelo YOLOV8x-seg con 0.708 contra 0.712 del modelo YOLOV8-m-seg como se muestra en la tabla 8, así mismo se muestra los resultados obtenidos en la fig.13, adicionalmente en la fig. 14 se muestra una comparación de los resultados en los modelos YOLOV7 y YOLOV8 usados para la segmentación.


## Figura 13

Segmentación de *Diplocarpon Rosae* mediante el proceso de segmentación y superposición con YOLOV8m-seg.



## Figura 14

*Comparación de los modelos usados para segmentación de YOLOV7 y YOLOV8*



## 5. Conclusiones

En este trabajo se demostró que los modelos basados en redes neuronales convolucionales, empleado en hojas infestadas por *Diplocarpon rosae* en cultivos de rosas en las zonas altoandinas de la región Puno, que exhiben un funcionamiento eficiente para la clasificación, detección y segmentación de la patología.

Se demostraron importantes resultados en la problemática abordada en este trabajo, a través de los modelos, que se evaluaron con métricas de rendimiento como Accuracy, Precision, Recall, F1, mAP50 y mAP50:95 para garantizar su confiabilidad. Se realizaron pruebas al modelo propuesto comparándolo con modelos pre-entrenados con cada una de las métricas, obteniendo los mejores resultados en cada tarea. En clasificación, los modelos ResNet50 y VGG16 demostraron una mejor exactitud de 0.99. En detección, el modelo no pre-entrenado obtuvo una precisión del 0.85. Para la tarea de segmentación, se utilizó YOLOV7 con un mAP50 del 0.68.

Este estudio demostró resultados eficientes con un muestreo de 2698 imágenes. Sin embargo, es importante probar y aplicar estos modelos en una muestra más amplia. Además, se considera fundamental profundizar en este tipo de estudios, no solo en las plagas que afectan a las rosas, sino también en diversos tipos de plantas y frutos. Este estudio se puede utilizar como base para llevar a cabo pruebas extensas con Datasets más amplios para la segmentación. Para lograr la segmentación en tiempo real de imágenes de rosas o plagas, se planean realizar pruebas adicionales. Se buscarán nuevas áreas de cultivo de rosas para realizar un mayor número de pruebas. Además, este trabajo aportará a investigaciones futuras

con la liberación del dataset y se planea implementar estos avances en escenarios de cultivo en el distrito de Coasa.

## Referencias

- Albattah, W., Nawaz, M., Javed, A., Masood, M., & Albahli, S. (2022). A novel deep learning method for detection and classification of plant diseases. *Complex and Intelligent Systems*, 8(1), 507–524. DOI: 10.1007/s40747-021-00536-1
- Bai, X., Wang, X., Liu, X., Liu, Q., Song, J., Sebe, N., & Kim, B. (2021). Explainable deep learning for efficient and robust pattern recognition: A survey of recent developments. *Pattern Recognition*, 120. Elsevier Ltd. DOI: 10.1016/j.patcog.2021.108102
- Baysal-Gurel, F., & Philips, A. C. (2019). La enfermedad del punto negro de la rosa.
- Bonillo Carrasco Miriam. (2021). Una propuesta de gestión de enfermedades en el parque del oeste de la ciudad de Valencia.
- Charles, G. (2019). Monitoreo de enfermedades de rosales de la rosaleda del prado de Montevideo.
- Dalai, R., & Senapati, K. K. (2019). An Intelligent Vision based Pest Detection System Using RCNN based Deep Learning Mechanism.
- Debener, T. (2017). Inheritance of Characteristics. In *Reference Module in Life Sciences*. Elsevier. DOI: 10.1016/b978-0-12-809633-8.05047-0.
- Dong, Q., Wang, X., Byrne, D. H., Ong, K. (2017). Characterization of partial resistance to black spot disease of *Rosa* sp. *HortScience*, 52(1), 49–53. DOI: 10.21273/HORTSCI11349-16
- Du, L., Sun, Y., Chen, S., Feng, J., Zhao, Y., Yan, Z., Zhang, X., & Bian, Y. (2022). A Novel Object Detection Model Based on Faster R-CNN for *Spodoptera frugiperda* According to Feeding Trace of Corn Leaves. *Agriculture (Switzerland)*, 12(2). DOI: 10.3390/agriculture12020248
- Huaman, L. (2021). Costos de producción y el precio de las rosas en la asociación de floricultores “SAWASIRAY”, Cusco, 2020.
- Hussain, M. (2023). YOLO-v1 to YOLO-v8, the Rise of YOLO and Its Complementary Nature toward Digital Manufacturing and Industrial Defect Detection. *Machines*, 11(7). Multidisciplinary Digital Publishing Institute (MDPI). DOI: 10.3390/machines11070677
- Junio, A.-, & Olivera, E. B. (2019). Impacto del cambio climático en el rendimiento de la producción de cañihua (*Chenopodium pallidicaule*) en la Región - Puno. *Journal of High Andean Research*, 21(2), 100–110. DOI: 10.18271/ria.2019.45

- Li, L., Zhang, S., & Wang, B. (2021). Plant Disease Detection and Classification by Deep Learning - A Review. *IEEE Access*, 9, 56683–56698. Institute of Electrical and Electronics Engineers Inc. DOI: 10.1109/ACCESS.2021.3069646
- Liu, L., Wang, R., Xie, C., Yang, P., Wang, F., Sudirman, S., & Liu, W. (2019). PestNet: An End-to-End Deep Learning Approach for Large-Scale Multi-Class Pest Detection and Classification. *IEEE Access*, 7, 45301–45312. DOI: 10.1109/ACCESS.2019.2909522
- Maeda, V. (2019). Comparación de arquitecturas de redes neuronales convolucionales para la clasificación de enfermedades en tomate.
- Marchant, R., Davey, M. R., Lucas, J. A., Lamb, C. J., Dixon, R. A., & Power, J. B. (1998). Expression of a chitinase transgene in rose (*Rosa hybrida* L.) reduces development of blackspot disease (*Diplocarpon rosae* Wolf). *Molecular Breeding*, 4(4).
- Marroquin, U., Saboya, N., & Sullon, A. A. (2021). Machine Learning-based predictive model for the prognosis of human papillomavirus (HPV) vaccination attrition. 2021 4th International Conference on Robot Systems and Applications, 44–49. DOI: 1145/3467691.3467695
- Medina Tobón, D. (2021). Conteo de flores y frutos para el monitoreo del cultivo de aguacate Hass por medio de imágenes utilizando Machine Learning.
- Neu, E., Featherston, J., Rees, J., & Debener, T. (2017). A draft genome sequence of the rose black spot fungus *Diplocarpon rosae* reveals a high degree of genome duplication. *PLoS ONE*, 12(10). DOI: 10.1371/journal.pone.0185310
- Ngugi, L. C., Abelwahab, M., & Abo-Zahhad, M. (2021). Recent advances in image processing techniques for automated leaf pest and disease recognition – A review. *Information Processing in Agriculture*, 8(1), 27–51. China Agricultural University. DOI: 10.1016/j.inpa.2020.04.004
- Plested, J., & Gedeon, T. (2022). Deep transfer learning for image classification: a survey. <http://arxiv.org/abs/2205.09904>
- Rajbongshi, A., Sarker, T., Ahamad, M. M., & Rahman, M. M. (2020, October 22). Rose Diseases Recognition using MobileNet. 4th International Symposium on Multidisciplinary Studies and Innovative Technologies, ISMSIT 2020 - Proceedings. DOI: 10.1109/ISMSIT50672.2020.9254420






- Samba, L., & Nazari, A. (2021). Tomato Leaf Disease Detection using Convolution Neural Network (CNN). *Evolution in Electrical and Electronic Engineering*, 2(2), 667–676. DOI: 10.30880/eeee.2021.02.02.080
- Sango Viracucha, B. A., Chanaluisa Orellana, C. G., & Llano Casa, A. C. (2021). Sistema inteligente para el análisis de plagas en plantas rosas Freedom aplicando redes neuronales. DOI: 10.26820/recimundo/5.(2).
- Sazzad, S., Rajbongshi, A., Shakil, R., Akter, B., & Kaiser, M. S. (2022). RoseNet: Rose leave dataset for the development of an automation system to recognize the diseases of rose. *Data in Brief*, 44. DOI: 10.1016/j.dib.2022.108497
- Yue, X., Qi, K., Na, X., Zhang, Y., Liu, Y., & Liu, C. (2023). Improved YOLOv8-Seg Network for Instance Segmentation of Healthy and Diseased Tomato Plants in the Growth Stage. *Agriculture (Switzerland)*, 13(8). DOI: 10.3390/agriculture13081643

## ANEXOS

### Anexo 1. Evidencia de Sumisión.

[CyS] Envío recibido

GS Grigori Sidorov  
<computacion-y-sistemas@cic.ipn.mx>  
Para: Daniel Andrés Sáenz Shupingahua Lun 23/10/2023 7:00

  Responder  Responder a todos  Reenviar  ...

Estiamdo/a Daniel Andrés Sáenz Shupingahua,



Gracias por enviarnos su manuscrito "Modelo de Deep Learning para reconocimiento de Diplocarpon Rosae en rosas Mister Lincoln en zonas altoandinas" a Computación y Sistemas. Gracias al sistema de gestión de revistas online que usamos podrá seguir su progreso a través del proceso editorial identificándose en el sitio web de la revista:

URL del manuscrito:  
<https://www.cys.cic.ipn.mx/ojs/index.php/CyS/author/submission/4719>  
Nombre de usuario/o: danielsaenz

Si tiene cualquier pregunta no dude en contactar con nosotros/as. Gracias por tener en cuenta esta revista para difundir su trabajo.

Atte,

Grigori Sidorov  
Computación y Sistemas

 Responder  Reenviar

## Anexo 2. Resolución de Inscripción del Perfil de Proyecto.



“AÑO DE LA UNIDAD, LA PAZ Y EL DESARROLLO”

RESOLUCIÓN N° 0165-2023/UPeU-FIA-CF-T

Lima, Ñaña 18 de abril de 2023

### VISTO:

El expediente de **Daniel Andres Saenz Shupingahua**, identificado(a) con Código Universitario N° 201810802, **Maycol Cahuana Diaz**, identificado(a) con Código Universitario N° 201811293 y **Guido Cristhian Quillimamani Soncco**, identificado(a) con Código Universitario N° 201811301, de la Escuela Profesional de Ingeniería de Sistemas de la Facultad de Ingeniería y Arquitectura de la Universidad Peruana Unión;

### CONSIDERANDO

Que la Universidad Peruana Unión tiene autonomía académica, administrativa y normativa, dentro del ámbito establecido por la Ley Universitaria N° 30220 y el Estatuto de la Universidad;

Que la Facultad de Ingeniería y Arquitectura de la Universidad Peruana Unión, mediante sus reglamentos académicos y administrativos, ha establecido las formas y procedimientos para la aprobación e inscripción del perfil de proyecto de tesis en formato artículo y la designación o nombramiento del asesor para la obtención del título profesional;

Que **Daniel Andres Saenz Shupingahua**, **Maycol Cahuana Diaz** y **Guido Cristhian Quillimamani Soncco**, han solicitado: la inscripción del perfil de proyecto de tesis titulado "Reconocimiento de Diplocarpon Rosae en hojas de rosas (Mister Lincoln) mediante redes neuronales y visión computacional en Puno" y la designación del Asesor, encargado de orientar y asesorar la ejecución del perfil de proyecto de tesis en formato artículo;

Estando a lo acordado en la sesión del Consejo de la Facultad de Ingeniería y Arquitectura de la Universidad Peruana Unión, celebrada el 18 de abril de 2023, y en aplicación del Estatuto y el Reglamento General de Investigación de la Universidad;

### SE RESUELVE:

Aprobar el perfil de proyecto de tesis en formato artículo titulado "**Reconocimiento de Diplocarpon Rosae en hojas de rosas (Mister Lincoln) mediante redes neuronales y visión computacional en Puno**" y disponer su inscripción en el registro correspondiente, designar al (a la) **Mg. Abel Angel Sullon Macalupu** como ASESOR para que oriente y asesore la ejecución del perfil de proyecto de tesis en formato artículo el cual fue dictaminado por: **MSc. Fredy Abel Huanca Torres** y **Mg. Ferdinand Edgardo Pineda AnccoJuliaa**, otorgándoles un plazo máximo de doce (12) meses para la ejecución.

Regístrese, comuníquese y archívese.



  
Dra. Erika Inés Acuña Salinas  
DECANA



  
Dr. Santiago Ramirez Lopez  
SECRETARIO ACADÉMICO

cc:  
-Interesado  
-Asesor  
-Dirección General de Investigación  
-Archivo



“AÑO DE LA UNIDAD, LA PAZ Y EL DESARROLLO”

RESOLUCIÓN N° 0653-2023/UPeU-FIA-CF

Lima, Ñaña, 14 de noviembre de 2023

**VISTO:**

El expediente de los (las) bachilleres **Daniel Andres, Saenz Shupingahua** identificado(a) con código universitario N° **201810802**, **Guido Cristhian, Quillimamani Soncco** identificado(a) con código universitario N° **201811301** y **Maycol ,Cahuana Diaz** identificado(a) con código universitario N° **201811293**, de la Escuela Profesional de Ingeniería de Sistemas de la Facultad de Ingeniería y Arquitectura de la Universidad Peruana Unión;

**CONSIDERANDO:**

Que la Universidad Peruana Unión tiene autonomía académica, administrativa y normativa, dentro del ámbito establecido por la Ley Universitaria N° 30220 y el Estatuto de la Universidad;

Que la Facultad de Ingeniería y Arquitectura de la Universidad Peruana Unión, mediante sus reglamentos académicos y administrativos, ha establecido las formas y procedimientos para la sustentación de la tesis en formato artículo;

Que el Comité Dictaminador ha emitido su dictamen aprobando el informe de tesis titulado "Modelo de Deep Learning para reconocimiento de Diplocarpon Rosae en rosas Mister Lincoln en zonas altoandinas", presentado por los(las) bachilleres **Daniel Andres, Saenz Shupingahua, Guido Cristhian, Quillimamani Soncco** y **Maycol ,Cahuana Diaz** reuniendo de esta manera las condiciones previas para la declaratoria de expedito para la programación de la sustentación;

Estando a lo acordado en la sesión del Consejo de la Facultad de Ingeniería y Arquitectura de la Universidad Peruana Unión, celebrada el 14 de noviembre de 2023, y en aplicación del Estatuto y el Reglamento General de investigación de la Universidad;

**SE RESUELVE:**

1. Declarar expedito a los (las) bachilleres **Daniel Andrés, Sáenz Shupingahua, Guido Cristhian, Quillimamani Soncco** y **Maycol ,Cahuana Diaz**, para que sustenten la tesis en formato artículo "Modelo de Deep Learning para reconocimiento de Diplocarpon Rosae en rosas Mister Lincoln en zonas altoandinas", conducente a la obtención del título profesional de Ingeniero de Sistemas, el 04 de diciembre de 2023, a las 17:00 horas, en el Auditorio Auditorio Wellesley Muir.
2. Designar el Jurado de Sustentación, encargado de gestionar la sustentación respectiva, el mismo que queda constituido por los siguientes miembros:

Presidente: MSc. Herrera Yucra Benazir Francis  
Secretario: Ing. Chambi Aguilar Jenson Daniel  
Asesor: Mg. Sullon Macalupu Abel Angel  
Vocal 1: MSc. Ferdinand Edgardo Pineda Ancco  
Vocal 2: MSc. Huanca Torres Fredy Abel

Regístrese, comuníquese y archívese.



Dra. Erika Inés Acuña Salinas  
DECANA



Mg. Ketty Magaly Arellano Lino  
SECRETARIA ACADÉMICA

cc:  
-Interesado  
-Jurado (05)  
-Secretaría General  
-Archivo