

**UNIVERSIDAD NACIONAL DE JAÉN**

**CARRERA PROFESIONAL DE INGENIERÍA FORESTAL Y  
AMBIENTAL**



**UNIVERSIDAD NACIONAL  
DE JAÉN**

**TESIS PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERÍA  
FORESTAL Y AMBIENTAL**

**Estimación de severidad de roya del café en sistemas  
agroforestales, utilizando Deep Learning en las provincias de Jaén  
y San Ignacio, Departamento de Cajamarca, 2023.**

**Autor** : **Est. Naili Diomar Cieza Peña**  
**Est. Sherson Esmith Herrera Zamora**

**Asesor** : **Mg. Candy Lisbeth Ocaña Zúñiga**  
**Dr. Lenin Quiñones Huatangari**

**Línea de investigación:** Conservación, manejo y aprovechamiento de los recursos  
naturales.

**JAÉN – PERÚ, 2024**

## Reporte de similitud

NOMBRE DEL TRABAJO

**Estimación de severidad de roya del café en sistemas agroforestales, utilizando Deep Learning en las**

AUTOR

**Naili Diomar Cieza Peña & Sherson Esmit  
Herrera Zamora**

RECuento DE PALABRAS

**14637 Words**

RECuento DE CARACTERES

**74232 Characters**

RECuento DE PÁGINAS

**65 Pages**

TAMAÑO DEL ARCHIVO

**2.5MB**

FECHA DE ENTREGA

**Aug 19, 2024 10:14 AM GMT-5**

FECHA DEL INFORME

**Aug 19, 2024 10:15 AM GMT-5**

### ● 9% de similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para cada base de datos.

- 9% Base de datos de Internet
- Base de datos de Crossref
- 5% Base de datos de trabajos entregados
- 2% Base de datos de publicaciones
- Base de datos de contenido publicado de Crossref

### ● Excluir del Reporte de Similitud

- Material bibliográfico
- Coincidencia baja (menos de 15 palabras)

 UNIVERSIDAD NACIONAL DE JAÉN  
*Dr. Alexander Huamán Mera*  
Responsable de la Unidad de Investigación de la Facultad de Ingeniería

Resumen



## ACTA DE SUSTENTACIÓN

En la ciudad de Jaén, el 23 de agosto del 2024, siendo las 11.30 horas, se reunieron los integrantes del Jurado Evaluador designados con Resolución N° 037-2024-UNJ/FI

Presidente, Dr. Segundo Sánchez Tello

Secretario, Dr. Cirilo Mario Caira Mamani

Vocal, Lupo Leónidas Varas Ponce

Para evaluar la sustentación del Informe Final de Tesis titulado: "ESTIMACIÓN DE SEVERIDAD DE ROYA DEL CAFÉ EN SISTEMAS AGROFORESTALES, UTILIZANDO DEEP LEARNING EN LAS PROVINCIAS DE JAÉN Y SAN IGNACIO, DEPARTAMENTO DE CAJAMARCA, 2023", cuyos autores son los egresados Naili Diomar Cieza Peña y Sherson Esmith Herrera Zamora, de la Escuela Profesional de Ingeniería Forestal y Ambiental, teniendo como asesor asesores a Mg. Candy Lisbeth Ocaña Zuñiga y Dr. Lenin Quiñones Huatangari.

Después de la sustentación y defensa, el Jurado Evaluador acuerda:

( X ) Aprobar    (   ) Desaprobar    ( x ) Unanimidad    (   ) Mayoría

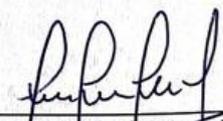
Con la siguiente mención:

Excelente	18, 19, 20	(   )
Muy bueno	16, 17	(   )
Bueno	14, 15	( 14 )
Regular	13	(   )
Desaprobado	12 o menos	(   )

Siendo las 13 horas del mismo día mes y año, el Jurado Evaluador concluye el acto de sustentación confirmando su participación con la suscripción de la presente.

  
\_\_\_\_\_  
Dr. Segundo Sánchez Tello  
Presidente Jurado Evaluador

  
\_\_\_\_\_  
Dr. Cirilo Mario Caira Mamani  
Secretario Jurado Evaluador

  
\_\_\_\_\_  
Dr. Lupo Leónidas Varas Ponce.  
Vocal Jurado Evaluador

## ÍNDICE

ÍNDICE .....	iv
ÍNDICE DE TABLAS.....	v
ÍNDICE DE FIGURAS.....	v
RESUMEN.....	vi
ABSTRACT .....	vii
I. INTRODUCCIÓN.....	1
II. MATERIAL Y METODOS.....	9
III. RESULTADOS.....	21
IV. DISCUSIÓN.....	37
V. CONCLUSIONES Y RECOMENDACIONES .....	39
VI. REFERENCIAS BIBLIOGRÁFICAS .....	41
AGRADECIMIENTO .....	47
DEDICATORIA .....	47
ANEXOS .....	48

## ÍNDICE DE TABLAS

Tabla 1 Población de la investigación .....	9
Tabla 2 Operacionalización de variables .....	11
Tabla 3 Niveles de severidad de la roya .....	14
Tabla 4 Matriz de confusión de la clasificación .....	19
Tabla 5 Especies forestales por parcela .....	19
Tabla 6 Precisión de los modelos. ....	21

## ÍNDICE DE FIGURAS

Figura 1 Hoja de café antes y después del procesamiento .....	17
Figura 2 Diagrama de Flujo de Severidad de Roya Mediante CNN .....	18
Figura 3 Inventario de especies de la Prosperidad Chirinos – San Ignacio.....	23
Figura 4 Inventario de especies de los lotes de La finca Palestina San José del Alto – Jaén .....	25
Figura 5 Porcentaje de sombra por lote en el distrito de Chirinos -San Ignacio .....	26
Figura 6 Porcentaje de sombra por lote en el distrito de San José del Alto – Jaén .....	27
Figura 7 Base de datos de severidad de roya según método de SENASA .....	28
Figura 8 Base de datos de severidad de roya según método de SENASICA México.....	29
Figura 9 Clasificación de severidad de roya según SENASA y SENASICA México. ....	30
Figura 10 Estructura de la red neuronal convolucional según SENASA .....	31
Figura 11 Estructura de la red neuronal convolucional según método alternativo de evaluación visual (SENASICA México).....	31
Figura 12 Modelo MobileNet.....	32
Figura 13 Modelo VGG16.....	33
Figura 14 Matriz de confusión de los modelos .....	34
Figura 15 Precisión de los modelos durante el entrenamiento. ....	35
Figura 16 Precisión del modelo durante la validación. ....	36

## RESUMEN

Los sistemas agroforestales pueden influir en la incidencia y abundancia de las plagas y enfermedades, debido a la combinación temporal de cultivos con árboles u otro tipo de vegetación para generar microclimas adecuados. La investigación tuvo como objetivo estimar la severidad de la roya de café en los sistemas agroforestales en distritos de la provincia de Jaén y San Ignacio, departamento de Cajamarca, 2023. El enfoque de investigación fue cuantitativo, de tipo descriptiva, se recolectaron 319 fotografías durante salidas de campo, las cuales fueron segmentadas, clasificadas y analizadas mediante Deep Learning considerando los métodos de medición de severidad de roya de SENASA Perú y SENASICA México y los modelos de aprendizaje de transferencia MobileNet y CNN (VGG16), ambos basados en aprendizaje profundo para la clasificación de enfermedades. Se obtuvo el grado de afectación 1 como el más prevalente de la severidad de la roya según la metodología de SENASA (1 al 5% de afectación de la hoja); de igual modo, el método SENASICA México indicó la prevalencia del grado 1 (0 al 2% de afectación). En cuanto a la red neuronal, el modelo propuesto MobileNet presentó la mejor tasa de precisión de clasificación del 94% en 50 etapas.

*Palabras clave.* Microclimas, estimación de sombra, especies forestales, algoritmo de aprendizaje, aprendizaje profundo.

## **ABSTRACT**

Agroforestry systems can influence the incidence and abundance of pests and diseases, due to the temporary combination of crops with trees or other vegetation to generate suitable microclimates. The research aimed to estimate the severity of coffee rust in agroforestry systems in districts of the province of Jaén and San Ignacio, department of Cajamarca, 2023. The research approach was quantitative, descriptive, 319 photographs were collected during field trips, which were segmented, classified and analyzed by Deep Learning considering the rust severity measurement methods of SENASA Peru and SENASICA Mexico and the transfer learning models MobileNet and CNN (VGG16), both based on deep learning for disease classification. Grade 1 was obtained as the most prevalent rust severity according to the SENASA methodology (1 to 5% leaf damage); similarly, the SENASICA Mexico method indicated the prevalence of grade 1 (0 to 2% damage). As for the neural network, the proposed MobileNet model presented the best classification accuracy rate of 94% in 50 stages.

*Keywords.* Microclimates, shadow estimation, forest species, learning algorithm, deep learning.

## I. INTRODUCCIÓN

La principal razón detrás del 80% de la deforestación es la expansión de la agricultura, implica la tala y quema de bosques para ampliar áreas agrícolas, lo que resulta en un cambio en el uso del suelo que afecta el equilibrio ecológico del bosque. Este cambio conlleva un aumento en la emisión de gases de efecto invernadero, así como pérdida de capacidad del bosque para proporcionar servicios de regulación, facilitando la propagación de plagas y enfermedades afectando su rendimiento (Libert y Paz, 2018).

Por ello la importancia de los sistemas agroforestales radica en combinar temporalmente cultivos con árboles u otro tipo de vegetación para generar microclimas adecuados. Son herramientas para mitigar efectos adversos del cambio climático (Parada et al., 2022). En el café, estos sistemas se adaptan a condiciones ecológicas específicas, creando microclimas que mejoran la productividad al reducir la temperatura relativa. Proporciona un entorno propicio para el intercambio gaseoso de los cafetales. Además, desde un punto de vista físico, ayudan a recuperar los nutrientes del suelo, lo que beneficia la calidad del mismo (DaMatta y Rodríguez, 2007). La finalidad es lograr producciones agrícolas sostenibles que se mantenga con el tiempo debido a condiciones ambientales estables. Esto incluye calidad del suelo, que se beneficia de la presencia de nutrientes esenciales, estabilidad climática y control de enfermedades de los cultivos (Márquez et al., 2020).

Pumisacho (2022), su investigación referente al *Inga spp* en sistemas agroforestales compara los indicadores de desarrollo fenológico, el aporte de minerales y la presencia de organismos beneficiosos en las especies *I. edulis* e *I. vera*. El estudio se realizó mediante un diseño de bloques completamente al azar (DBCA) con tres tratamientos y seis repeticiones. *I. edulis* muestra un crecimiento polinómico, alcanzando una altura de hasta 5.79 m, un diámetro a la altura del pecho (DAP) de 0.075 m y 31.66 ramas con un diámetro de sombra de 5.94 m, superando a *I. vera*, que alcanzó una altura de 4.74 m, un DAP de 0.061 m y 14.33 ramas con un diámetro de sombra de 4.79 m. En cuanto a su aporte al suelo, se encontró que *I. vera* contribuye con NH<sub>4</sub>, K y Mg, mientras que *I. edulis* aporta más P y Ca. La reserva mineral foliar varía, predominando *I. edulis* en NH<sub>4</sub>, P y

Mg foliares, aunque *I. vera* contiene más K y Ca foliares. En la hojarasca, *I. edulis* posee 3.13% de N, mientras que *I. vera* tiene 2.53% de N. Los microorganismos presentes en el ensayo fueron lombrices de tierra (*Lumbricus terrestris*) en el subsuelo, con mayor cantidad por árbol en *I. edulis* (22.6) que en *I. vera* (14.9). No obstante, en *I. vera* hay una mayor población de avispas *Polistes dominula* (4.6) y *Vespula vulgaris* (10.3), en comparación con *I. edulis*, que alcanza 2.7 y 5.2 individuos por árbol, respectivamente.

Considerando los efectos negativos del cambio climático en la agricultura, desde hace unas décadas atrás a cultivos como el café, este se ha venido cultivando bajo sombra de árboles para protegerlo de la luz solar directa (Farfán, 2014). Esta práctica es más empleada en países de Centro América, Colombia, Perú entre otros (Villarreyna, 2016). Precisamente, los sistemas agroforestales brindan la sombra necesaria para el cultivo de café, permitiendo que la producción sea adecuada, y evitando pérdidas, además que se gestione óptimamente los cultivos (Villarreyna et al., 2020).

En Perú, el café representa el principal producto agrícola exportado, lo que implica un importante respaldo para el sustento y crecimiento de alrededor de 223 mil familias situadas principalmente en los departamentos de Junín, San Martín, Cajamarca, Cusco, Amazonas, Huánuco y Pasco. Estos concentran el 91% de la producción y las áreas de cultivo. El café es una cosecha permanente en el país y se cultiva principalmente en la región de la selva alta o yunga. Las plantaciones de café se establecen en el bosque tropical húmedo de las laderas, caracterizado por suelos propensos a erosión, lo que impacta negativamente en la capacidad productiva a largo plazo del suelo (Llanos, 2021). En comparación con otros países de la región, el rendimiento promedio del café en Perú es relativamente bajo, aproximadamente de 13 quintales por hectárea. Sin embargo, en áreas como Jaén, Bagua, San Ignacio o Villa Rica, el rendimiento es considerablemente mayor, oscilando entre 30 y 80 quintales por hectárea (Morán y Jiménez, 2023). La baja productividad del café está vinculada a la deforestación y, consecuentemente, a la degradación del suelo y propagación de enfermedades (Díaz y Carmen, 2017).

Desde su primera aparición en 1979 en la selva central peruana, la roya ha causado graves pérdidas económicas, como en el caso del 2012 (290,000 hectáreas), cuando afectó el 60% de la cosecha, generando una pérdida estimada de 1,000 millones de soles, lo que lo convierte en uno de los años más perjudiciales para el cultivo de café en el país (Nahuamel, 2019). No obstante, hasta la fecha se ha observado que hay una falta de desarrollo en términos de planificación para hacer frente a la roya (González y Martínez, 2022). Ante el impacto de la roya, el SENASA formuló el Plan Nacional de Renovación de Cafetales, el cual contó con financiamiento de 122 millones de dólares y logró la instalación de 37,200 hectáreas (Gómez, 2019). Esta plaga afecta principalmente a las hojas maduras, pero en casos graves también puede infectar hojas jóvenes, lo que provoca pérdida significativa de hojas y disminuye la producción. La aparición de la roya se relaciona con prácticas de cultivo deficientes, como falta de fertilización, uso inadecuado de fungicidas y presencia de plantaciones viejas, entre otros factores que debilitan las plantas y las hacen susceptibles a los ataques. El cambio climático contribuye a la propagación de la roya al alterar las condiciones climáticas, como el aumento de precipitaciones y humedad atmosférica, crea un ambiente propicio para que se desarrolle con rapidez y gravedad (Omondi et al., 2011).

Según Palacios et al., (2022), a nivel internacional, la roya ha tenido un fuerte impacto en América Latina, lo que ha llevado a los países a desarrollar estrategias para enfrentar su propagación. Colombia ha logrado controlar la roya de manera exitosa, contando con instituciones dedicadas a la investigación de enfermedades de plantas. Brasil también se ha centrado en la investigación como una estrategia para combatir la roya, proponiendo métodos de control como evaluación de la severidad, una medida que también se ha implementado en México. Este método utiliza escalas descriptivas y gráficas (Omondi, 2011).

El Deep Learning es una herramienta que agiliza el diagnóstico de enfermedades en cultivos, como el café, al determinar la severidad del daño y proporcionar datos para la prevención. Su papel es fundamental en el estudio de la roya, ya que permite identificar de manera eficiente características de esta enfermedad y estima con precisión la severidad de los daños (Martínez, 2005). Se utiliza para cumplir

con objetivos de detección de objetos en imágenes mediante el uso de redes neuronales convolucionales. Este enfoque se basa en el aprendizaje supervisado para entrenar modelos capaces de identificar con precisión objetos y formas en imágenes. De esta manera, se puede determinar el impacto causado por una enfermedad. El Deep Learning emplea algoritmos en programas de computadora que aprenden a través de la experiencia, evaluando el rendimiento mediante la mejora en la precisión del diagnóstico a medida que se alimenta el programa con más datos (Román y Ruiz, 2021). Utiliza datos de entrada, como imágenes digitales, para generar salidas que establecen una conexión efectiva entre entradas y salidas. Permite que el modelo aprenda, de modo que cuando se introducen nuevas imágenes digitales, el modelo produce respuestas automáticas debido al proceso de aprendizaje previo (Pereyra, 2020).

Para detectar y medir la severidad de la roya de manera precisa y eficiente, es primordial la gestión agrícola y la implementación de medidas de control. Aquí es donde el Deep Learning juega un papel fundamental (Mahlein, 2016). El uso de imágenes de alta resolución, capturadas por drones, satélites o cámaras montadas en tractores, proporciona una gran cantidad de datos visuales que pueden ser analizados para detectar presencia y severidad de roya. Los modelos de Deep Learning, particularmente las redes neuronales convolucionales (CNN), son altamente efectivos para el análisis de imágenes. Estas redes pueden aprender características específicas de las enfermedades de las plantas, como patrones de color, textura y forma que son indicativos de la roya (LeCun, Bengio, & Hinton, 2015).

El primer paso en el proceso de detección y medición es el preprocesamiento de las imágenes para mejorar la calidad y eliminar el ruido. Esto puede incluir ajustes en la iluminación, contraste y normalización de los tamaños de las imágenes (Zhang et al., 2018). Se requiere un conjunto de datos, donde las imágenes de hojas afectadas por la roya están etiquetadas con la severidad de la enfermedad. Este conjunto de datos se utiliza para entrenar el modelo de Deep Learning (Mohanty, Hughes, & Salathé, 2016). Una vez entrenado, el modelo puede clasificar imágenes nuevas en categorías como "sano", "infectado leve", "infectado moderado" e "infectado severo". Además, las técnicas de segmentación

pueden identificar y delinear las áreas específicas de la hoja que están afectadas, proporcionando una medida cuantitativa de la severidad (Ferentinos, 2018). Los modelos se evalúan utilizando métricas como la precisión, sensibilidad y especificidad. La validación cruzada y el uso de conjuntos de datos independientes ayudan a asegurar que el modelo generaliza bien a nuevos datos (Russakovsky et al., 2015).

Los modelos de Deep Learning pueden superar a los métodos tradicionales (histopatología y microscopía, trampeo y monitoreo de esporas, inspección visual, entre otros) de detección en términos de precisión y rapidez. Esto es especialmente útil en grandes plantaciones donde la inspección manual es impracticable (Kamilaris & Prenafeta-Boldú, 2018). El proceso puede ser automatizado completamente, desde la captura de imágenes hasta la generación de reportes de severidad. Esto reduce la necesidad de intervención humana y permite un monitoreo continuo. Además, pueden ser adaptados y reentrenados para detectar otras enfermedades de las plantas o para ajustarse a nuevas variedades de cultivos y condiciones ambientales (Barbedo, 2018).

Por tanto, el uso de Deep Learning para la detección y medición de la severidad de la roya representa un avance significativo en la agricultura de precisión. Al combinar imágenes de alta resolución con modelos avanzados de Deep Learning, es posible identificar y cuantificar la enfermedad de manera rápida y precisa, lo que permite una gestión más efectiva y sostenible de los cultivos afectados. Sin embargo, es importante abordar los desafíos relacionados con los datos y la variabilidad para asegurar que estas tecnologías puedan ser implementadas de manera efectiva en el campo (Mekonnen et al., 2020).

Numerosos estudios han demostrado el potencial del uso de imágenes empleando Deep Learning para detectar enfermedades en plantas. Párraga et al., (2019) utilizó 1560 imágenes de hojas de café robusta con ácaros y manchas rojas visibles (que denotan la presencia de roya del café) para casos de infección e imágenes sin dichas estructuras para casos sanos. Además, incluyeron anotaciones sobre objetos (hojas), estado (saludable y no saludable) y gravedad de la enfermedad (área foliar con manchas). Todas las imágenes se obtuvieron utilizando la cámara de un teléfono inteligente. Con la información recolectada crearon un aplicativo

denominado RoCoLe, demostrando el rendimiento de los algoritmos de aprendizaje automático para la segmentación y clasificación de imágenes relacionadas con el reconocimiento de enfermedades de las plantas.

Para Valle (2019) en su tesis realizada en La Convención-Cusco referente a la severidad de la roya amarilla (*Hemileia Vastatrix Berk & Br.*), planteando como objetivo principal evaluar el porcentaje de incidencia y severidad de la roya amarilla. La metodología empleada se centró en el enfoque cuantitativo, siendo de tipo descriptiva, empleándose el método de evaluación de SENASA para medir la severidad con que la plaga afecta a al cultivo, analizándose las hojas. Los resultados obtenidos fueron que se presentó un 76.75% de incidencia de roya y respecto al grado de severidad el 42% de las hojas analizadas presentaban un nivel de severidad de roya de grado 3. En conclusión, la incidencia de roya en esta zona del Cusco es elevada, al igual que el grado de severidad.

Alvarado et al. (2020) realizaron un estudio sobre el potencial agroforestal de las especies de guabo *Inga edulis* e *I. vera*, ampliamente empleadas en sistemas agroforestales. El objetivo fue comparar sus indicadores de desarrollo fenológico, el aporte de minerales y la presencia de organismos beneficiosos para la calidad del suelo. Utilizando un diseño de bloques completamente al azar (DBCA) con tres tratamientos y seis repeticiones, se encontró que *I. edulis* exhibe un crecimiento polinómico más prometedor, alcanzando una altura de 5.79 m, un diámetro a la altura del pecho (DAP) de 0.075 m y 31.66 ramas con un diámetro de sombra de 5.94 m, superando a *I. vera* que alcanza 4.74 m de altura, DAP de 0.061 m y 14.33 ramas con sombra de 4.79 m de diámetro. Las especies también difieren en su aporte de macronutrientes al suelo: *I. vera* muestra una mayor contribución de NH<sub>4</sub>, K y Mg, mientras que *I. edulis* aporta más P y Ca. En cuanto al contenido mineral foliar, *I. edulis* supera a *I. vera* en NH<sub>4</sub>, P y Mg foliares, aunque *I. vera* presenta concentraciones más altas de K y Ca foliares. En términos de nutrientes en la hojarasca, *I. edulis* contiene un 3.13% de N, mientras que *I. vera* tiene un 2.53% de N. La fauna asociada también mostró diferencias significativas: *I. edulis* alberga en promedio 22.6 lombrices de tierra (*Lumbricus* terrestres) por árbol, mientras que *I. vera* tiene 14.9. Por otro lado, *I. vera* muestra una mayor población promedio de avispas *Polistes dominula* (4.6 individuos) y

*Vespula vulgaris* (10.3 individuos) en comparación con los 2.7 y 5.2 individuos respectivamente encontrados en *I. edulis*.

En conclusión, el estudio demostró que tanto *I. edulis* como *I. vera* muestran un crecimiento polinómico consistente en altura, diámetro, ramaje y sombreado con un coeficiente de determinación ( $R^2$ ) de 0.9 hasta los dos años de establecimiento. *I. edulis* destacó significativamente sobre *I. vera* en todos los indicadores de desarrollo fenológico analizados. Además, *I. edulis* contribuye de manera más significativa con  $NH_4$  al suelo, con 39.76 kg N/ha/año comparado con los 32.14 kg N/ha/año de *I. vera*. El análisis foliar reveló diferencias marcadas en la composición de macronutrientes entre ambas especies, y la fauna asociada mostró patrones distintivos en la población de lombrices de tierra y avispas entre *I. edulis* e *I. vera*.

En una investigación de desarrollada por Biniyam y Mossab (2023), respecto a la clasificación de las enfermedades de café haciendo uso de redes neuronales convolucionales, plantearon como objetivo proponer un modelo de detección de estas enfermedades empleando las arquitecturas GoogleNet y RESNET. Esta investigación se realizó partiendo de la definición del café como un cultivo agrícola de gran importancia a nivel global, y la mejora de su producción y el mantenimiento de su calidad son cruciales. Así también abordaron la problemática de este cultivo, evidenciándose que los cafetos son vulnerables a diversas enfermedades que pueden afectar negativamente la producción y la calidad del producto final, y que la detección temprana y la identificación precisa de estas enfermedades son fundamentales para enfrentar estos desafíos. En este estudio, se propuso un enfoque basado en aprendizaje profundo para la identificación y clasificación de enfermedades del café, utilizando redes neuronales convolucionales (CNN). La investigación se estructuró en tres etapas principales: el preprocesamiento de imágenes, la extracción de características y la clasificación. Se emplearon técnicas como el filtrado gaussiano y el aumento de datos para mejorar la robustez del modelo y reducir el ruido. Se utilizó una CNN que combina arquitecturas como GoogLeNet y RESNET para extraer características de alto nivel, capturando de manera efectiva formas, objetos y patrones complejos de las imágenes de entrada, aspectos cruciales para tareas

como el reconocimiento y la clasificación de objetos. Posteriormente, las características extraídas se clasificaron utilizando perceptrones multicapa (MLP), aprendizaje automático y clasificadores de conjuntos. El modelo propuesto alcanzó una precisión de prueba del 99.08%, superando a otros métodos de clasificación evaluados. Estos resultados subrayan la efectividad del adecuado preprocesamiento de imágenes, el uso de CNN y el aumento de datos como un método eficiente para la identificación y clasificación de enfermedades del café.

Bordin y Leite (2023), examinaron la detección temprana de enfermedades del café en Brasil. El objetivo fue integrar redes convolucionales en un tablero microcontrolado de bajo costo para clasificar las hojas del café sin necesidad de conexión a internet. Se utilizaron dos conjuntos de datos y se capturaron imágenes con el tablero de desarrollo, obteniendo alrededor de 6000 imágenes de 6 tipos diferentes de enfermedades del café. La precisión de las estructuras utilizadas en el Deep Learning alcanzó valores del 96 y 98%, lo que lleva a concluir que el Deep Learning, basado en la arquitectura del programa es eficaz y capaz de detectar tempranamente enfermedades del café.

- Gavito (2019), desarrollo en Querétaro, un sistema inteligente para la detección temprana de la roya del café. La metodología consistió en la obtención de imágenes hiperespectrales las que permitirán hacer el análisis de las hojas. El procesamiento de datos se realizó a través de algoritmos de Machine Learning, separando las hojas diferentes y clasificándolas de acuerdo al grado del daño. La investigación demostró que, si se detecta la roya en etapas tempranas, esto permitiría a los expertos controlar la enfermedad.
- Ávila (2022), desarrolló una aplicación para Android usando redes neuronales con la finalidad de identificar plagas en las hojas del café. Para poder alcanzar el entrenamiento de la red neuronal consideró bases de datos con imágenes de plaga de roya. Empleó lenguaje de programación e identificación de patrones Python, los resultados obtenidos demuestran la utilidad para pequeños agricultores ya que les facilitaba la detección temprana de enfermedades de cultivos.

La investigación se justifica debido a que está relacionada con la protección del medio ambiente, la conservación de la calidad del suelo mediante las

implementaciones de sistemas agroforestales, y potenciar los servicios ecosistémicos del bosque como la regulación, vinculada con el control de plagas o enfermedades de los cultivos como la roya que impacta directamente en la productividad del café, afectando así el rendimiento económico del cultivo en la Región Cajamarca. Este estudio es factible porque aborda el problema de la roya del café en áreas productoras de las provincias de Jaén y San Ignacio. Su propósito es mejorar la productividad y, por consiguiente, promover el desarrollo económico de la población.

La investigación planteó como objetivo general: Estimar la severidad de la roya del café en los sistemas agroforestales empleando Deep Learning en las provincias de Jaén y San Ignacio, departamento de Cajamarca, 2023, y como objetivos específicos: a) Caracterizar los sistemas agroforestales presentes en las parcelas de café; b) Generar una base de datos con la clasificación de la severidad de roya según SENASA y el método alternativo de evaluación visual de la severidad para medir con exactitud la superficie dañada de la hoja; y c) Aplicar redes neuronales convolucionales para estimar la severidad de Roya de café en provincias de Jaén y San Ignacio.

## II. MATERIAL Y METODOS

El área de estudio estuvo conformada por diez lotes de cuatro parcelas situadas en el distrito San José del Alto, perteneciente a la provincia de Jaén; y el distrito de Chirinos perteneciente a la provincia de San Ignacio, departamento de Cajamarca, 2023, ver tabla 1.

*Tabla 1*  
*Población de la investigación*

Provincia	Distrito	Asociación o cooperativa	Total, de parcelas	Total, de lotes
Jaén	San José del Alto	Finca “La Palestina”	02	05
San Ignacio	Chirinos	Cooperativa Agraria Cafetalera “La Prosperidad”	02	05
<b>Total</b>			<b>04</b>	<b>10</b>

La materia vegetal estudiada estuvo conformada por las hojas de 50 plantas de café pertenecientes a los 10 lotes del estudio situados en las provincias de Jaén y

San Ignacio, departamento de Cajamarca 2023. Para realizar el análisis correspondiente, por lote se tomaron 05 plantas situadas en los extremos y centro del lote.

Se utilizó el muestreo por conveniencia, para lo cual se seleccionaron 12 hojas de la parte inferior, media y superior de la planta de café, iniciando desde el punto medio de cada lote (Otzen y Manterola, 2017)

Las variables de estudio fueron Deep Learning y la severidad de la roya de café (ver tabla 2). La variable independiente fue el Deep Learning, la cual consiste en una red neuronal que facilita el proceso de aprendizaje a través de grandes cantidades de datos, que consiste en imágenes que permiten realizar predicciones. Los ordenadores reciben la información y procesan datos mediante ecuaciones predefinidas (Velo, 2020). Sobre la variable dependiente, Severidad de roya del café en sistemas agroforestales; la roya es una enfermedad que afecta principalmente a las hojas de la planta del café, y su severidad es marcada afectando la productividad del cultivo (Hernández et al., 2021).

Tabla 2  
Operacionalización de variables

Variable		Dimensiones	Definición conceptual	Indicadores	Unidad	Técnica de Recolección de datos	Instrumento de Recolección de datos
Tipo	Nombre						
<b>Independiente</b>	Modelos matemáticos	Comportamiento	El Deep Learning, es una técnica de aprendizaje basada en un conjunto de algoritmos relacionados con el aprendizaje automático, se está volviendo cada vez más específico en aplicaciones del mundo real (predicción de resultados comerciales, desarrollo de asistentes virtuales, análisis de imágenes médicas, etc.) Está atrayendo la atención de las empresas porque puede aprovechar al máximo la inteligencia artificial (Padial, 2019).	Exactitud	Porcentaje	Observación	Cámara digital
				Precisión	Porcentaje	Observación	Imágenes
<b>Dependiente:</b>	Severidad de roya del café en sistemas agroforestales	Nivel de afectación	La severidad es una medida de la intensidad de una enfermedad basada en la evaluación del grado de ataque del tejido vegetal. Se puede medir el área de tejido vegetal afectada, o su porcentaje (Julca et al., 2019).	Grado de afectación	Grado (0) Grado (1) Grado (2) Grado (3) Grado (4)	Observación	Imágenes
				Porcentaje de incidencia de roya	Porcentaje	Observación	Imágenes

**Nota.** La unidad de medida del indicador grado de aceptación de la variable de la roya a sido obtenido de la normativa de SENASA.

El método de investigación se enmarcó en el enfoque cuantitativo, dado que se empleó la recolección de datos y se contabilizó el número de hojas por cada rama estudiada y también el número de hojas afectadas por roya. Su análisis para dar respuesta a la pregunta de investigación y comprobar la hipótesis, haciendo uso de la medición numérica y la estadística para determinar con precisión los patrones de conducta de severidad.

El tipo de investigación fue descriptiva ya que se detalló los procedimientos empleados para la obtención de muestras. Permitió detalles puntuales que permitieron determinar los niveles de afectación de las hojas, también se define cómo aquella investigación que busca recopilar información cuantificable mediante métodos estadísticos. La técnica empleada en la investigación fue la observación, la misma que es definida como un conjunto de técnicas o herramientas que buscan evaluar un fenómeno de investigación, la observación implica en sí una manera de percibir la realidad tal cual se manifiesta con la finalidad de conocerla, estudiando la conducta o comportamientos observables del fenómeno estudiado. Así mismo, de forma específica se empleó la observación directa, dado que el investigador estuvo en contacto sin intermediarios con el fenómeno estudiado (Matos, 2008).

Se detalla los procedimientos seguidos para la obtención de los resultados:

***A. Caracterizar los sistemas agroforestales presentes en las parcelas de café.***

El primer paso a seguir estuvo enfocado en verificar por medio de la observación los sistemas agroforestales que se encontraban en las parcelas de café tomadas como muestra para la investigación. Además, se estimó el porcentaje de sombra, utilizando el aplicativo HabitApp y se determinó la especie o especies forestales presentes. Finalmente, se realizó la consulta al propietario referente a la edad de las especies forestales.

**B. Base de datos con la clasificación de la severidad de roya según SENASA y método alternativo de la evaluación visual de la severidad.**

**B.1. Imágenes de severidad de roya del café en sistemas agroforestales en las provincias de Jaén y San Ignacio.**

Se seleccionó cincuenta (50) plantas de 4 parcelas, de acuerdo a los datos establecidos por el proyecto PE501079151-2022 (RPAS- Roya), los puntos de muestreo estuvieron establecidos en la provincia de Jaén (San José del Alto), San Ignacio (Chirinos), de cada lote se seleccionó 5 plantas y de cada planta son 4 hojas por cada nivel de planta (alto, medio y bajo), en total fueron 12 hojas por planta. Además, se verificó el número de hojas totales y número de hojas con roya en cada una de los niveles (Shi, 2023).

Las hojas afectadas, fueron fotografiadas de manera individual haciendo uso de una cámara digital Nikon Coolpix P1000. Con la finalidad de determinar el área de la hoja y el área afectada por la mancha de hierro del cafeto y así estimar el grado de severidad. Cada imagen fue codificada para su posterior identificación y proceso (Guzmán, et al., 2003).

**B.2. Severidad de Roya según SENASA.**

La clasificación de la severidad de la roya (ver tabla 3), se realizó mediante la escala de SENASA, y la obtención de las imágenes, para ello se empleó el aplicativo Leaf Doctor utilizado para realizar evaluaciones cuantitativas para enfermedades de las plantas en las hojas, con estos métodos se pudo estimar el área del tejido enfermo mediante escalas del desarrollo de enfermedades o diagramas de severidad. los niveles de severidad fueron determinados mediante la ecuación (1) índice de afectación y la ecuación (2) porcentaje de severidad.

$$\text{Índice de infección} = N^{\circ} \text{ manchas} \times \frac{N^{\circ} \text{ hojas enfermas}}{N^{\circ} \text{ total de hojas}} \quad (1)$$

$$\begin{aligned}
 \text{Porcentaje de severidad} & & (2) \\
 &= \frac{\text{Área necrótica}}{\text{Área sana}} \\
 &= \frac{\text{Área necrótica}}{\text{Área total de la hoja} - \text{Área necrótica}}
 \end{aligned}$$

*Tabla 3*  
*Niveles de severidad de la roya-SENASA*

<b>Grado o calificación</b>	<b>Descripción</b>
0	Sano o sin síntomas visibles
1	Síntomas visibles llegando de 1 a 5% del área total sana
2	Las manchas empiezan a unirse llegando a ocupar del 6 al 20% del área sana
3	Las hojas comienzan a necrosarse de manera muy notoria afectando el 21 al 50% del área sana
4	Mayor al 50 del área foliar se encuentra afectada

### ***B.3. Método alternativo de la evaluación visual de la severidad-SENASICA-México.***

Este método se empleó para medir el porcentaje del tejido vegetal afectado por la roya basándose en la escala de Cobb, la cual fue modificada por Peterson et al., (1948), y tuvo por finalidad relacionar el porcentaje real de ocupación de la roya con el grado de severidad. Así mismo Navarro y Arauz (1999), indican que este método de evaluación visual de la severidad se utiliza dado que se caracteriza por su sencillez, rapidez y bajo costo, sin embargo, cuando se trata de analizar grandes cantidades de muestras puede ser impreciso.

Para el procesamiento de la información, se requiere previamente la obtención de imágenes digitales (fotografías), de las hojas y otras partes de la planta que se encuentran afectadas, para poder realizar comparaciones. Un beneficio extra de este método es que no emplea técnicas destructivas para la planta. El análisis que se realiza permite conocer el número, tamaño, color y forma de las lesiones en la hoja.

*Tabla 4*  
*Niveles de severidad de la roya-SENASICA*

<b>Grado o calificación</b>	<b>Descripción</b>
0	Sano o sin síntomas visibles
1	Síntomas visibles primeros puntos cloróticos
2	Las manchas empiezan a unirse llegando a ocupar el 2% del área sana
3	Las manchas empiezan a unirse llegando a ocupar el 7% del área sana
4	Las hojas comienzan a necrosarse de manera muy notoria afectando el 20% del área sana
5	La hoja alcanza un 45% de afectación de roya
6	Mayor al 70% del área foliar se encuentra afectada

Para el cálculo de lesiones por centímetro cuadrado se emplea la ecuación (3):

$$LPC = \frac{NTL \times 100}{AS} \quad (3)$$

**Donde:**

LPC: Número de lesiones por centímetro cuadrado

NTL: Número total de lesiones

AS: Área foliar

Para la severidad se calcula con la ecuación (4):

$$MED (\%) = \frac{AD}{AS} \times 100 \quad (4)$$

**Donde:**

MED: Área foliar dañada por la enfermedad

AD: Área dañada

AS: Área foliar

***C. Aplicar redes neuronales convolucionales para estimar la severidad de Roya de café en las provincias de Jaén y San Ignacio.***

El primer paso consistió en recopilar y procesar los conjuntos de datos, y se describió en cuatro aspectos:

(1) Características de los conjuntos de datos: Se utilizó conjuntos de datos de elaboración propia, las imágenes fueron tomadas en condiciones naturales.

(2) Anotación del conjunto de datos: Una de las condiciones necesarias para evaluar la identificación de la severidad de la roya, se etiquetaron según la escala ordinal cualitativa.

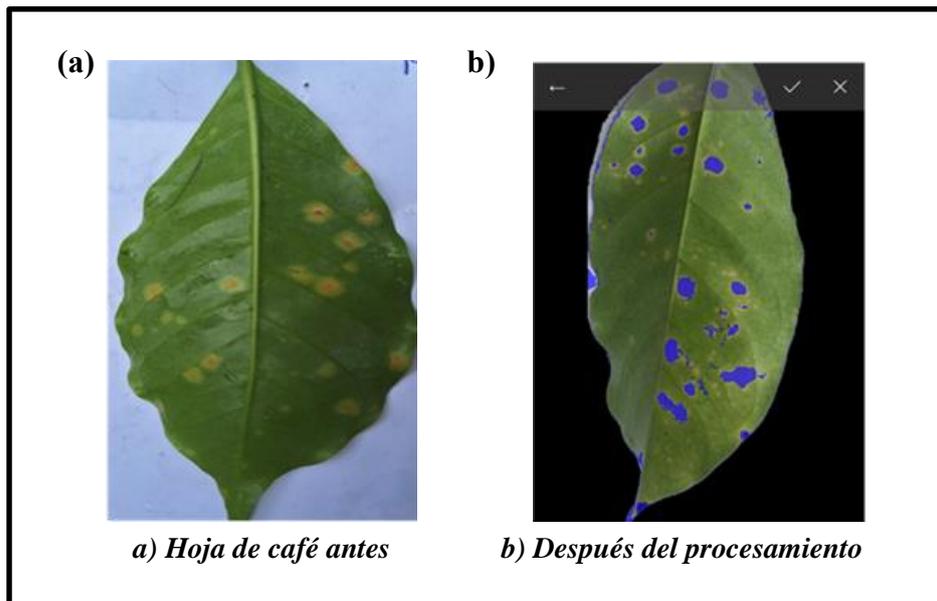
(3) División del conjunto de datos: El conjunto de datos se dividió en tres partes: conjunto de datos de entrenamiento (70%), validación (20%) y prueba (10%).

(4) Preprocesamiento de datos. Se realizó dos operaciones de preprocesamiento antes de introducir las imágenes en la CNN. En segundo lugar, las imágenes se normalizaron para que el modelo converja rápidamente, lo que mejoró significativamente la eficacia del entrenamiento.

### **3.1 Hojas con Roya**

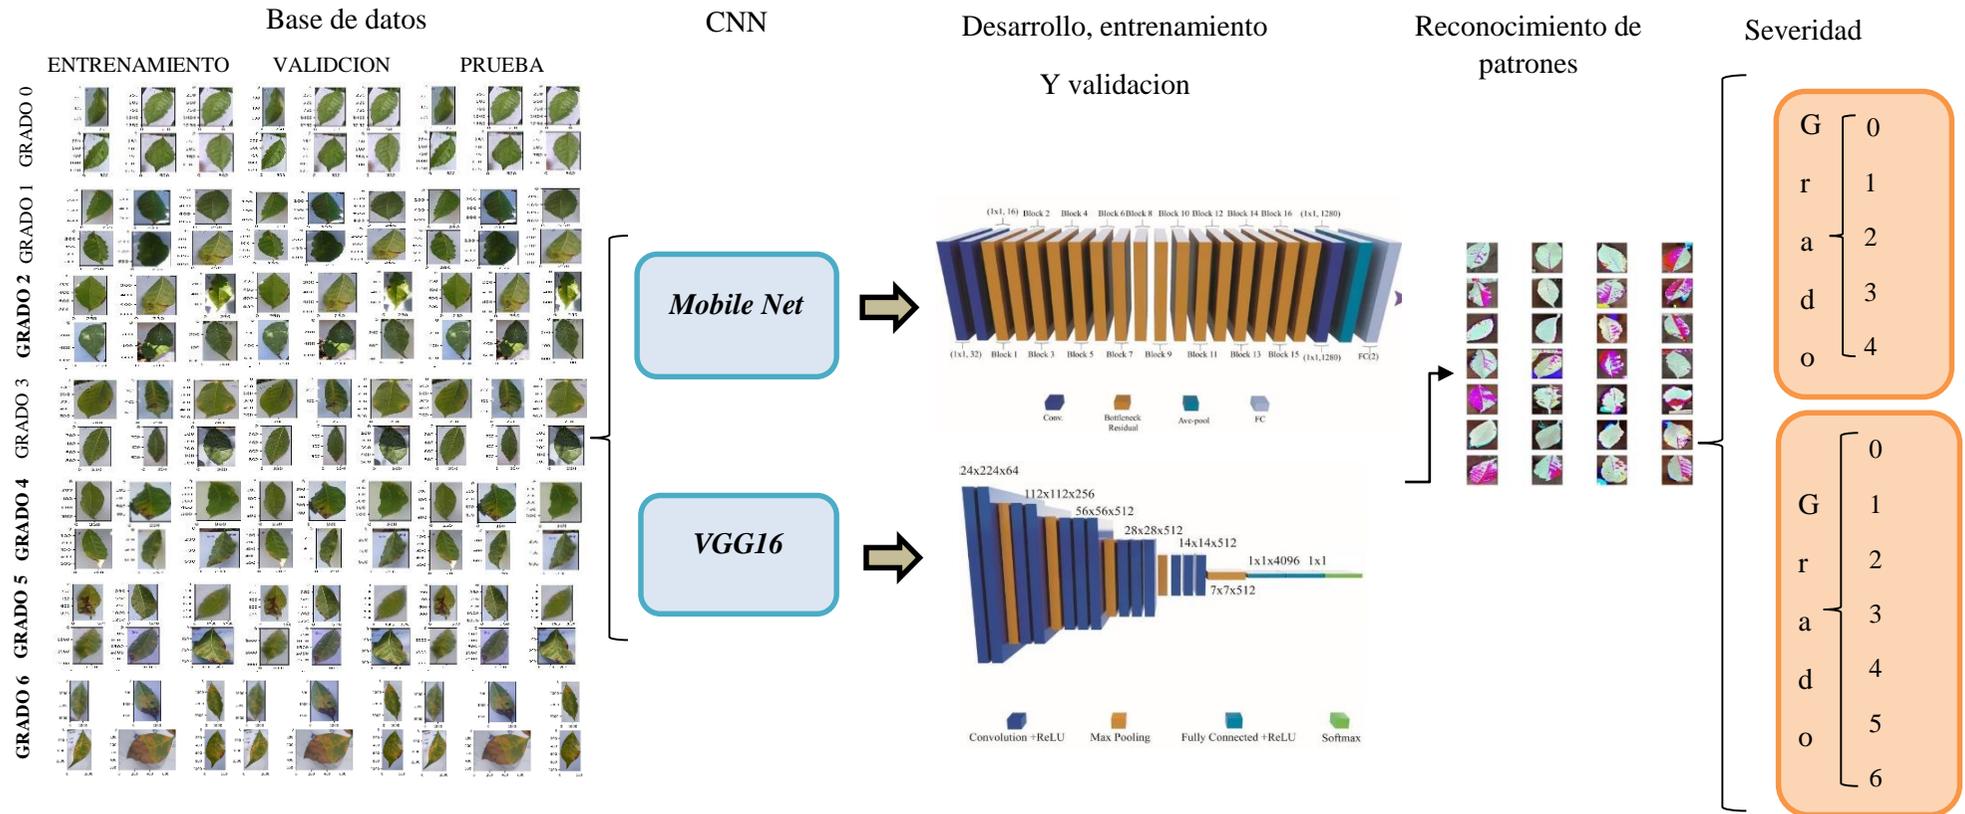
Fueron recolectadas en la parcela experimental de la “finca la prosperidad de Chirinos”. La figura 1 (a) muestra la hoja infectada antes de su procesamiento, la figura 1 (b) muestra la hoja después de su procesamiento, se aplicó redes neuronales convolucionales a través del Google Colaboratory, obteniendo así el grado de severidad de la hoja, se puede apreciar los patrones de severidad que nos brinda información valiosa sobre el grado de clasificación según SENASA, los grados son 5: grado 0,1,2,3 y 4 y el grado de clasificación según SENASICA México los grados son 7: grado 0,1,2,3,4,5 y 6. Esta prueba es una innovación que se utiliza en la industria agrícola que proporciona información sobre el grado de severidad de la hoja de café (ver figura 2).

*Figura 1*  
*Hoja de café antes y después del procesamiento*



Adaptado de Palomino et al (2023).

Figura 2  
Diagrama de Flujo de Severidad de Roya Mediante CNN



Adaptado de Palomino et al (2023).

El segundo paso fue la fase de selección y entrenamiento del modelo, que se describe en dos aspectos:

(1) Selección del marco CNN. Los marcos CNN utilizados incluyeron AlexNet y ResNet.

(2) Métodos de entrenamiento. Consistió en inicializar el modelo con los pesos de un modelo pre entrenado y, a continuación, entrenar algunos o todos los pesos en el conjunto de datos de destino.

El tercer paso consiste en evaluar el rendimiento de los modelos CNN.

Se obtuvo utilizando el conjunto de pruebas en el modelo entrenado. Se evaluó e interpretó el grado de severidad de roya, empleando los estadísticos de exactitud, precisión y recuerdo basados en la matriz de confusión, Tabla 4.

*Tabla 5*  
*Matriz de confusión de la clasificación*

		Detectado	
		Positivo	Negativo
Actual	Positivo	Positivo Verdadero (PV)	Negativo Falso (NF)
	Negativo	Positivo Falso (PF)	Negativo Verdadero (NV)

Nota. Elaboración propia

La exactitud es la proporción del número total de predicciones donde correctamente ha calculado, ver ecuación (5). La precisión es el radio de los casos correctamente clasificados a el número total de casos mal clasificados y casos correctamente clasificados, ver ecuación (6). El recuerdo es el radio de los casos clasificados correctamente del número total de casos no clasificados y casos clasificados correctamente, ver ecuación (7).

$$Exactitud = \frac{PV + NV}{PV + NF + NV + PF} \quad (5)$$

$$\textit{Precisi3n} = \frac{PV}{PV + PF} \quad (6)$$

$$\textit{Recuerdo} = \frac{PV}{PV + NF} \quad (7)$$

Entre los instrumentos utilizados, se aplic3 un formato de campo adaptada de la metodolog3a establecido por seg3n la resoluci3n Jefatural N3 035-2000-AG-SENASA, los instrumentos de recolecci3n de datos que se emplearon en la investigaci3n responden a la t3cnica de la observaci3n y dada la naturaleza del fen3meno en estudio, se requiri3 que estos instrumentos sean estructurados, por lo cual en el proceso de su elaboraci3n el investigador se formul3 las preguntas: qu3 se va a observar, es necesario que se tenga claro o se conozca la naturaleza del fen3meno para poder identificar aquellas cualidades o caracter3sticas del fen3meno haciendo m3s eficiente el proceso de recolecci3n de datos, as3 mismo se debe preguntar donde y cuando se va a observar dado que los fen3menos principalmente relacionados a la naturaleza y medio ambiente son c3clicos y tienen ciertas temporadas. La investigaci3n dise3n3 una ficha de observaci3n estructurada (D3az, 2011).

El an3lisis de los datos de los estados de grados de severidad de roya de caf3 fue analizado empleando la estad3stica descriptiva a trav3s de tablas y figuras. Adem3s, se emple3 el Deep Learning. En cuanto al software de procesamiento se utiliz3 Python (Powers, 2020).

### III. RESULTADOS

#### 3.1. Caracterización de los sistemas agroforestales presentes en las parcelas de café

##### 3.1.1 Asociación de sistemas agroforestales

En la tabla 6 muestra la caracterización en plantaciones de café; presenta una gran diversidad de componentes; el número de lotes, ubicación, variación de café en cada lote, la edad, el número de plantaciones forestales, predominando el lote 3 de la finca La Palestina y el que menos destaca son los lotes 1 y 2; las especies frutales de lotes que más predominan es el lote 5 por la prosperidad asimismo el 1 y 5 por la finca la palestina, el que menos destaca es el lote 1 de la Prosperidad.

Nombres de las parcelas	N <sup>a</sup> lotes	m.s.n.m	Variedad de café	Distanciamiento de plantas de café (metros)	Edad (años)	N <sup>a</sup> especies forestales	N <sup>a</sup> especies frutales
	1	1720	Pache	0.8 * 2.5	8	10	6
	2	1752	Caturra	0.8 * 2.5	8	7	9
<b>La Prosperidad</b>	3	1777	Bourbon	0.8 * 2.5	8	8	9
	4	1599	Gheysha	0.8 * 2.5	12	6	7
	5	1613	Catimor	0.8 * 2.5	12	8	12
	1	1776	Gueysha	1 * 2	4	3	12
	2	1735	Catimor	1 * 2	3	3	9
<b>La Palestina</b>	3	1787	Caturra	1 * 2	12	12	9
	4	1780	Pache	1 * 2	11	5	7
	5	1724	Bourbon	1 * 2	15	7	12

Tabla 6

Especies forestales por parcela

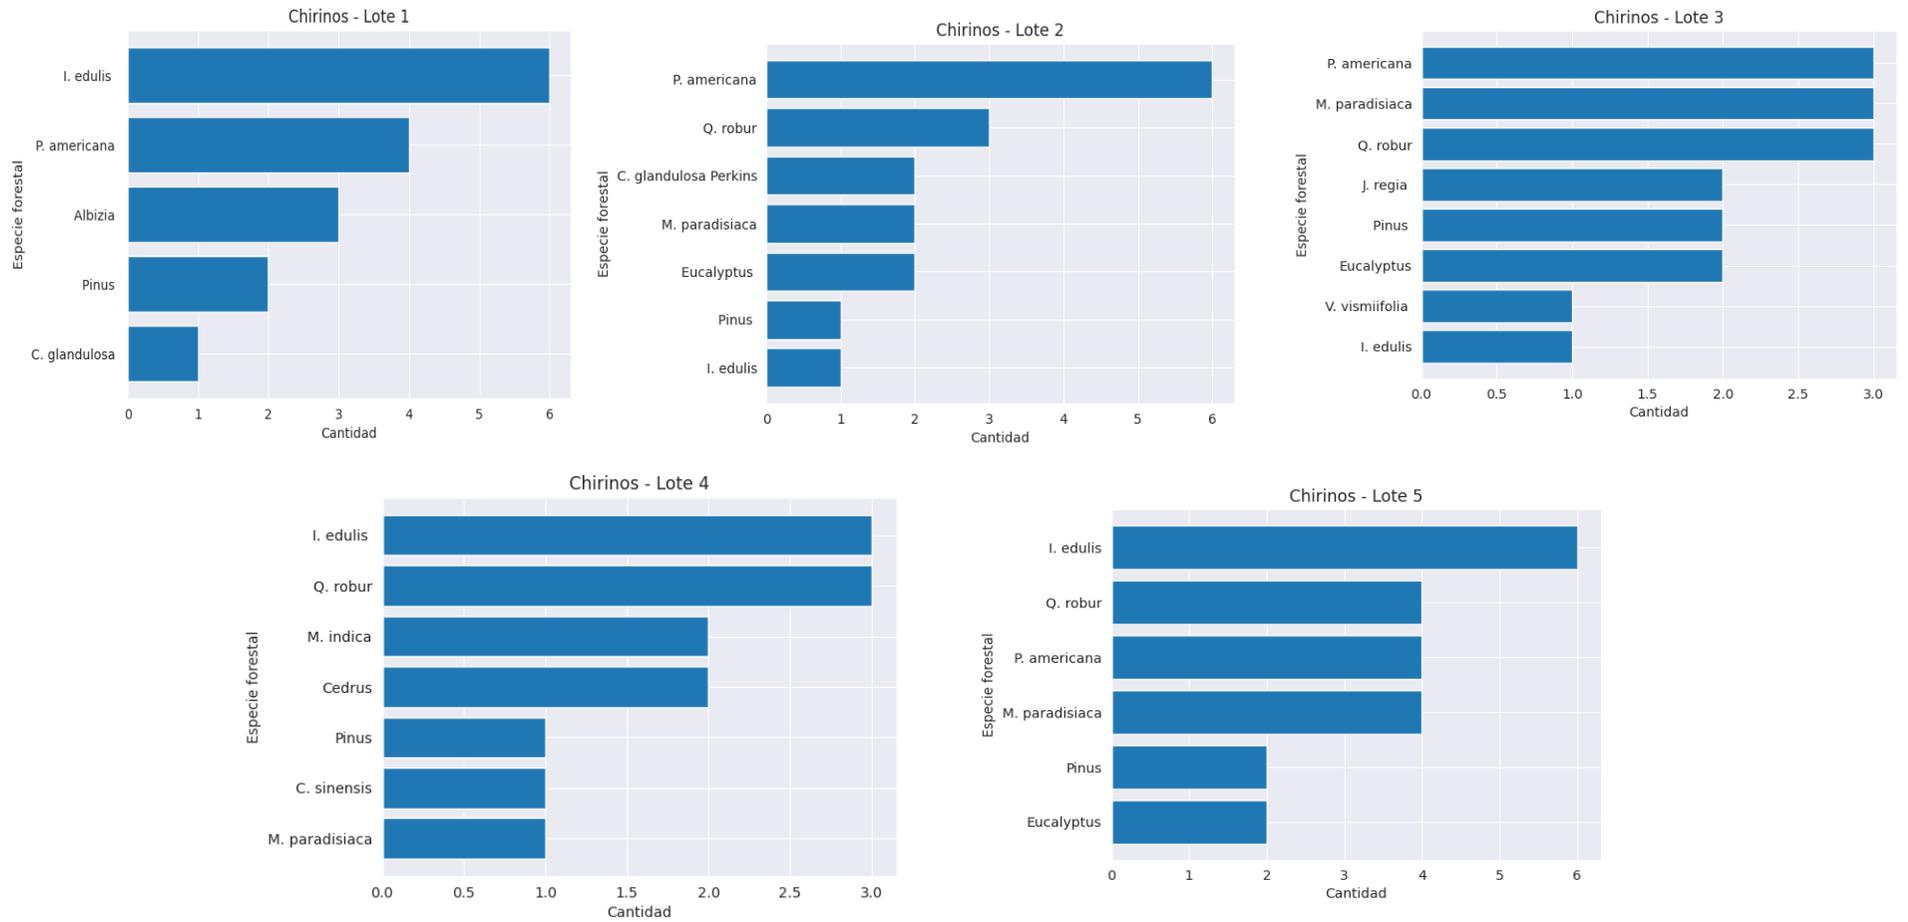
##### 3.1.2 Inventario de especies en el sistema agroforestal

###### a. Parcela de muestreo del distrito de Chirinos

En la figura 3, en el lote 1, *Inga edulis* y *Persea americana* son las especies más abundantes, también se encontraron especies con menos presencia como *Albizia*, *Pinus* y *Colubrina glandulosa*. Asimismo, en el lote 2 de igual manera fue *Persea americana* la especie más fértil, además se localizó especies con menores cantidades como *Quercus robur*, *Colubrina glandulosa Perkins*, *Musa paradisiaca*, *Eucaliptus*, *Pinus* y *Inga edulis*. En el lote 3 se halló especies en cantidades similares: *Persea americana*, *Musa paradisiaca*, *Quercus robur*, *Juglans regia*, *Pinus*, *Eucaliptus*, *Vochysia vismiifolia* y *Inga edulis*. En el cuarto lote al igual que en el lote tres se considera que las cantidades de especies fueron

similares y en lote 5 al igual que en el lote uno *Inga edulis* fue la especie con mayor cantidad, asimismo se encontraron otras especies con menos cantidad como *Quercus robur*, *Persea americana*, *Musa paradisiaca*, *Calycophyllum candidissimum*, *Pinus* y *Eucaliptus*.

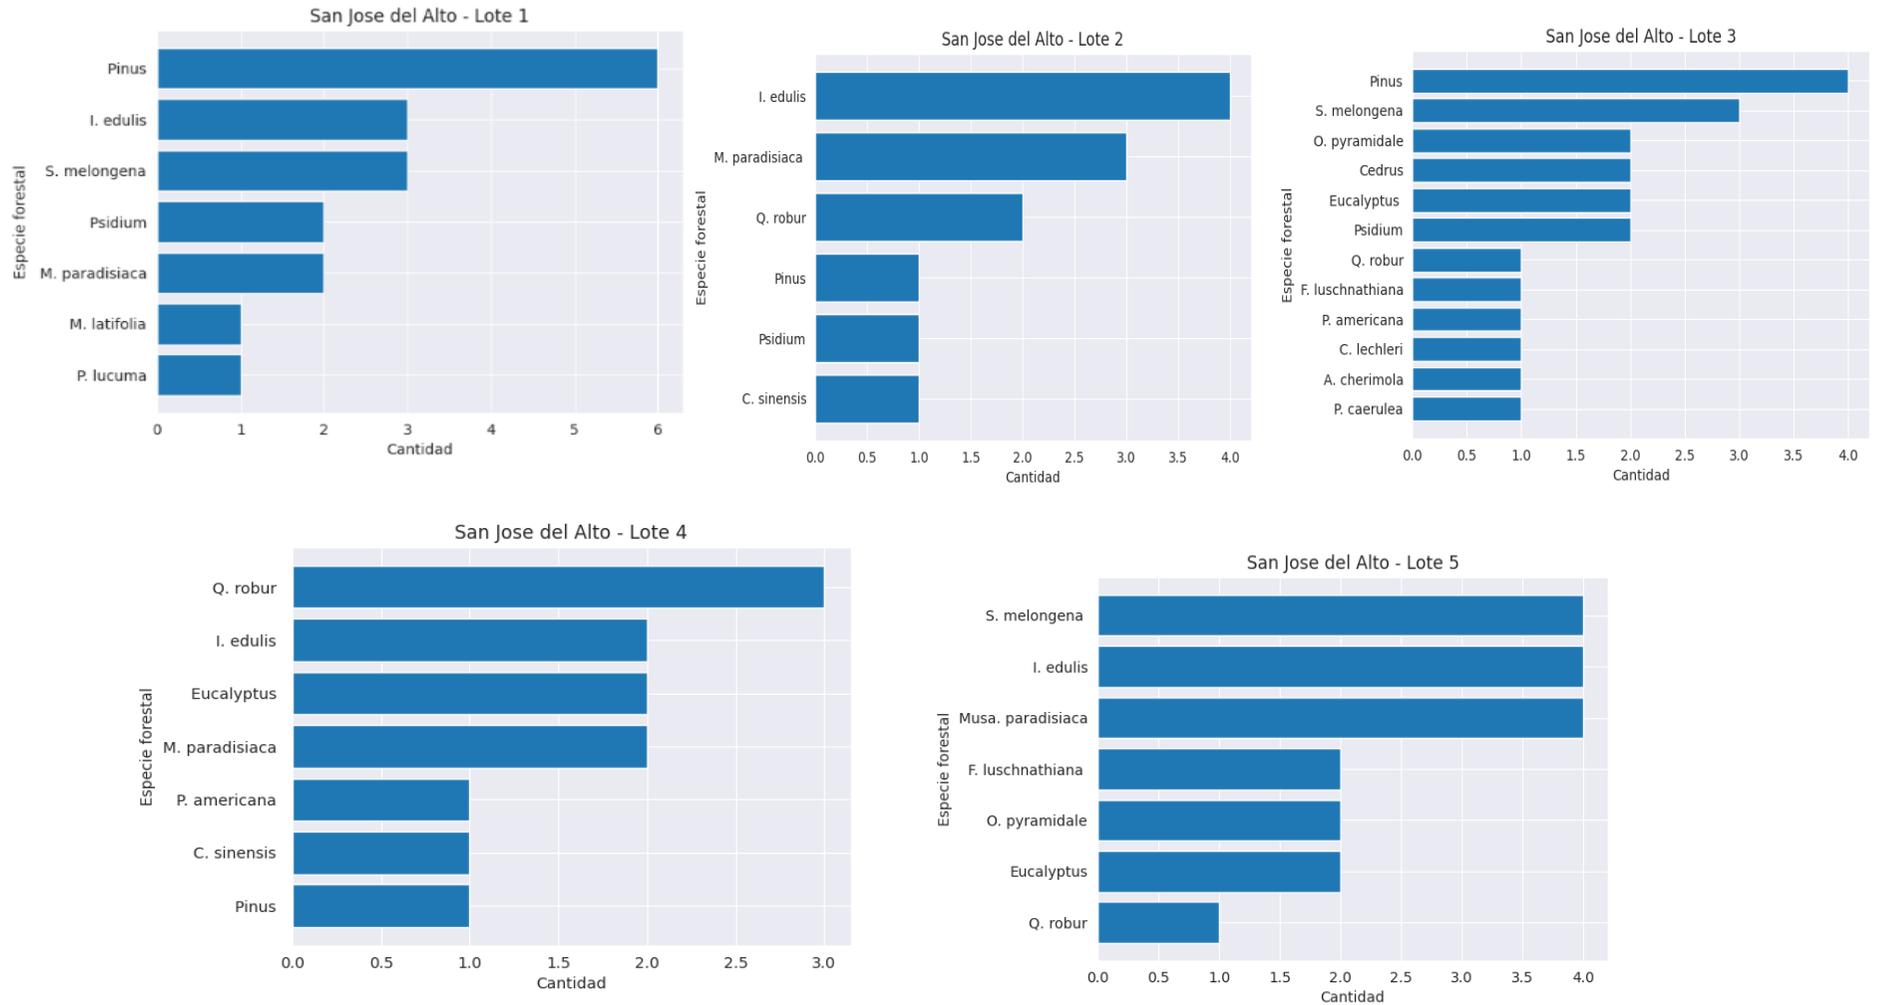
**Figura 3**  
**Inventario de especies de la Prosperidad Chirinos – San Ignacio**



b. Parcela de muestreo del Distrito de San José del Alto

Como se aprecia en la figura 4, en el lote 1 se encontraron especies con cantidades parecidas como *Pinus*, *Inga edulis*, *Solanum melongena*, *psidium*, *Musa paradisiaca*, *Parsea americana* y *Pouteria lúcuma*. En el lote dos *persea americana* es la especie abundante, también se encontraron especies con cantidades menores como *Quercus robur*, *Colubrina glandulosa Perkins*, *Eucalyptus*, *Pinus*, *Inga edulis*. En el lote tres, cuatro y cinco al igual que en lote uno presenta diversidad+ de especies comunes del lugar, pero las cantidades son idénticas.

**Figura 4**  
**Inventario de especies de los lotes de La finca Palestina San José del Alto – Jaén**

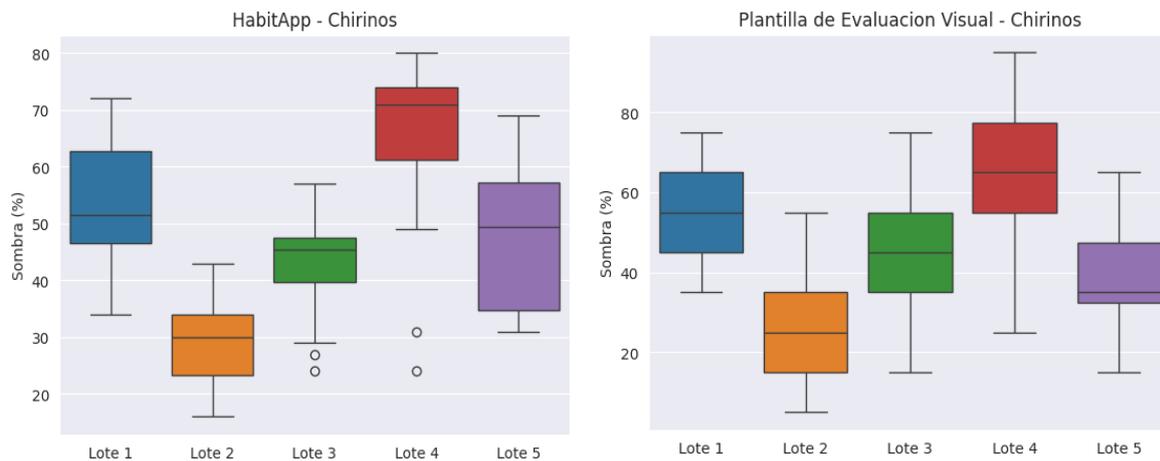


### 3.1.2 Estimación de sombra

#### a. En sistemas agroforestales del distrito Chirinos

La figura 5 describe el porcentaje de sombra de los lotes 1-5, la media (HabitApp) en el lote uno es de 53.9, lote dos 29.5, lote tres 43, lote cuatro 64.9, lote cinco 47.15; la media (plantilla visual) presento en el lote uno 55.5, lote dos 25.5, lote tres 45.5, lote cuatro 67.5 y lote cinco 38. La desviación estándar (HabitApp) en el lote 1es de 11.33, en el lote dos 7.86, lote tres 8.94, lote cuatro 15.48 y lote cinco 11.78; desviación estándar (plantilla visual) lote uno 13.56, lote dos 14.31, lote tres 16.69, lote cuatro 17.43, lote cinco 14.54. En los valores mínimos y máximos el que más resalta (HabitAp) es el lote uno y el que menos destaca es el lote dos a diferencia que que en la plantilla visual el lote que más tiene relevancia es el cuatro y al igual que usando el aplicativo también el lote que menos destaca es el dos. En el lote 3 y 4 (HabitApp) hay dos outliers, en cada lote mencionado cabe resaltar son valores extremos que se desvían de la tendencia general de un conjunto de datos.

Figura 5  
Porcentaje de sombra por lote en el distrito de Chirinos -San Ignacio

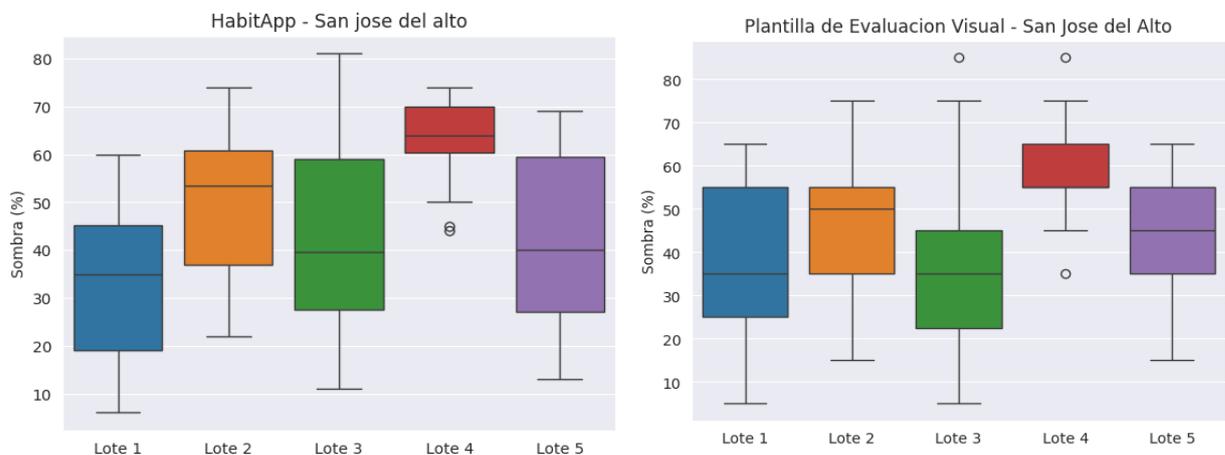


**Nota.** La medición se ha llevado a cabo en base al manual denominado: Instrumentos para estimar el porcentaje de sombra del cafetal, haciendo uso de la aplicación HabitApp y plantilla visual de sombra.

**b. En sistemas agroforestales en San José del alto**

La figura 6, describe el porcentaje de sombra de los lotes 1-5 se define que la media representa el promedio del porcentaje de sombra; lote uno 32.6, lote dos 50.35, lote tres 42.25, lote cuatro 62.6, y lote cinco 41.7 en cambio (plantilla visual) los promedios fueron lote uno 37.5, lote dos 47, lote tres 36.5, lote cuatro 59.5 y lote cinco 45.5; se obtuvieron datos de la desviación estándar en el lote uno 16.12, lote dos 14.86, lote tres, 20.10, lote cuatro 8.65, lote cinco 18.84 y en plantilla visual se obtuvieron otros resultados lote uno 17.73, lote dos 15.07, lote tres 21.34, lote cuatro 12.34 y lote cinco 13.56. En los valores mínimos y máximos en el aplicativo el que más resalto fue el lote 3 de igual manera que en la plantilla visual también resalto el lote 3. En el lote 4 (HabitApp) hay dos outliers, de la misma manera en el lote 4 de plantilla visual también hay dos outliers en el lote 4 y en el lote 3 hay uno, cabe resaltar son valores extremos que se desvían de la tendencia general de un conjunto de datos.

**Figura 6**  
**Porcentaje de sombra por lote en el distrito de San José del Alto – Jaén**



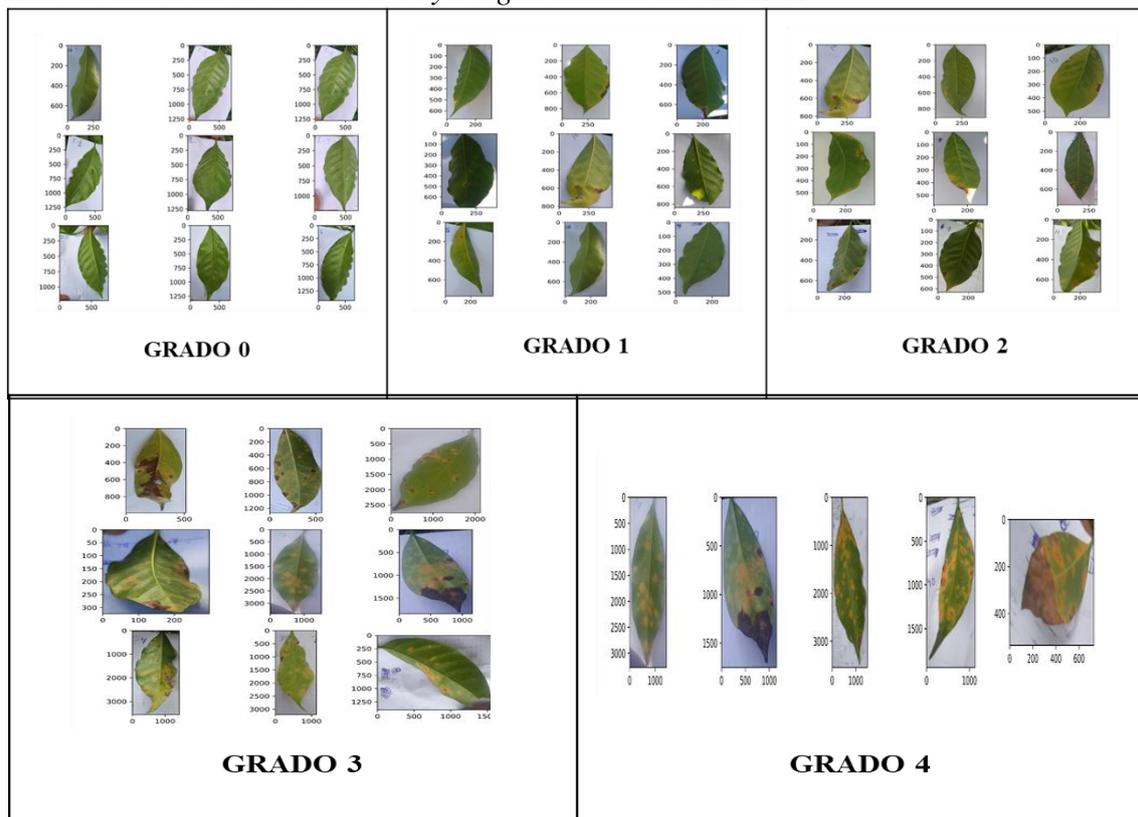
**Nota.** La medición se ha llevado a cabo en base al manual denominado: Instrumentos para estimar el porcentaje de sombra del cafetal, haciendo uso de la aplicación HabitApp y plantilla visual de sombra.

## 2.2. base de datos de severidad de roya

### 2.2.1 Base de datos según Senasa

Fue obtenida recopilando muestras de campo de 4 parcelas experimentales ubicadas en Jaén y San Ignacio respectivamente, entre los años 2023-2024, en la figura 7 se muestra las imágenes clasificadas según su grado de severidad que clasifica Senasa, grado 0, 1, 2, 3 y 4. Con un total de 319 imágenes, se recortaron imágenes de 224 x 224 píxeles y condiciones de iluminación ya que esto reduce la carga computacional en el modelo, acelera la convergencia y clasificación de las hojas y permite predicciones superiores al 90%. Además, se aplicaron técnicas de aumento de datos para mejorar la calidad y cantidad de datos de entrenamiento para construir un modelo eficiente. Las técnicas utilizadas incluyeron: voltear, recortar, rotar y transformar el espacio de color, entre otras.

*Figura 7*  
*Base de datos de severidad de roya según método de SENASA*



Adaptado de Palomino et al (2023).

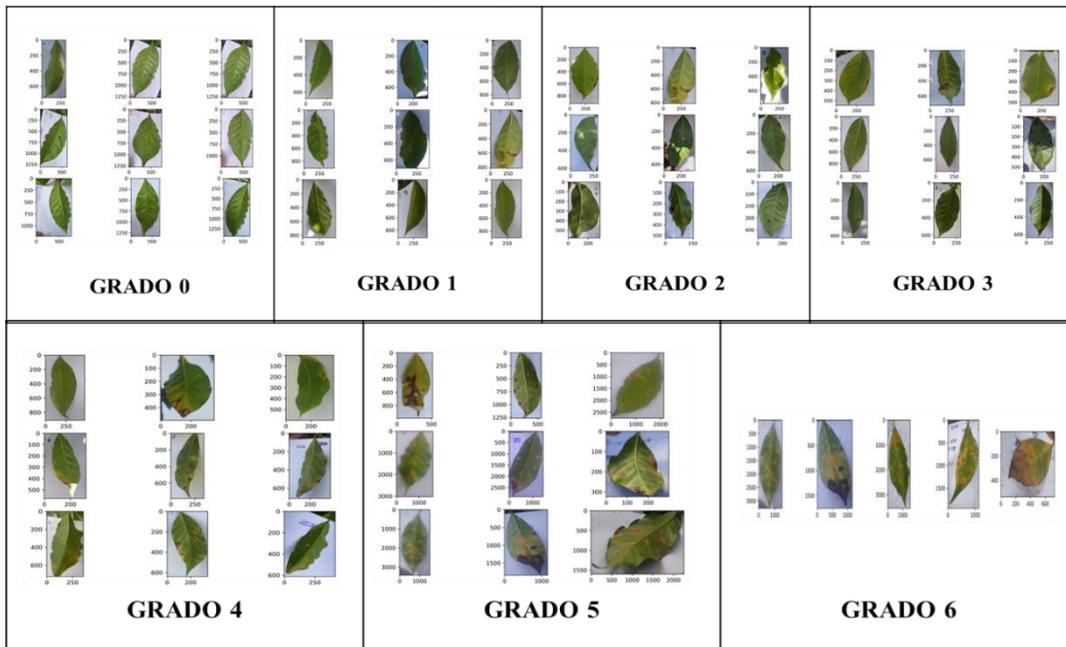
Las imágenes se procesaron y se mejoraron mediante técnicas de aumento de datos, como volteo, recorte y rotación. Se usaron dos arquitecturas de CNN (MobileNet y VGG16), para el entrenamiento y la validación de los modelos. La evaluación del rendimiento se hizo usando métricas como precisión, sensibilidad

y especificidad. Los resultados mostraron que el modelo MobileNet obtuvo una precisión del 94% en la predicción de la severidad de la roya del café para ambos métodos, mientras que el modelo VGG16 alcanzó precisiones del 91 y 90% para SENASA y SENASICA México, respectivamente. La precisión del modelo se validó utilizando matrices de confusión, demostrando un rendimiento excepcional en la clasificación de la severidad de la roya del café.

### 2.2.3 Base de datos según SENASICA México

La base de datos fue obtenida recopilando muestras en campo de 4 parcelas experimentales ubicadas en jaén y san Ignacio, entre los años 2023-2024, en la figura 8 se muestra las imágenes clasificadas según su grado de severidad que clasifica según el Método alternativo de evaluación visual de la severidad, grado 0,1,2,3,4,5 y 6. Con un total de 319 imágenes, se recortaron imágenes de 224 x 224 pixeles y condiciones de iluminación ya que esto reduce la carga computacional en el modelo, acelera la convergencia y clasificación de las hojas y permite predicciones superiores al 90%. Además, se aplicaron técnicas de aumento de datos para mejorar la calidad y cantidad de datos de entrenamiento para construir un modelo eficiente. Las técnicas utilizadas incluyeron: voltear, recortar, rotar y transformar el espacio de color, entre otras.

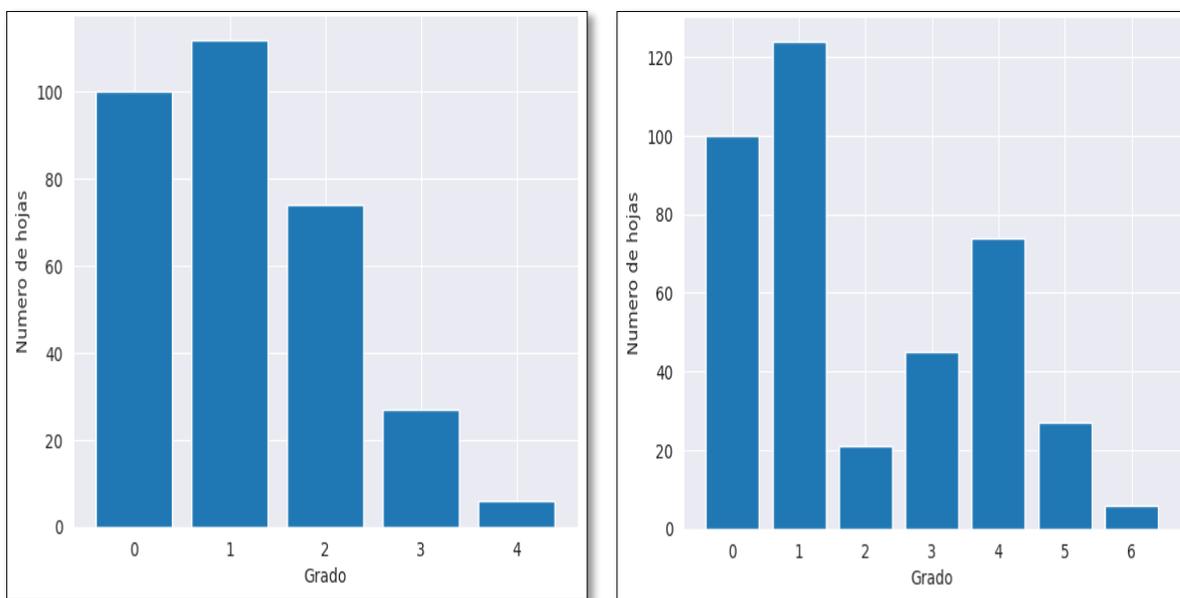
*Figura 8*  
*Base de datos de severidad de roya según método de SENASICA México*



Adaptado de Palomino et al (2023).

La figura 9 según el método de SENASA, el grado de hojas infectadas en su mayoría es del grado 1, con un porcentaje de afectación (1 al 5%), con pequeñas manchas amarillas o puntos cloróticos afectando el área sana de la hoja; asimismo en el método de evaluación según SENASICA México, también el grado de severidad de hojas infectadas es el 1 con una afectación del (1 al 2%) y el menor porcentaje de severidad si varía según SENASA es el grado cuatro (más del 50%) de afectación y según SENASICA México es del grado 6 (más del 70%) de afectación .

*Figura 9*  
*Clasificación de severidad de roya según SENASA y SENASICA México.*



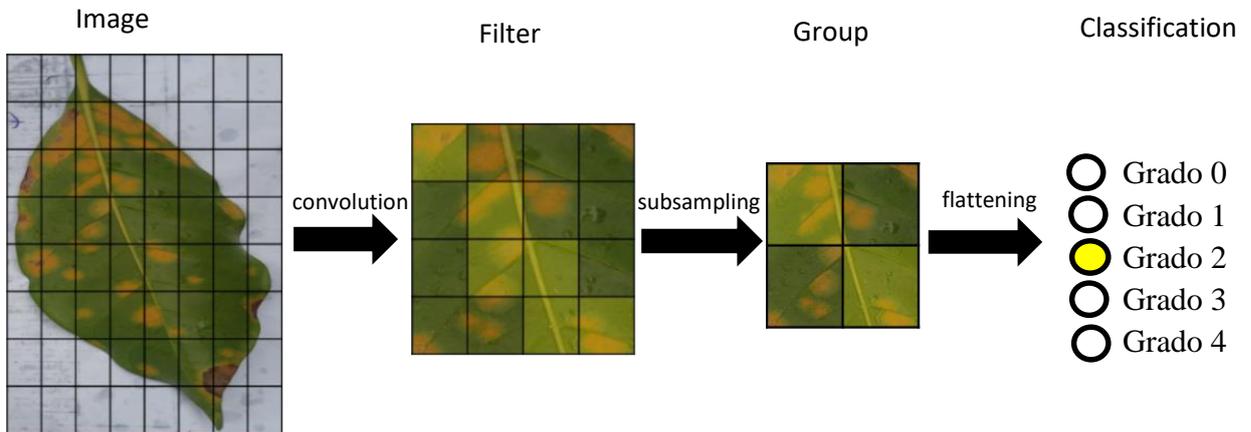
### **III. Empleando Redes neuronales convolucionales para estimar la severidad de Roya de café en provincias de Jaén y San Ignacio.**

#### **4. CNN (Redes Neuronales Convolucionales)**

Emplea núcleos convolucionales para realizar múltiples transformaciones en cada capa. A diferencia de las redes neuronales convolucionales, las capas de una CNN no están completamente conectadas, si no escasamente conectadas lo que se denomina conexión local. Esta conexión local aprovecha la correlación espacial entre las capas de la red neuronal, que es afectada para extraer características relevantes en datos de imágenes, voz, texto en lenguaje natural, etc. La figura 10 muestra la estructura de la CNN utilizada para clasificar las hojas con roya, compuesta por la capa de entrada, imagen de la hoja con roya, y las capas ocultas

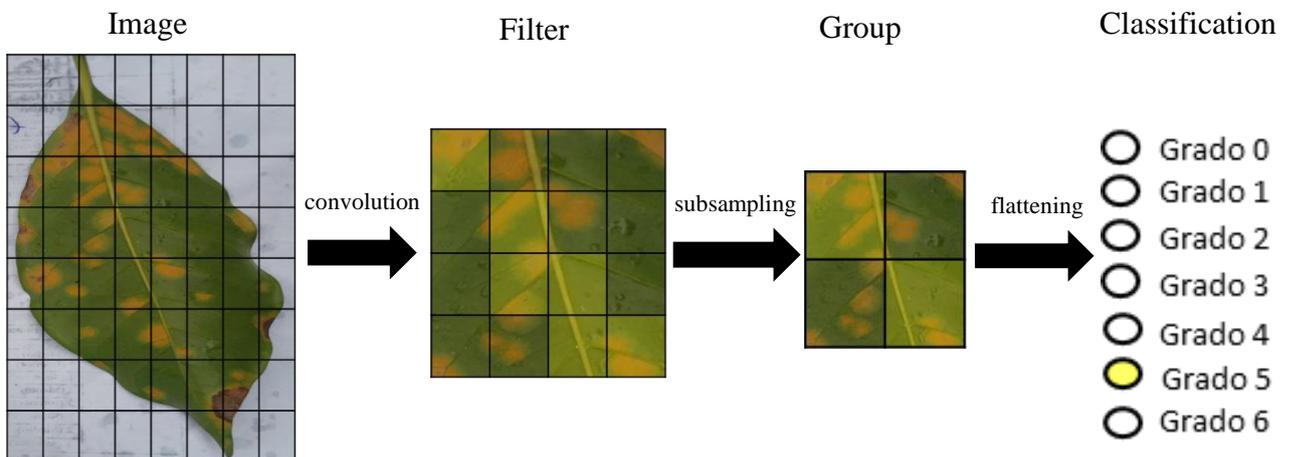
compuestas por la capa convolucional, capa de pooling y la capa de salida. Cada imagen es procesada por la CNN mediante filtros y transformaciones en sus dimensiones hasta determinar el grado de severidad (figura 10).

*Figura 10*  
*Estructura de la red neuronal convolucional según SENASA*



Adaptado de Palomino et al (2023).

*Figura 11*  
*Estructura de la red neuronal convolucional según método alternativo de evaluación visual (SENASICA México)*



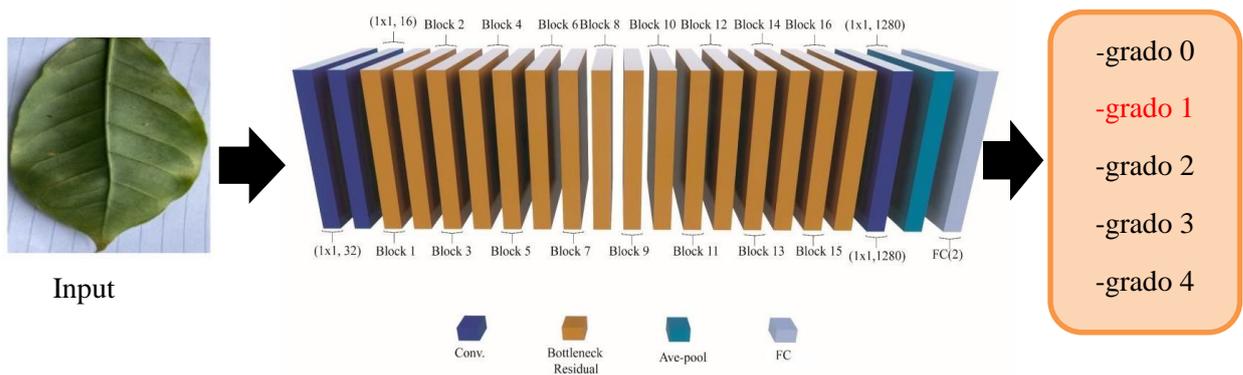
Adaptado de Palomino et al (2023).

## 5. Desarrollo, capacitación y validación de CNN

La matriz de datos se construyó con la biblioteca Python keras, una API de red neuronal convolucional de alto nivel que puede ejecutarse sobre las bibliotecas, utilizando la interfaz de computación en la nube colab con una GPU NVIDIA Tesla V100 de alto rendimiento y 26,9 Gb de RAM en la plataforma Google Colaboratory, estas configuraciones permiten la computación paralela masiva necesaria para entrenar modelos grandes. La base de datos se descargó de Google Drive y se configuran los parámetros de entrada para cada red neuronal convolucional, luego se creó el conjunto de datos para entrenamiento.

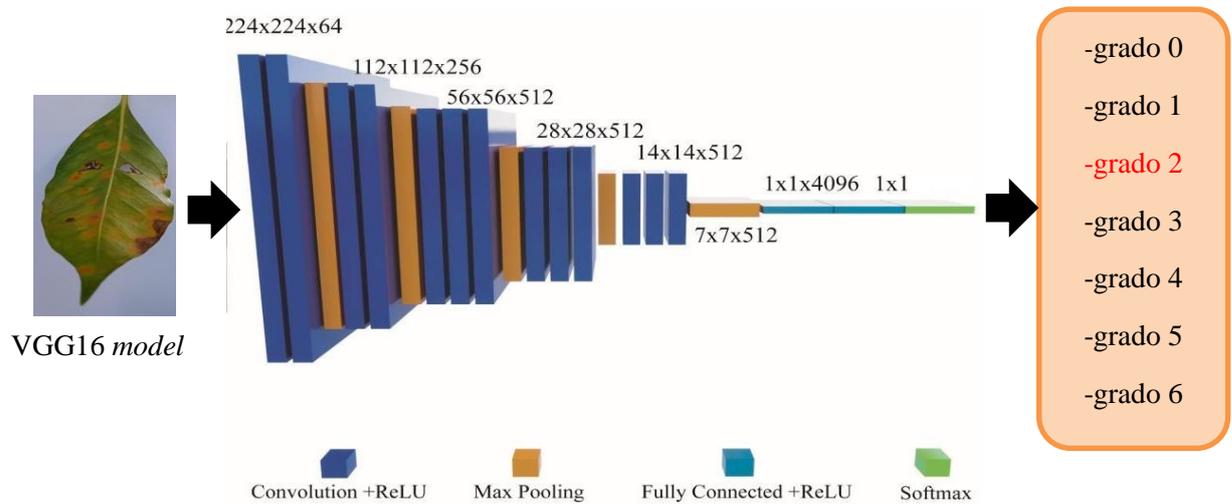
En la figura 12 se muestra imágenes de los grados de severidad según la clasificación SENASA grado 0, 1, 2, 3 y 4. Con un total de 318 imágenes. Además, se aplicaron técnicas de aumento de datos para mejorar la calidad y cantidad de datos de entrenamiento para construir un modelo eficiente. Las técnicas utilizadas incluyeron: voltear, recortar y rotar, entre otras. Las imágenes se almacenaron en un único archivo según el tipo de defecto en la plataforma Google Drive.

Figura 12  
Modelo MobileNet



**Nota.** Se muestra la arquitectura del modelo MobileNet, que consta de una capa de entrada que recibe la imagen del porcentaje de severidad de las hojas utilizando una matriz de 224 x 224 píxeles y un canal de color. Se procesa la información, en las capas convolucionales separables en profundidad que realizan una convolución 1 x 1, las capas residuales del cuello de botella reducen la dimensionalidad de los datos de entrada antes de aplicar capas convolucionales, lo que reduce el número de canales y la cantidad de cálculo requerido, la información se pasa a la capa ave-pool mediante puntos de agrupación, donde se calcula el promedio de los grupos de los píxeles, la capa completamente conectada con seis neuronas estima la severidad de roya según las características extraídas de las capas anteriores.

Figura 13  
Modelo VGG16



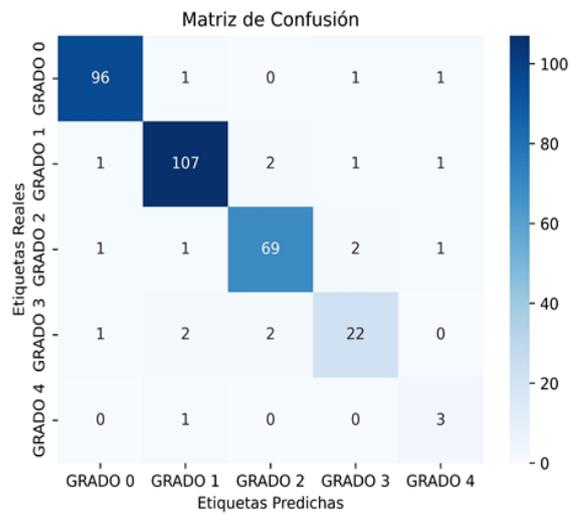
**Nota.** Se muestra imágenes de los grados de severidad según el Método alterno de evaluación visual de la severidad (SENASICA MEXICO), grado 0, 1, 2, 3, 4, 5, y 6. Muestra la estructura del modelo VGG16, que consta de los siguientes elementos, una capa de entrada que recibe la imagen del defecto en 224 x 224 píxeles y colores RGB; seguido de 13 capas convolucionales con 64 filtros, cada uno de tamaño 3 x 3, y una función de activación ReLU para extraer características relevantes. Luego la información se pasa al Capa MaxPooling con una ventana de 2 x 2 y un paso de 2, que tiene como objetivo reducir las dimensiones espaciales. A continuación, se aplican capas convolucionales adicionales con 128, 256 y 512 filtros, seguidas de funciones de activación ReLU. Una penúltima capa de MaxPooling con una ventana de 2 x 2 y un paso de dos reduce aún más las dimensiones. Luego se agregan tres capas completamente conectadas una capa con 4096 neuronas y una función de activación ReLU. Finalmente, la capa anterior está conectada a la última capa con seis neuronas y una función de activación softmax para clasificar el tipo de grado severidad.

## 6. Métricas de Evaluación de las CNN

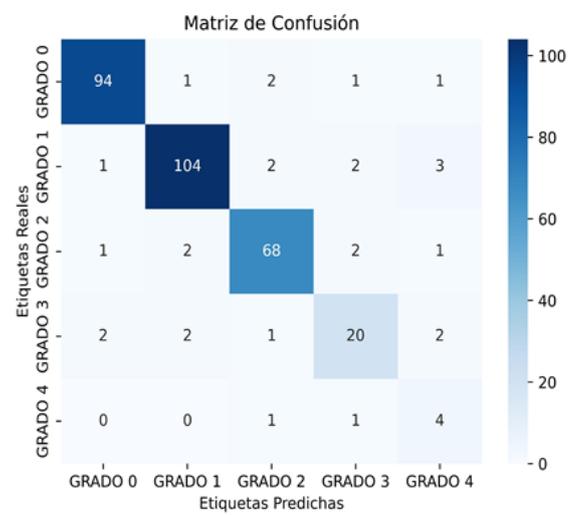
### Matriz de confusión

La matriz de confusión permite comparar las etiquetas reales frente a las predichas con las clases predichas correctamente trazadas en la diagonal y calcula parámetros como precisión, recuperación y exactitud de la clasificación general. La figura 14 se muestra el resumen de la validación de los modelos con la clase real vs. La prevista de los grados de severidad de roya de café según SENASA grados: 0,1,2,3 y 4. Y según SENASICA México grados: 0,1,2,3,4,5 y 6. Validados con un conjunto de pruebas etiquetado con sus respectivos grados de severidad. Al analizar las matrices de confusión de los 2 modelos, observamos diferentes niveles de precisión de identificación, y el modelo MobileNet demostró un rendimiento excepcional, alcanzando una precisión del 94% en la clasificación de la severidad de roya del café (figura 14).

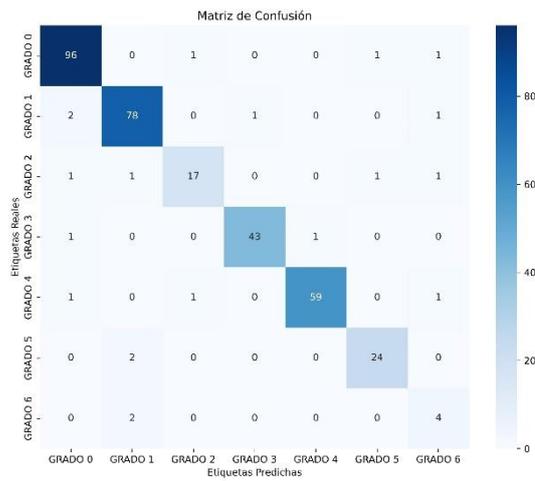
Figura 14  
Matriz de confusión de los modelos



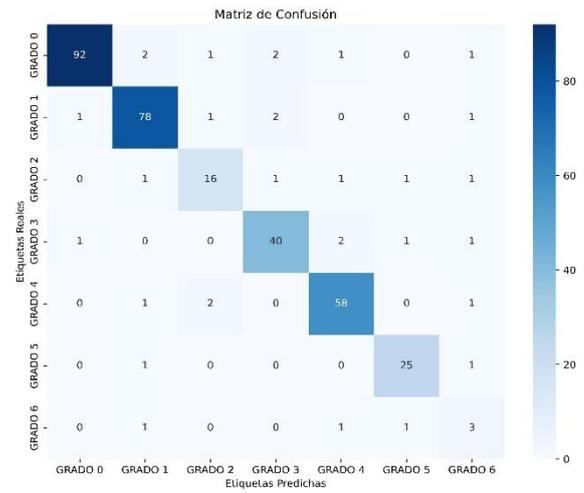
a) SENASA MobileNet



b) SENASA VGG16



a) SENASICA México\_MobileNet



b) SENASICA México\_VGG16

Nota. Gráficos obtenidos de Google colabory Python.

## Precisión de los Modelos

Tabla 7  
Precisión de los modelos

Precisión de las CNN			
Clasificación SENASICA México		Clasificación SENASA	
Mobilenet	Vgg16	Mobilenet	Vgg16
92%	90%	94%	91%

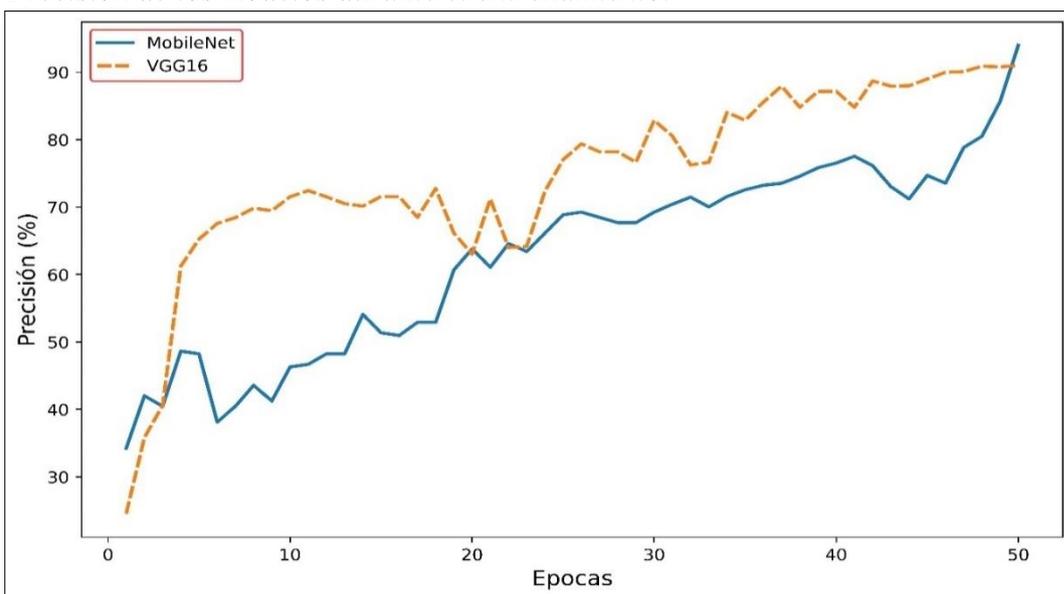
**Nota.** La siguiente tabla muestra la precisión del modelo MobileNet y VGG16, en la severidad de roya del café, el modelo con mayor precisión en estimación de severidad fue Mobile Net con 94% y 92% según las dos clasificaciones utilizadas. Obtenidas de Python

Los modelos MobileNet y VGG16. Sus estadísticas se muestran en la tabla 6; ser evaluado utilizando la base de datos obtenida experimentalmente en términos de precisión.

## Entrenamiento

Luego de generar desde Python los modelos MobileNet y VGG16. Configurados con diferentes arquitecturas y variables de entrada, utilizando 319 imágenes, las cuales fueron procesadas, la figura.16 muestra la generación del entrenamiento obteniendo los mejores resultados en términos de precisión con el modelo MobileNet con un 94% y un error de 6% en 50 épocas. Capturando las diferentes características de la severidad de roya.

Figura 15  
Precisión de los modelos durante el entrenamiento.

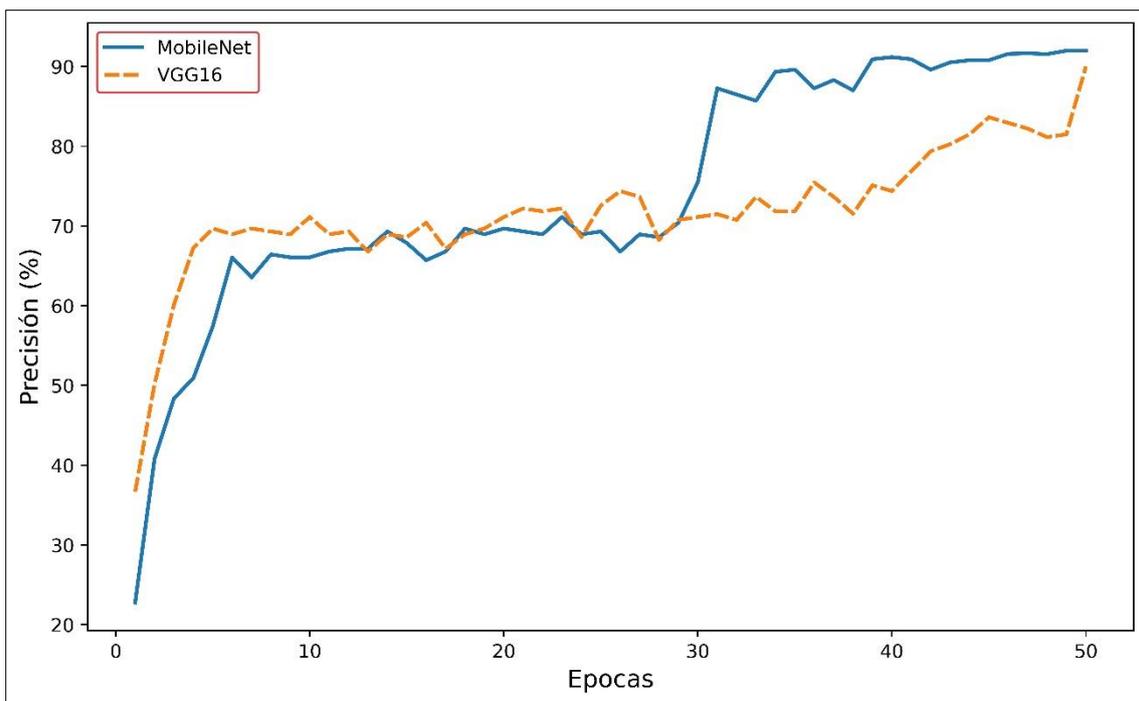


**Nota.** grafica de entrenamiento de las CNN obtenida de Python.

## Validación

La figura 17 muestra la validación de los modelos en la predicción de la severidad de roya de café, aplicando al conjunto de datos de prueba, obteniendo un 94% de precisión con el modelo MobileNet, que identifica patrones y caracteriza cada tipo de error al 6%, los demás modelos presentan un error de menos de 15%. Para elegir el número de épocas, el trabajo se basó en Palomino et al., (2023) teniendo en cuenta los factores: la complejidad del conjunto de datos, la arquitectura del modelo y la convergencia del proceso de entrenamiento, calculando en 50 el número óptimo de épocas determinado a través de la experimentación y validación, para mejorar el rendimiento de los modelos, reduciendo en tiempo computacional.

*Figura 16*  
*Precisión del modelo durante la validación.*



**Nota.** grafica de Validación de las CNN obtenida de Python.

#### IV. DISCUSIÓN

Respecto al objetivo específico uno se halló que la especie predominante fue *Inga edulis*. Este resultado es comparable con lo hallado por Alvarado et al. (2020) quienes realizaron un estudio sobre el potencial agroforestal de guabo *Inga edulis*, los resultados evidenciaron que este tipo de especie permite la recuperación de los suelos degradados dado que permite la generación de macronutrientes como el nitrógeno, fósforo, potasio, calcio, magnesio y azufre, y de micronutrientes como boro, cobre, zinc, molibdeno entre otros. También para Parada et al., (2022) los sistemas agroforestales son importantes dado que mitigan los efectos negativos del cambio climático como la propagación de plagas; y, DeMatta y Rodríguez (2007) señala que estos sistemas permiten a las plantas de café adaptarse a las condiciones ecológicas, creando microclimas que mejoran la productividad al reducir la temperatura relativa.

De la comparación de los resultados de la presente investigación resalta la importancia de los sistemas agroforestales para la sostenibilidad de la calidad del suelo, el control de plagas y proteger las especies que se encargan de la polinización que permite la cosecha de algunos cultivos. Principalmente la especie forestal de *Inga edulis* es de suma relevancia en los sistemas agroforestales que buscan proporcionar sombra, siendo esto gracias a su fácil crecimiento, su notable capacidad de fijar el nitrógeno en el suelo, así como en los procesos de adaptabilidad; siendo muy valorada también por su característica de crecer en asociación con otras especies.

Se generó una base de datos con la clasificación de severidad de la roya tomando en cuenta el método de SENASA Perú y SENASICA México, habiéndose hecho uso de dos arquitecturas de CNN como MobileNet y VGG16 para entrenar y validar el modelo con los datos recolectados como las imágenes de hojas de café. El resultado de la generación de las bases de datos con el modelo MobileNet obtuvo una precisión de 94% y el modelo VGG16 una precisión de 91% por SENASA y 90% por SENASICA México. Este resultado es comparable por el hallado por Párraga et al., (2019) quienes en su investigación abordaron el estudio sobre enfermedades en las hojas del café robusta conformando un conjunto de imágenes denominado RoCole, permitiendo a través del uso de logaritmos de

aprendizaje automático lograr segmentar y clasificar las imágenes de las plantas con una mayor precisión en el diagnóstico. También este resultado es comparable con los resultados de Herrero (2021), en una investigación realizada en Valladolid en la cual utilizó el Deep Learning para determinar la retinopatía diabética, las imágenes tomadas a los pacientes permitieron que se clasifiquen adecuadamente, contando con un coeficiente kappa de 0.919, especificidad de 96.31% y precisión de 94.10%, estos resultados permitieron comprobar que es posible realizar detección temprana y clasificación de la enfermedad. Los resultados de Biniyam y Mossab (2023) también permite ser comprables con los hallados en la presente investigación habiendo utilizado arquitecturas como GoogLeNet y RESNET para extraer características de alto nivel, determinándose que el modelo propuesto alcanzó una precisión de prueba del 99.08%, superando a otros métodos de clasificación evaluados.

Se aplicó redes neuronales convolucionales para estimar la severidad de Roya hallándose mediante el método de SENASA que el grado de severidad predominante fue el grado comprendido entre el 1 al 5% de afectación de la hoja, y aplicando el método de SENASICA México el grado de severidad hallado fue el grado 1 característico del inicio de la plaga presentando mínimo puntos de cloróticos. Estos resultados son comparables con lo obtenido por Valle (2019) quien en su investigación sobre severidad de la roya amarilla halló que la incidencia de esta plaga fue del 76.75% y respecto al grado de severidad el 42% de las hojas analizadas presentaban un nivel de severidad de roya de grado 3. Esta comparación revela diferencias significativas en la metodología y los resultados obtenidos, lo que puede ser indicativo de variaciones en las condiciones ambientales, técnicas de muestreo o en las características específicas de las poblaciones de cafetos estudiadas.

## V. CONCLUSIONES Y RECOMENDACIONES

### 5.1. Conclusiones

- La caracterización de sistemas agroforestales permite comprender mejor la complejidad del sistema y tomar decisiones de manejo más efectivas para mejorar la sostenibilidad y productividad de las plantaciones.
- Se logró estimar la severidad de la roya del café en los sistemas agroforestales empleando Deep Learning en las provincias de Jaén y San Ignacio, departamento de Cajamarca, 2023, aplicando los métodos de SENASA y SENASICA México, se determinó que el más conveniente recalcar es el método de SENASA ya que permite una evaluación temprana de la roya, la escala del 0 al 4% proporciona una mayor precisión en la medición de la severidad de la roya en comparación con escalas más amplias, esto permite una evaluación más precisa de la extensión del daño y una mejor planificación de las estrategias de control ya que también es un método propio del país.
- Se logró caracterizar los sistemas agroforestales presentes en las parcelas de café, evidenciándose que las especies de plantas presentes con mayor frecuencia en los lotes estudiados, la especie que más predominó fue *Inga edulis* tanto como para la finca La Palestina y finca La Prosperidad.
- Se logró generar una base de datos con la clasificación de la severidad de roya según SENASA y SENASICA México para medir con exactitud la superficie dañada de la hoja, la cual estuvo conformada por un total de 319 hojas, las cuales fueron analizadas con ambos métodos. Según el método de SENASA la severidad de la roya con mayor presencia fue de grado 1 es decir que las hojas presentan un grado de afectación del 1% al 5%; asimismo haciendo el uso del método alternativo de evaluación visual se identificó que la afectación de la roya fue de clase 1 presentándose mínimos puntos cloróticos.
- Se logró aplicar redes neuronales convolucionales para estimar la severidad de Roya de café en provincias de Jaén y San Ignacio, demostrándose que las técnicas de aprendizaje profundo supervisado, específicamente las redes neuronales convolucionales (CNN), son efectivas para predecir la severidad de la roya del café. Utilizando métodos de SENASA y SENASICA México, y una base de datos de imágenes clasificadas de hojas de café recolectadas en

parcelas experimentales, se desarrollaron y entrenaron modelos CNN en Google Colab con bibliotecas de aprendizaje automático como TensorFlow y Keras. Los modelos MobileNet y VGG16 se evaluaron utilizando métricas de precisión, sensibilidad y especificidad. Los resultados indicaron que MobileNet alcanzó una precisión del 94% en ambos métodos, mientras que VGG16 logró precisiones del 91% y 90% para SENASA y SENASICA México, respectivamente. La validación del modelo con matrices de confusión confirmó su alto rendimiento, subrayando el potencial de estas técnicas para mejorar significativamente la vigilancia y el control de la roya del café.

## **5.2.Recomendaciones**

A los agricultores-productores de café, implementar sistemas agroforestales en sus parcelas productivas, optando por las especies de *Inga edulis* dado que son especies que permite mejorar la calidad del grano y prevenir enfermedades de la planta como la roya.

A los investigadores, realizar más investigaciones sobre manejo, conservación y caracterización de los sistemas agroforestales.

Capacitar a los productores del avance tecnológico para sus cultivos en detección de enfermedades y mejor manejo de sus cultivos.

A los productores, prevenir enfermedades como la roya, dado que si se realiza un diagnóstico temprano pueden adoptarse medidas necesarias para revertir dicho problema.

## VI. REFERENCIAS BIBLIOGRÁFICAS

- Alvarado, A., Pilaloe, W., Carrera, B. y Carrera, D. (2020). Desarrollo comparative de dos especies *Inga* en base a su potencial agroforestal. *Revista de Investigación en Ciencias Agronómicas y Veterinarias*, 4 (12), 186-199. [http://www.scielo.org.bo/pdf/arca/v4n12/v4n12\\_a02.pdf](http://www.scielo.org.bo/pdf/arca/v4n12/v4n12_a02.pdf)
- Andrade, Y. (2016). *Especialización en planeación ambiental y manejo integral de los recursos naturales* (Trabajo de grado). Universidad Militar Nueva Granada, Bogotá. <https://repository.unimilitar.edu.co/bitstream/handle/10654/15293/AndradePradoYinethAlexandra2016.pdf?sequence=1&isAllowed=y>
- Ávila, G. (2022). *Entrenamiento de redes neuronales para la identificación de plagas en cultivos de café*. Universidad Pedagógica Nacional, Bogotá. <http://repository.pedagogica.edu.co/bitstream/handle/20.500.12209/18306/entrenamiento%20redes%20neuronales.pdf?sequence=4&isAllowed=y>
- Barbedo, J. G. A. (2018). Impact of dataset size and variety on the effectiveness of deep learning and transfer learning for plant disease classification. *Computers and Electronics in Agriculture*, 153, 46-53.
- Biniyam, A. y Mossab, A. (2023). Clasificación de enfermedades del café mediante redes neuronales convolucionales basadas en concatenación de características. *La informática en medicina desbloqueada*, 39 (12), 1-9. <https://www.sciencedirect.com/science/article/pii/S2352914823000874>
- Bordin, J. y Leite, J. (2023). Coffee disease classification at the Edge using deep learning. *Smart Agricultural Technology*, 4 (2), 1-9.
- DaMatta, F. y Rodríguez, N. (2007). Producción sostenible de cafetales en sistemas agroforestales del Neotrópico: una visión agronómica y ecofisiológica. *Agronomía colombiana*, 25 (1), 113-123. <http://www.scielo.org.co/pdf/agc/v25n1/v25n1a13.pdf>
- Díaz, C. y Carmen, M. (2017). *Línea de base del sector café en el Perú. Documento de trabajo*. Ministerio de Agricultura y Riego. <https://www.midagri.gob.pe/portal/download/2017/pncafe/sector-cafe-peru.pdf>

- Díaz, L. (2011). *La observación*. Universidad Autónoma de México. [https://www.psicologia.unam.mx/documentos/pdf/publicaciones/La\\_observacion\\_Lidia\\_Diaz\\_Sanjuan\\_Texto\\_Apoyo\\_Didactico\\_Metodo\\_Clinico\\_3\\_Sem.pdf](https://www.psicologia.unam.mx/documentos/pdf/publicaciones/La_observacion_Lidia_Diaz_Sanjuan_Texto_Apoyo_Didactico_Metodo_Clinico_3_Sem.pdf)
- Farfán, F. (2014). *Agroforestería y Sistemas Agroforestales con Café*. Manizales, Caldas (Colombia). [https://www.cenicafe.org/es/publications/Agroforester%C3%ADa\\_y\\_sistemas\\_agroforestales\\_con\\_caf%C3%A9.pdf](https://www.cenicafe.org/es/publications/Agroforester%C3%ADa_y_sistemas_agroforestales_con_caf%C3%A9.pdf)
- Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311-318.
- Gavito, J. (2019). *Sistema inteligente para detección temprana de la roya en cafetales* (Tesis de maestría). Centro de ingeniería y desarrollo industrial, Querétaro. <https://cidesi.repositorioinstitucional.mx/jspui/bitstream/1024/422/1/M-JCGM-2019.pdf>
- Gómez, S. (2019). Los 10 mayores productores de café del mundo – 2019. [https://quecafe.info/mayores-productores-de-cafe-en-el-mundo/#10\\_%E2%80%93\\_Mayores\\_productores\\_de\\_cafe\\_Peru](https://quecafe.info/mayores-productores-de-cafe-en-el-mundo/#10_%E2%80%93_Mayores_productores_de_cafe_Peru)
- González, A. y Martínez, C. (2022). Mejoramiento y uso de los efluentes para el beneficio del café. *Revista de técnicas agropecuarias*, 31 (2), 1-7. [http://scielo.sld.cu/pdf/rcta/v31n2/es\\_2071-0054-rcta-31-02-e08.pdf](http://scielo.sld.cu/pdf/rcta/v31n2/es_2071-0054-rcta-31-02-e08.pdf)
- Guzmán, P., Gómez, G., Rivillas, O. Y Oliveros, C. (2003). Utilización del procesamiento de imágenes para determinar la severidad de la mancha de hierro del café. *Cenicafe*, 54 (3). 258-265. .DOI: 10.1080/08839514.2017.1315516
- Hernández, C., López, L. y Sánchez, L. (2021). Agentes de control biológico de la roya del café ¿cómo funcionan y qué tan efectivos son?. *Bio Tecnología*, 25 (1), 21-31. <https://smbb.mx/wp-content/uploads/2021/05/Hernandez-et-al.-2021.pdf>
- Herrero, M. (2021). *Clasificación automática de la severidad de la Retinopatía Diabética mediante técnicas de Deep Learning* (Trabajo de fin de master). Universidad de Valladolid, Valladolid. <https://uvadoc.uva.es/bitstream/handle/10324/50053/TFM-G1502.pdf?sequence=1&isAllowed=y>

- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70-90.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Libert, A. y Paz, F. (2018). Del papel a la acción en la mitigación y adaptación al cambio climático: la roya del cafeto en Chiapas. *Madera y bosques*, 24(2), 1-24. <https://www.scielo.org.mx/pdf/mb/v24nspe/2448-7597-mb-24-spe-e2401914.pdf>
- Llanos, D. (2021). *Análisis de los costos logísticos de la cadena de valor del café en Chanchamayo* (Tesis de maestría). Universidad del Pacífico, Lima. [https://repositorio.up.edu.pe/bitstream/handle/11354/3048/LlanosDiana\\_Tesis\\_maestria\\_2021.pdf?sequence=1&isAllowed=y](https://repositorio.up.edu.pe/bitstream/handle/11354/3048/LlanosDiana_Tesis_maestria_2021.pdf?sequence=1&isAllowed=y)
- 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.
- Márquez, F., Quispe, P., Molleapaza, N., Cabrera, A. y Peña, J. (2020). Relación entre las características del suelo y altitud con la caldead sensorial del café cultivado bajo sistemas agroforestales en Cusco, Perú. *Scientia Agropecuaria*, 11 (4), 529-536. <http://www.scielo.org.pe/pdf/agro/v11n4/2077-9917-agro-11-04-529.pdf>
- Martínez, E. (2005). Errores frecuentes en la interpretación del coeficiente de determinación lineal. *Anuario jurídico y económico Escorialense*, 38(3), 315-332
- Matos, Y. (2008). La observación, discusión y demostración: técnicas de investigación en el aula. *Revista de educación Laurus*, 14 (27), 33-52. <https://www.redalyc.org/pdf/761/76111892003.pdf>
- Mekonnen, T. F., Tilahun, S. L., Salunkhe, O., & Pant, J. (2020). Application of artificial intelligence in agriculture. *International Journal of Environmental Research and Public Health*, 17(23), 8698.
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7, 1419.
- Morán, J. y Jiménez, E. (2023). Caracterización de sistemas productivos de café (*Coffea arabica* L.) en la Reserva Natural Tepec-Xomolth, Madriz, Nicaragua. *Siembra*,

10 (1), 2-12. <http://scielo.senescyt.gob.ec/pdf/siembra/v10n1/2477-8850-siembra-10-01-04402.pdf>

Nahuamel, E. (2019). *Efecto económico de la roya amarilla en el comercio mundial de café. Caso Perú: periodo 2011-2015* (Tesis de doctorado). Universidad Nacional Mayor de San Marcos, Lima. <https://cybertesis.unmsm.edu.pe/bitstream/handle/20.500.12672/12597/Nahuamel-je.pdf?sequence=1&isAllowed=y>

Navarro J. y Arauz, L. [1999] Exactitud y repetitividad de dos métodos para la evaluación de la severidad de enfermedades fungosas en el fruto de la papaya (Carica papaya). *Agronomía oostarricense*, 23 (14), 89-96.

Omondi, M. (2011). *Roya del cafeto*. [http://www.cesavep.org/descargas/RDC/Ficha\\_Tecnica\\_Roya\\_del\\_cafeto.pdf](http://www.cesavep.org/descargas/RDC/Ficha_Tecnica_Roya_del_cafeto.pdf)

Otzen, T. y Manterola, C. (2017). Técnicas de Muestreo sobre una Población a Estudio. *Int.J. Morphol*, 35 (1), 227-232. <https://scielo.conicyt.cl/pdf/ijmorphol/v35n1/art37.pdf>

Padial, J. (2019). Deep Learning: ¿Simulacro o realización artificial de la inteligencia? *Naturaleza y libertad*, 12 (5), 191-210.

Palacios, A., Durand, M., Valle, J. y Saldivar, A. (2022). Desafíos de los medios de vida frente a la roya del café en dos comunidades del Soconusco, Chiapas, México. *Revista de alimentación contemporánea y desarrollo regional*, 33 (61), 1-25.

Palomino, J., Cayotopa, B., Quiñones, L., Piedra, J., Milla, M. y Rojas, W. (2023). Convolutional Neural Network for Predicting Failure Type in Concrete Cylinders During Compression Testing. *Civil Engineering Journal*, 9 (9), 2105-2119.

Parada, P., Barradas, V., Ortiz, G., Cervantes, J y Cerdán, C. (2022). Climatic suitability for Coffea arabica L. front to climate events extreme: Tree cover importance. *Scientia Agropecuaria*, 13 (1), 53-62. <http://www.scielo.org.pe/pdf/agro/v13n1/2077-9917-agro-13-01-53.pdf>

Parraga, J., Cusme, K., Loor, A., y Santander, E. (2019). RoCoLe: un conjunto de datos de imágenes de hojas de café robusta para la evaluación de métodos basados en aprendizaje automático en el reconocimiento de enfermedades de las plantas.

*Datos breves*, 25 (2), 1-5.  
<https://www.sciencedirect.com/science/article/pii/S2352340919307693>

Pereyra, M. (2020). Detección de enfermedades y plagas en cultivos mediante Machine Learning. Universidad Nacional de la Plata.  
[http://sedici.unlp.edu.ar/bitstream/handle/10915/118496/Documento\\_completo.pdf?sequence=1&isAllowed=y](http://sedici.unlp.edu.ar/bitstream/handle/10915/118496/Documento_completo.pdf?sequence=1&isAllowed=y)

Peterson R., Campbell, A y Hannah, A. (1948) A diagrammatic scale for estimating rust intensity of leaves and stem of cereals. *Canadian Journal of Research* 26 (13), 496-500

Powers, C. (2020). Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation», *J. Mach. Learn. Technol.*, 2 (1), 37-63.  
[https://www.academia.edu/3090500/Evaluation\\_From\\_Precision\\_Recall\\_and\\_F\\_Measure\\_to\\_ROC\\_Informedness\\_Markedness\\_and\\_Correlation](https://www.academia.edu/3090500/Evaluation_From_Precision_Recall_and_F_Measure_to_ROC_Informedness_Markedness_and_Correlation)

Pumisacho, C. (2022). *Propagación sexual y asexual de Inga Insignis Kunth, de los cantones Ibarra y Antonio Ante de la provincia de Imbabura*. Universidad Técnica del Norte, Ibarra.  
<https://repositorio.utn.edu.ec/bitstream/123456789/12094/2/03%20FOR%20340%20TRABAJO%20GRADO.pdf>

Román, E. y Ruiz, M. (2021). Detección de macronutrientes y enfermedades en campos de cultivos de banano orgánico con Machine Learning (Tesis de grado). Universidad de Piura, Piura.  
[https://pirhua.udep.edu.pe/bitstream/handle/11042/4939/T\\_IME\\_2102.pdf?sequence=1&isAllowed=y](https://pirhua.udep.edu.pe/bitstream/handle/11042/4939/T_IME_2102.pdf?sequence=1&isAllowed=y)

Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., ... & Fei-Fei, L. (2015). ImageNet large scale visual recognition challenge. *International Journal of Computer Vision*, 115(3), 211-252.

SERFOR. (2021). *Sistemas agroforestales*.  
<https://cdn.www.gob.pe/uploads/document/file/2057503/Sistemas%20Agroforestales.pdf.pdf>

- Shi, T. (2023). Recent advances in plant disease severity assessment using convolutional neural networks, *Sci. Rep.*, 13 (1). 2023, doi: 10.1038/s41598-023-29230-7.
- Valle, E. (2019). *Diagnóstico de incidencia y severidad de la roya amarilla (Hemileia Vastatrix Berk. & Br) en cultivares de café en los sectores de Pampa Rosario y Santa Barbara del distrito de Santa Ana-La Convención-Cusco* (Tesis de pregrado). Universidad Nacional San Antonio Abad del Cusco, Cusco. [https://repositorio.unsaac.edu.pe/bitstream/handle/20.500.12918/5049/253T20170499\\_TC.pdf?sequence=1&isAllowed=y](https://repositorio.unsaac.edu.pe/bitstream/handle/20.500.12918/5049/253T20170499_TC.pdf?sequence=1&isAllowed=y)
- Velo, E. (2020). *Introducción a los métodos Deep learning basados en redes neuronales*. [http://eio.usc.es/pub/mte/descargas/ProyectosFinMaster/Proyecto\\_1654.pdf](http://eio.usc.es/pub/mte/descargas/ProyectosFinMaster/Proyecto_1654.pdf)
- Villareyna, R., Avelino, J. y Cerda, R. (2020). Adaptación basada en ecosistemas: efecto de los árboles de sombra sobre servicios ecosistémicos en cafetales. *Agronomía Mesoamericana*, 31 (2), 499-516. <https://www.redalyc.org/journal/437/43762994016/html/>
- Villarreyna, R. (2016). *Efecto de los árboles de sombra sobre el suelo, en sistemas agroforestales con café, incluyendo la fenología y fisiología de los cafetos*. Catie, Costa Rica. [https://agritrop.cirad.fr/582061/1/Reporte%203\\_Sombra%20y%20rendimientos%20de%20caf%C3%A9.pdf](https://agritrop.cirad.fr/582061/1/Reporte%203_Sombra%20y%20rendimientos%20de%20caf%C3%A9.pdf)
- Villarreyna, R. (2016). *Efecto de sombra sobre el rendimiento de los cafetos., basado en perfiles de daño*. Catie, Costa Rica. [https://agritrop.cirad.fr/582061/1/Reporte%203\\_Sombra%20y%20rendimientos%20de%20caf%C3%A9.pdf](https://agritrop.cirad.fr/582061/1/Reporte%203_Sombra%20y%20rendimientos%20de%20caf%C3%A9.pdf)
- Zhang, S., Zhang, S., Huang, T., Gao, W., & Qiao, Y. (2018). Learning from multimodal heterogeneous data for plant growth prediction in a modern greenhouse. *IEEE Access*, 6, 36386-36397.

## **AGRADECIMIENTO**

Al apoyo logístico del proyecto “Evaluación de la severidad y distribución espacial de la roya del café utilizando RPAS y técnicas de aprendizaje automático en las provincias de San Ignacio y Jaén en la Región Cajamarca” financiado por PROCIENCIA de CONCYTEC.

A los asesores Mg. Candy Lisbeth Ocaña Zúñiga y Dr. Lenin Quiñones Huatangari, por su enseñanza y por compartir su conocimiento, lo cual ha enriquecido enormemente nuestra formación académica.

Al Ing. José Manuel Palomino Ojeda, por su generoso aporte que facilitó la realización de este estudio.

A nuestra amiga Milagros del Pilar Horna Oliva por su orientación, apoyo constante y valiosos comentarios que fueron fundamentales en la realización de este trabajo.

## **DEDICATORIA**

La investigación va dedicada a nuestros padres, por su apoyo incondicional y constante durante este viaje académico. Sin ustedes, este logro no sería posible. A todos aquellos que creyeron en nosotros, su fe en nosotros nos impulsó a seguir adelante.

# ANEXOS

## Anexo 1 Ficha para determinar incidencia de Roya

UNIVERSIDAD NACIONAL DE JAÉN  
 Proyecto: ROYA - RPAS  
 Pro CIENCIA

LOTE 2  
 CATORRA

FICHA PARA DETERMINAR INCIDENCIA DE ROYA

Finca: LA PROSPERIDAD Propietario: LA COOPERATIVA  
 Lote: II Fecha de muestreo: 21-10-2023  
 Muestreador: Naji y Sheron

10.00 AM

N° planta	N° rama	Hojas totales	Hoja con roya
1	1 (Superior)	2	—
	2 (Medio)	0	—
	3 (Inferior)	3	—
2	1 (Superior)	0	0
	2 (Medio)	2	0
	3 (Inferior)	4	0
3	1 (Superior)	4	0
	2 (Medio)	0	0
	3 (Inferior)	4	0
4	1 (Superior)	0	0
	2 (Medio)	7	0
	3 (Inferior)	0	0
5	1 (Superior)	0	1
	2 (Medio)	4	—
	3 (Inferior)	4	0
Total			
Incidencia			

FICHA PARA DETERMINAR SEVERIDAD DE ROYA

Finca: \_\_\_\_\_ Propietario: \_\_\_\_\_  
 Lote: \_\_\_\_\_ Fecha muestreo: \_\_\_\_\_  
 Muestreador: \_\_\_\_\_

N° planta	N° rama	Hojas totales	N0	N1	N2	N3	N4
1	1 (Superior)	4	4	—	—	—	—
	2 (Medio)	4	0	—	—	—	—
	3 (Inferior)	4	4	—	—	—	—
2	1 (Superior)	4	0	—	—	—	—
	2 (Medio)	4	4	—	—	—	—
	3 (Inferior)	4	4	—	—	—	—
3	1 (Superior)	4	4	—	—	—	—
	2 (Medio)	4	0	—	—	—	—
	3 (Inferior)	4	4	—	—	—	—
4	1 (Superior)	4	0	—	—	—	—
	2 (Medio)	4	4	—	—	—	—
	3 (Inferior)	4	0	—	—	—	—
5	1 (Superior)	4	4	—	—	—	—
	2 (Medio)	4	4	—	—	—	—
	3 (Inferior)	4	4	—	—	—	—
Total		60					
Severidad							

UNIVERSIDAD NACIONAL DE JAÉN  
 Proyecto: ROYA - RPAS  
 Pro CIENCIA

Finca: Palestina Propietario: \_\_\_\_\_  
 Lote: 01 Fecha de muestreo: 22 de Julio  
 Muestreador: \_\_\_\_\_

GUEISHA

N° planta	N° rama	Hojas totales	Hoja con roya
1	1 (Superior)	16	2
	2 (Medio)	20	15
	3 (Inferior)	4	2
2	1 (Superior)	14	6
	2 (Medio)	1	1
	3 (Inferior)	1	1
3	1 (Superior)	19	4
	2 (Medio)	25	4
	3 (Inferior)	5	1
4	1 (Superior)	15	9
	2 (Medio)	16	4
	3 (Inferior)	2	0
5	1 (Superior)	11	9
	2 (Medio)	1	1
	3 (Inferior)	4	2
Total			
Incidencia			

FICHA PARA DETERMINAR SEVERIDAD DE ROYA

Finca: \_\_\_\_\_ Propietario: \_\_\_\_\_  
 Lote: \_\_\_\_\_ Fecha muestreo: \_\_\_\_\_  
 Muestreador: \_\_\_\_\_

N° planta	N° rama	Hojas totales	N0	N1	N2	N3	N4
1	1 (Superior)	4	1	I.1	—	—	—
	2 (Medio)	4	4	I.2	I.3	I.4	I.5
	3 (Inferior)	4	2	I.6	I.7	—	—
2	1 (Superior)	4	4	I.10	I.11	I.12	I.13
	2 (Medio)	4	1	I.9	—	—	—
	3 (Inferior)	4	1	I.8	—	—	—
3	1 (Superior)	4	1	I.14	—	—	—
	2 (Medio)	4	3	I.16	I.17	I.18	—
	3 (Inferior)	4	1	I.15	—	—	—
4	1 (Superior)	4	4	I.19	I.20	I.21	I.22
	2 (Medio)	4	2	I.23	I.24	—	—
	3 (Inferior)	4	0	—	—	—	—
5	1 (Superior)	4	3	I.25	I.26	I.27	—
	2 (Medio)	4	1	I.28	—	—	—
	3 (Inferior)	4	2	I.29	I.30	—	—
Total		60					
Severidad							

## Anexo 2 Código CNN-Clasificador de imágenes

```
from keras.models import Sequential, Model

from keras.layers import Conv2D, MaxPool2D, Dense, Flatten,
Dropout, BatchNormalization, Input

from keras.optimizers import Adam

from keras.callbacks import TensorBoard, ModelCheckpoint

import os

import numpy as np

from tensorflow.keras.preprocessing.image import ImageDataGenerator

import numpy as np

from keras.preprocessing import image

from keras.applications.imagenet_utils import preprocess_input,
decode_predictions

from keras.applications.vgg16 import VGG16

from keras.applications.vgg19 import VGG19

from keras.applications.mobilenet import MobileNet

from keras.preprocessing.image import ImageDataGenerator

from sklearn.utils import shuffle

from sklearn.model_selection import train_test_split

import cv2

import matplotlib.pyplot as plt

%matplotlib inline

from google.colab import drive

drive.mount('/content/drive')

Drive already mounted at /content/drive; to attempt to forcibly
remount, call drive.mount("/content/drive", force_remount=True).

#Mostrar cuantas imagenes tengo de cada categoria

!ls /content/drive/MyDrive/SENASA/"GRADO 0" | wc -l

!ls /content/drive/MyDrive/SENASA/"GRADO 1" | wc -l

!ls /content/drive/MyDrive/SENASA/"GRADO 2" | wc -l

!ls /content/drive/MyDrive/SENASA/"GRADO 3" | wc -l

!ls /content/drive/MyDrive/SENASA/"GRADO 4" | wc -l
```

```
#Mostrar algunas imagenes con pyplot
import os
import matplotlib.pyplot as plt
import matplotlib.image as mpimg

plt.figure(figsize=(15,15))

carpeta = '/content/drive/MyDrive/SENASA/GRADO 2'

imagenes = os.listdir(carpeta)
for i, nombreimg in enumerate(imagenes[:15]):
    plt.subplot(5,5,i+1)
    imagen = mpimg.imread(carpeta + '/' + nombreimg)
    #plt.savefig('Senasa grado 1.jpg',dpi=1000) # Cambiar el grado
    #segun las imagenes que se mostraran
    plt.imshow(imagen)
```

### **Anexo 3** Configuración de parámetro

```
width_shape = 224
height_shape = 224
num_classes = 5
epochs = 50
batch_size = 32
```

#### **Path de dataset**

```
train_data_dir = '/content/drive/MyDrive/SENASA'
validation_data_dir = '/content/drive/MyDrive/SENASA'
```

#### **Generador de imágenes (entrenamiento y validación)**

```
train_datagen = ImageDataGenerator(

    rotation_range=5,
    zoom_range=0.1,
    width_shift_range=0.1,
    height_shift_range=0.1,
    horizontal_flip=False,
    vertical_flip=True,
    validation_split=0.2,
    preprocessing_function=preprocess_input)

valid_datagen = ImageDataGenerator(

    rotation_range=5,
    zoom_range=0.1,
    width_shift_range=0.1,
    height_shift_range=0.1,
    horizontal_flip=False,
    vertical_flip=True,
```

```

validation_split=0.2, # Conjutos datos de validación
preprocessing_function=preprocess_input)

train_generator = train_datagen.flow_from_directory(
    train_data_dir,
    target_size=(width_shape, height_shape),
    batch_size=batch_size,
    #save_to_dir='',
    subset='training',
    class_mode='categorical')

validation_generator = valid_datagen.flow_from_directory(
    validation_data_dir,
    target_size=(width_shape, height_shape),
    batch_size=batch_size,
    #save_to_dir='',
    subset='validation',
    class_mode='categorical')

#Imprimir 10 imagenes del generador de entrenamiento
plt.figure(figsize=(15, 15))
for image, etiqueta in train_generator:
    for i in range(10):
        plt.subplot(5,5,i+1)
        plt.xticks([])
        plt.yticks([])
        #plt.savefig('Patrones de las diferentes clases.jpg',dpi=1000)
        plt.imshow(image[i].astype('uint8'))

    break
plt.show()

```

#### **Anexo 4** Entrenamiento del modelo MobileNet

```
image_input = Input(shape=(width_shape, height_shape, 3))

m_MobileNet = MobileNet(input_tensor=image_input,
include_top=False,weights='imagenet')

last_layer = m_MobileNet.layers[-1].output
x=Flatten(name='flatten')(last_layer)

x=Dense (100, activation='relu', name='fc1')(x)

x=Dropout(0.1)(x)

out=Dense(num_classes, activation='softmax', name='output')(x)

custom_model= Model(image_input, out)

custom_model.summary()

custom_model.compile(loss='categorical_crossentropy',
optimizer='adam',metrics=['accuracy'])

tensorboardDenso = TensorBoard(log_dir='logs/denso')

model_history = custom_model.fit(
    train_generator,
    epochs=epochs,batch_size=32,
    validation_data=validation_generator,callbacks=[tensorboardDens
o])
```

#### **Anexo 5** Grabación del modelo en disco

```
from keras.models import save_model
!mkdir /content/drive/MyDrive/Models

save_model(m_MobileNet,
"/content/drive/MyDrive/Models/SENASA_Mobilnet.h5")
```

## Anexo 6 Gráficas de entrenamiento y validación (accuracy - loss)

```
#Cargar la extension de tensorboard de colab
%load_ext tensorboard

#Ejecutar tensorboard e indicarle que lea la carpeta "logs"
%tensorboard --logdir logs

def plotTraining(hist, epochs, typeData):

    if typeData=="loss":
        plt.figure(1,figsize=(10,5))
        yc=hist.history['loss']
        xc=range(epochs)
        plt.ylabel('Loss', fontsize=24)
        plt.plot(xc,yc,'-r',label='Loss Training')

    if typeData=="accuracy":
        plt.figure(2,figsize=(10,5))
        yc=hist.history['accuracy']
        for i in range(0, len(yc)):
            yc[i]=100*yc[i]
        xc=range(epochs)
        plt.ylabel('Accuracy (%)', fontsize=24)
        plt.plot(xc,yc,'-r',label='Accuracy Training')

    if typeData=="val_loss":
        plt.figure(1,figsize=(10,5))
        yc=hist.history['val_loss']
        xc=range(epochs)
        plt.ylabel('Loss', fontsize=24)
        plt.plot(xc,yc,'--b',label='Loss Validate')

    if typeData=="val_accuracy":
        plt.figure(2,figsize=(10,5))
        yc=hist.history['val_accuracy']
        for i in range(0, len(yc)):
```

```
        yc[i]=100*yc[i]
    xc=range(epochs)
    plt.ylabel('Accuracy (%)', fontsize=24)
    plt.plot(xc,yc,'--b',label='Training Validate')

    plt.rc('xtick',labelsize=24)
    plt.rc('ytick',labelsize=24)
    plt.rc('legend', fontsize=18)
    plt.legend()
    plt.xlabel('Numero de epocas',fontsize=24)
    plt.grid(True)
```

```
plotTraining(model_history,epochs,"loss")
plotTraining(model_history,epochs,"accuracy")
plotTraining(model_history,epochs,"val_loss")
plotTraining(model_history,epochs,"val_accuracy")
```

## Anexo 7 Predicciones

```
from keras.applications.imagenet_utils import preprocess_input,
decode_predictions

from keras.models import load_model

names = ["GRADO 0", "GRADO 1", "GRADO 2", "GRADO 3", "GRADO 4"]

modelt = load_model("/content/drive/MyDrive/SENASA_Mobilnet.h5")

#modelt = custom_vgg_model
# Mediante URL
import requests

imaget_path = "/content/drive/MyDrive/SENASA/GRADO 1/1.jpg"

imaget=cv2.resize(cv2.imread(imaget_path), (width_shape,
height_shape))

xt = np.asarray(imaget)
xt=preprocess_input(xt)
xt = np.expand_dims(xt,axis=0)
preds = modelt.predict(xt)

plt.imshow(cv2.cvtColor(np.asarray(imaget), cv2.COLOR_BGR2RGB))
plt.axis('off')
plt.show()

#print(" "+"-----"+names[np.argmax(preds)]+"-----")
```

## Anexo 8 Matriz de confusión y métricas de desempeño

```
from sklearn.metrics import confusion_matrix, f1_score, roc_curve,
precision_score, recall_score, accuracy_score, roc_auc_score

from sklearn import metrics

from mlxtend.plotting import plot_confusion_matrix

from keras.models import load_model

import numpy as np
```

```

import matplotlib.pyplot as plt

%matplotlib inline

names =["GRADO 0", "GRADO 1","GRADO 2", "GRADO 3", "GRADO 4"]
test_data_dir= '/content/drive/MyDrive/SENASA'

test_datagen =ImageDataGenerator()

test_generator=test_datagen.flow_from_directory(
    test_data_dir,
    target_size= (width_shape, height_shape),
    batch_size=batch_size,
    class_mode='categorical',
    shuffle=False)

custom_Model=load_model ("/content/drive/MyDrive/SENASA_Mobilnet.h5"
)

predictions=custom_Model.predict(test_generator)

y_pred= np.argmax(predictions, axis=1)
print(y_pred)
y_real= test_generator.classes
print(y_real)

matc=confusion_matrix(y_real, y_pred)

plot_confusion_matrix(conf_mat=matc,
figsize=(10,10),show_normed=False )

plt.tight_layout()

#print(metrics.classification_report(y_real, y_pred, digits=4) )

```

**Anexo 9** Panel fotográfico

1. seleccionando plantas a estudiar



2. tomando fotografías a plantas seleccionadas



3. transcribiendo información obtenida



4. Obtención y recolección de data



Anexo 10 Declaración Jurada de no Plagio

**UNIVERSIDAD NACIONAL DE JAÉN**  
Ley de Creación N° 29304  
Universidad Licenciada con Resolución del Consejo Directivo N° 002-2018-SUNEDU/CD

**FORMATO 04: DECLARACIÓN JURADA DE NO PLAGIO**

Yo, Naili Dlonnar Dieza Peña,  
identificado con DNI N° 70417016, estudiante de la Escuela Profesional de  
Ingeniería Forestal y Ambiental  
de la Universidad Nacional de Jaén; declaro bajo juramento que soy autor del **Trabajo de investigación:**  
Estimación de Severidad de Roya del café en  
Sistemas agroforestales, utilizando Deep Learning en  
las provincias de Jaén y San Ignacio, Departamento de Cajamarca, 2023.

1. El mismo que presento para optar: ( ) Grado Académico de Bachiller  Título Profesional
2. El **Trabajo de investigación** no ha sido plagiado ni total ni parcialmente, para la cual se han respetado las normas internacionales de citas y referencias para las fuentes consultadas.
3. El **Trabajo de investigación** presentado no atenta contra derechos de terceros.
4. El **Trabajo de investigación** no ha sido publicado ni presentado anteriormente para obtener algún grado académico previo o título profesional.
5. Los datos presentados en los resultados son reales, no han sido falsificados, ni duplicados, ni copiados. Por lo expuesto, mediante la presente asumo toda responsabilidad que pudiera derivarse por la autoría, originalidad y veracidad del contenido del **Trabajo de investigación**, así como por los derechos sobre la obra y/o invención presentada. Asimismo, por la presente me comprometo a asumir además todas las cargas pecuniarias que pudieran derivarse para la UNJ en favor de terceros por motivo de acciones, reclamaciones o conflictos derivados del incumplimiento de lo declarado o las que encontraren causa en el contenido del **Trabajo de investigación**.

De identificarse fraude, piratería, plagio, falsificación o que el trabajo de investigación haya sido publicado anteriormente; asumo las consecuencias y sanciones civiles y penales que de mi acción se deriven.

Jaén, 18 de 09 del 2024

  
Firma  Huella Digital 

FORMATO 04: DECLARACIÓN JURADA DE NO PLAGIO

Yo, Sherson Smith Herrera Zamora,  
identificado con DNI N° 60910152, estudiante de la Escuela Profesional de  
Ingeniería Forestal y Ambiental  
de la Universidad Nacional de Jaén; declaro bajo juramento que soy autor del Trabajo de

**investigación:**

Estimación de severidad de Roya del café en sistemas  
agroforestales, utilizando Deep Learning en las provincias de  
Jaén y San Ignacio, Departamento de Cajamarca, 2023.

1. El mismo que presento para optar: ( ) Grado Académico de Bachiller (X) Título Profesional
2. El **Trabajo de investigación** no ha sido plagiado ni total ni parcialmente, para la cual se han respetado las normas internacionales de citas y referencias para las fuentes consultadas.
3. El **Trabajo de investigación** presentado no atenta contra derechos de terceros.
4. El **Trabajo de investigación** no ha sido publicado ni presentado anteriormente para obtener algún grado académico previo o título profesional.
5. Los datos presentados en los resultados son reales, no han sido falsificados, ni duplicados, ni copiados. Por lo expuesto, mediante la presente asumo toda responsabilidad que pudiera derivarse por la autoría, originalidad y veracidad del contenido del **Trabajo de investigación**, así como por los derechos sobre la obra y/o invención presentada. Asimismo, por la presente me comprometo a asumir además todas las cargas pecuniarias que pudieran derivarse para la UNJ en favor de terceros por motivo de acciones, reclamaciones o conflictos derivados del incumplimiento de lo declarado o las que encontraren causa en el contenido del **Trabajo de investigación**.

De identificarse fraude, piratería, plagio, falsificación o que el trabajo de investigación haya sido publicado anteriormente; asumo las consecuencias y sanciones civiles y penales que de mi acción se deriven.

Jaén, 18 de 09 del 2024.



Firma - Huella Digital

Anexo 11 Compromiso del Asesor

**UNIVERSIDAD NACIONAL DE JAÉN**  
Ley de Creación N° 29304  
Universidad Licenciada con Resolución del Consejo Directivo N° 002-2018-SUNEDU/CD

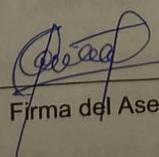
**FORMATO 01: COMPROMISO DEL ASESOR**

El que suscribe, Candy Leobeth Ocaña Zúñiga  
Con Profesión/Grado de Ingeniero Forestal  
DNI  / Pasaporte ( ) / Carnet de extranjería ( ) N° 44798819  
con conocimiento del Reglamento General de Grado Académico y Título Profesional de la  
Universidad Nacional de Jaén, se compromete y deja constancia de las orientaciones al  
Estudiante/Egresado o Bachiller Naili Damar Cieza Peña y Sherson Esmita Herrera Zamora  
de la Escuela profesional de Ingeniería Forestal y Ambiental  
en la formula y ejecución del:

( ) Plan de Trabajo de Investigación    ( ) Informe Final de Trabajo de Investigación  
( ) Proyecto de Tesis                       Informe Final de Tesis  
( ) Informe Final del Trabajo por Suficiencia Profesional

Por lo indicado doy testimonio y visto bueno que el asesorado a ejecutado el trabajo de  
investigación; por lo que en fe a la verdad suscribo la presente

Jaén, 09 de 09 de 2024.

  
Firma del Asesor

UNIVERSIDAD NACIONAL DE JAÉN

Ley de Creación N° 29304

Universidad Licenciada con Resolución del Consejo Directivo N° 002-2018-SUNEDU/CD

FORMATO 01: COMPROMISO DEL ASESOR

El que suscribe, ... LENIN QUINONES HUATANBARI .....

Con Profesión/Grado de Licenciado en Matemáticas .....

DNI (X) / Pasaporte ( ) / Carnet de extranjería ( ) N° 42827048 .....

con conocimiento del Reglamento General de Grado Académico y Título Profesional de la

Universidad Nacional de Jaén, se compromete y deja constancia de las orientaciones al

Estudiante/Egresado o Bachiller Naili Dymar Cieza Peña y Skerson Esmita Herrera Zamora

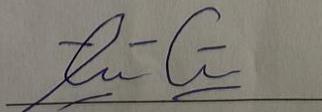
de la Escuela profesional de Ingeniería forestal y Ambiental .....

en la formula y ejecución del:

- ( ) Plan de Trabajo de Investigación      ( ) Informe Final de Trabajo de Investigación  
( ) Proyecto de Tesis                      (X) Informe Final de Tesis  
( ) Informe Final del Trabajo por Suficiencia Profesional

Por lo indicado doy testimonio y visto bueno que el asesorado a ejecutado el trabajo de investigación; por lo que en fe a la verdad suscribo la presente

Jaén, 09 de 09 de 2024

  
Firma del Asesor