



UNAP



FACULTAD DE INGENIERÍA DE SISTEMAS E INFORMÁTICA

**MAESTRÍA EN INGENIERÍA DE SISTEMAS CON MENCIÓN EN
GERENCIA DE LA INFORMACIÓN Y GESTIÓN DE SOFTWARE**

TESIS

**CLASIFICACIÓN DE ESPECIES DE ÁRBOLES FORESTALES
AMAZÓNICOS A PARTIR DE HOJAS UTILIZANDO UN
MODELO HÍBRIDO DE APRENDIZAJE
AUTOMÁTICO SUPERVISADO**

**PARA OPTAR EL GRADO ACADÉMICO DE MAESTRO EN INGENIERÍA
DE SISTEMAS CON MENCIÓN EN GERENCIA DE LA INFORMACIÓN Y
GESTIÓN DE SOFTWARE**

PRESENTADO POR: RODOLFO CARDENAS VIGO

**ASESORES: ING. ELECTR. ERWIN JUNGER DIANDERAS CAUT, MSC
ING. IND. CARLOS ALBERTO GARCIA CORTEGANO, DR.**

IQUITOS, PERÚ

2024



UNAP



FACULTAD DE INGENIERÍA DE SISTEMAS E INFORMÁTICA

**MAESTRÍA EN INGENIERÍA DE SISTEMAS CON MENCIÓN EN
GERENCIA DE LA INFORMACIÓN Y GESTIÓN DE SOFTWARE**

TESIS

**CLASIFICACIÓN DE ESPECIES DE ÁRBOLES FORESTALES
AMAZÓNICOS A PARTIR DE HOJAS UTILIZANDO UN
MODELO HÍBRIDO DE APRENDIZAJE
AUTOMÁTICO SUPERVISADO**

**PARA OPTAR EL GRADO ACADÉMICO DE MAESTRO EN INGENIERÍA
DE SISTEMAS CON MENCIÓN EN GERENCIA DE LA INFORMACIÓN Y
GESTIÓN DE SOFTWARE**

PRESENTADO POR: RODOLFO CARDENAS VIGO

**ASESORES: ING. ELECTR. ERWIN JUNGER DIANDERAS CAUT, MSC.
ING. IND. CARLOS ALBERTO GARCIA CORTEGANO, DR.**

IQUITOS, PERÚ

2024



UNAP

Escuela de Postgrado

"Oficina de Asuntos

Académicos"



ACTA DE SUSTENTACIÓN DE TESIS

N°039-2024-OAA-EPG-UNAP

En Iquitos en la Escuela de Postgrado (EPG) de la Universidad Nacional de la Amazonía Peruana (UNAP) a los veintiséis días del mes de marzo de 2024 a las 11:00 a.m, se dió inicio a la sustentación de la tesis denominada "CLASIFICACIÓN DE ESPECIES DE ÁRBOLES FORESTALES AMAZÓNICOS A PARTIR DE HOJAS UTILIZANDO UN MODELO HÍBRIDO DE APRENDIZAJE AUTOMÁTICO SUPERVISADO", aprobado con Resolución Directoral N°0453-2024-EPG-UNAP, presentado por el egresado **RODOLFO CARDENAS VIGO**, para optar el **Grado Académico de Maestro en Ingeniería de Sistemas con mención en Gerencia de la Información y Gestión de Software**, que otorga la UNAP de acuerdo a la Ley Universitaria 30220 y el Estatuto de la UNAP.

El jurado calificador designado mediante Resolución Directoral N°0284-2024-EPG-UNAP, esta conformado por los profesionales siguientes:

Ing. Electr. Alejandro Reátegui Pezo, Dr.	(Presidente)
Ing. Fores. José Antonio Escobar Díaz, Dr.	(Miembro)
Ing. Sist. José Edgar García Díaz, Mgr.	(Miembro)

Después de haber escuchado la sustentación y luego de formuladas las preguntas, éstas fueron respondidas: CORRECTAMENTE

Finalizado la evaluación; se invitó al público presente y al sustentante abandonar el recinto; y, luego de una amplia deliberación por parte del jurado, se llegó al resultado siguiente:

La sustentación pública y la tesis ha sido: APROBADO con calificación MUY BUENO

A continuación, el Presidente del Jurado da por concluida el sustentación, siendo las 11:20 del veintiséis de marzo de 2024; con lo cual, se le declara al sustentante APTO, para recibir **Grado Académico de Maestro en Ingeniería de Sistemas con mención en Gerencia de la Información y Gestión de Software**.

Ing. Electr. Alejandro Reátegui Pezo, Dr.
Presidente

Ing. Fores. José Antonio Escobar Díaz, Dr.
Miembro

Ing. Sist. José Edgar García Díaz, Mgr.
Miembro

Ing. Electr. Erwin Junger Dianderas Caut, MSc.
Asesor

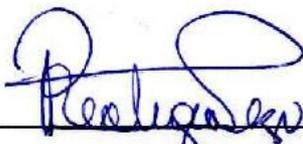
Ing. Ind. Carlos Alberto García Cortegano, Dr.
Asesor

Somos la Universidad licenciada más importante de la Amazonía del Perú, rumbo a la acreditación

Calle Los Rosales cuadra 5 s/n, San Juan Bautista, Maynas, Perú
Celular: 953 664 439 - 956 875 744
Correo electrónico: postgrado@unapiquitos.edu.pe www.unapiquitos.edu.pe



TESIS APROBADA EN SUSTENTACIÓN PÚBLICA EL 26 DE MARZO DEL 2024, EN LA ESCUELA DE POSTGRADO DE LA UNIVERSIDAD NACIONAL DE LA AMAZONÍA PERUANA, EN LA CIUDAD DE IQUITOS-PERÚ.



ING. ELECTR. ALEJANDRO REATEGUI PEZO, DR.
PRESIDENTE



ING. SIST. JOSÉ EDGAR GARCÍA DÍAZ, MGR.
MIEMBRO



ING. FORES. JOSÉ ANTONIO ESCOBAR DÍAZ, DR.
MIEMBRO



ING. ELECTR. ERWIN JUNGER DIANDERAS CAUT, MSC.
ASESOR



ING. IND. CARLOS ALBERTO GARCIA CORTEGANO, DR.
ASESOR

NOMBRE DEL TRABAJO

**EPG_MAESTRÍA_TESIS_CARDENAS VIG
O.pdf**

AUTOR

RODOLFO CARDENAS VIGO

RECuento de palabras

10361 Words

RECuento de caracteres

57705 Characters

RECuento de páginas

58 Pages

Tamaño del archivo

1.1MB

Fecha de entrega

Dec 15, 2023 7:39 PM GMT-5

Fecha del informe

Dec 15, 2023 7:40 PM GMT-5

● **13% de similitud general**

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

- 11% Base de datos de Internet
- Base de datos de Crossref
- 9% 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 10 palabras)

A Dios por su amor, fuerza y guía. A mi familia por su apoyo inquebrantable, especialmente a mi esposa, padres y pastores de la Iglesia Cuadrangular de Iquitos, por alentarme a alcanzar esta meta.

AGRADECIMIENTO

Expreso de manera especial mi agradecimiento a Dios, por su amor infinito, por ser mi guía constante y darme la fuerza necesaria para alcanzar este logro.

A mi familia, por su apoyo inquebrantable y por ser mi pilar en todo momento. Especialmente, a mi querida esposa y a mis padres, cuyo amor y sacrificio han sido fundamentales en este camino. A los pastores de la Iglesia Cuadrangular de Iquitos, por su continuo aliento y por motivarme a alcanzar esta meta.

A mis asesores Ing. Electr. Erwin Junger Dianderas Caut, Msc. y Ing. Ind. Carlos Alberto Garcia Cortegano, Dr., por su invaluable orientación y conocimiento Durante todo el proceso de investigación.

Al Consejo Nacional de Ciencia, Tecnología e Innovación Tecnológica (CONCYTEC) y al Programa Nacional de Investigación Científica y Estudios Avanzados – PROCIENCIA, que financio el presente trabajo en el marco del proyecto “Sistema de reconocimiento offline y online de las 30 especies forestales maderables vulnerables ante la tala ilegal, y de mayor importancia económica y ecológica, mediante algoritmos de aprendizaje de máquina y cloud computing como propuesta para mejorar el Plan de Manejo Forestal de las empresas del sector forestal maderero - Caso de estudio: Región Loreto” (Numero de contrato 052-2021-FONDECYT).

ÍNDICE DE CONTENIDO

	Páginas
Carátula	i
Contracarátula	ii
Acta de sustentación	iii
Jurado	iv
Resultado del informe de similitud	v
Dedicatoria	vi
Agradecimiento	vii
Índice de contenido	viii
Índice de tablas	x
Índice de figuras	xi
Resumen	xii
Abstract	xiii
INTRODUCCIÓN	1
CAPÍTULO I: MARCO TEÓRICO	3
1.1. Antecedentes	3
1.2. Bases teóricas	5
1.3. Definición de términos básicos	9
CAPÍTULO II: VARIABLES E HIPÓTESIS	11
2.1. Variables y su operacionalización	11
2.2. Formulación de hipótesis	12
CAPÍTULO III: METODOLOGÍA	13
3.1. Tipo y Diseño de la investigación	13
3.2. Población y muestra	14
3.3. Técnicas e instrumentos	15
3.4. Procedimientos de recolección de datos	15
3.5. Técnicas de procesamientos y análisis de los datos	16
3.6. Aspectos éticos	16
CAPÍTULO IV: RESULTADOS	17
CAPÍTULO V: DISCUSIÓN DE LOS RESULTADOS	50
CAPÍTULO VI: PROPUESTA	52
CAPÍTULO VII: CONCLUSIONES	54
CAPÍTULO VIII: RECOMENDACIONES	56
CAPÍTULO IX: REFERENCIAS BIBLIOGRÁFICAS	57
ANEXOS	
- 1. Matriz de consistencia	
- 2. Tabla de operacionalización de variables	
- 3. Instrumentos de recolección de datos	
- 4. Arquitectura de las redes neuronales	
- 5. Curvas de entrenamiento de modelos de CNN	
- 6. Matriz de confusión del dataset de pruebas	

- 7. Código fuente para el procesamiento del datasets
- 8. Código fuente para ejecutar la predicción del modelo híbrido

ÍNDICE DE TABLAS

	Páginas	
Tabla N° 01	Lista de dispositivos celulares utilizados para generación de imágenes de hojas de árboles forestales amazónicos	17
Tabla N° 02	Lista de especies con el tipo de dispositivo celular y el total de imágenes por cada especie	18
Tabla N° 03	Tabla de cantidad de imágenes por datasets	30
Tabla N° 04	Resumen de la cantidad de imágenes a nivel de especie y cámaras después de procesar	30
Tabla N° 05	Configuración de parámetros de los modelos de CNN.	40
Tabla N° 06	Resultados de entrenamiento de los modelos CNN	41
Tabla N° 07	Cantidad de características que se extrae en cada modelo de CNN	41
Tabla N° 08	Resultados de entrenamiento de SVM	43
Tabla N° 09	Resultados de entrenamiento de LR	44
Tabla N° 10	Resultados de la prueba de los algoritmos CNN y Machine learning	45

ÍNDICE DE FIGURAS

	Páginas	
Figura N°01	Ubicación de recolectas de imágenes de hojas de árboles en pie	17
Figura N°02	Muestra del resultado de eliminación de fondo de una imagen de hoja	26
Figura N° 03	Muestra del resultado de extracción de píxeles de contornos de la imagen de una hoja	27
Figura N° 04	Muestra del resultado de redimensión de la imagen de una hoja	28
Figura N° 05	Muestra del resultado de selección de la imagen "envés" de una hoja	29
Figura N° 06	Muestra del resultado de rotación de la imagen de una hoja	29
Figura N° 07	Arquitectura lógica de modelo híbrido	39
Figura N° 08	Matriz de confusión de modelo híbrido MobileNet+LR	47

RESUMEN

La pérdida de biodiversidad y actos delictivos como consecuencia de la falta de monitoreo y control, están estrechamente vinculadas a la escasa tecnología y limitada oferta de herramientas que apoyen las actividades de identificación de las especies de biodiversidad presentes en el territorio, principalmente existen dificultades para la identificación y clasificación de especies de árboles forestales en la Amazonía. Es por ello, que el objetivo de la presente investigación ha sido el desarrollo e implementación de una solución basada en el uso de Inteligencia Artificial en la línea de investigación del reconocimiento de imágenes, que ha resultado en un modelo híbrido de aprendizaje automático supervisado, que facilita la clasificación de hasta 40 especies de árboles forestales amazónicos del Perú. Se ha realizado una comparación entre distintos modelos de algoritmos de redes neuronales convolucionales (CNN) y algoritmos de clasificación como máquina de vectores (SVM) y regresión logística (LR), teniendo como base, un conjunto de imágenes de hojas procesadas de 40 especies de árboles de importancia forestal. Los resultados más destacados, señalan como la mejor solución al modelo híbrido usando el modelo CNN MobileNet y el algoritmo de Regresión Logística (LR), concluyendo que este modelo alcanza índices altos en las principales métricas como Precisión, Sensibilidad, Especificidad y F1-score, siendo su promedio de rendimiento del modelo de 99%, que demuestra su eficiencia para este caso de clasificación, que usa imágenes de hojas para identificar especies de árboles forestales amazónicos.

Palabras clave: Árboles forestales, MobileNet, Regresión Logística, Aprendizaje automático híbrido

ABSTRACT

The loss of biodiversity and criminal acts as a consequence of the lack of monitoring and control are closely linked to the scarce technology and limited supply of tools that support the activities of identification of the species of biodiversity present in the territory, mainly there are difficulties for the identification and classification of species of forest trees in the Amazon. For this reason, the objective of this research has been the development and implementation of a solution based on the use of Artificial Intelligence in the research line of image recognition, which has resulted in a hybrid model of supervised machine learning, which facilitates the classification of up to 40 species of Amazonian forest trees in Peru. A comparison has been made between different models of convolutional neural network (CNN) algorithms and classification algorithms such as vector machine (SVM) and logistic regression (LR), based on a set of processed leaf images of 40 species of trees of forest importance. The most outstanding results point to the hybrid model using the CNN MobileNet model and the Logistic Regression (LR) algorithm as the best solution, concluding that this model achieves high rates in the main metrics such as Accuracy, Sensitivity, Specificity and F1-score, being its average model performance 99%, which demonstrates its efficiency for this classification case, which uses leaf images to identify Amazonian forest tree species.

Keywords: Forest Trees, MobileNet, Logistic Regression, Hybrid Machine Learning

INTRODUCCIÓN

La preservación de los bosques en el mundo representa una de las principales necesidades que abordar para la permanencia de la vida en la tierra, teniendo como principal rol, ayudar a mantener la regulación del clima, equilibrio de los ecosistemas, contribución al ciclo del agua, entre otros. ⁽¹⁾

En la Amazonía peruana se estima que existen aproximadamente 2,500 especies forestales, de las cuales sólo están debidamente reconocidas cerca de 600 especies ⁽²⁾. La falta de información y herramientas adecuadas dificulta enormemente el reconocimiento de las especies y sus características morfológicas, ecológicas y silviculturales. Los bosques amazónicos son ricos en biodiversidad y son parte integral de la cultura y el sustento de las comunidades indígenas y locales que habitan en la Amazonía ⁽³⁾

En el caso particular del Sector forestal, la identificación incorrecta de los árboles está asociada a problemas delictivos como: blanqueo de madera, tráfico ilegal de árboles, extinción de especies forestales de poco conocimiento, deforestación y tala ilegal. Sin embargo, históricamente la identificación científica de especies forestales ha estado a cargo de especialistas botánicos, biólogos o profesionales afines, sin embargo, a medida que la tecnología ha avanzado, la legislación y las demandas comerciales también han requerido exigir entre sus procesos la apropiada identificación de dichas especies ⁽⁴⁾. Es por ello que, sumado a la falta de especialistas y la necesidad de identificación rápida y precisa de especies arbóreas, se ha impulsado la búsqueda de métodos automatizados y precisos para la clasificación de especies de árboles forestales a partir de características de hojas. En este contexto, las hojas son una de las partes más utilizadas en la identificación de los árboles debido a su disponibilidad y facilidad para ser almacenadas en los herbarium. Sin embargo, la identificación basada en las características de las hojas puede ser una tarea complicada debido a la similitud en las características de hojas de diferentes especies forestales.

En la actualidad, se han desarrollado diversas herramientas informáticas para facilitar la identificación de árboles a partir de las características de imágenes

de sus hojas. Los avances tecnológicos en el campo de la inteligencia artificial han permitido el desarrollo de algoritmos de redes neuronales convolucionales (CNN) que son los mejores según el estado de arte para la extracción de características de imágenes ⁽⁵⁾, incluyendo imágenes de hojas de árboles ⁽⁶⁾. Por otro lado, los algoritmos de máquinas de vectores de soporte (SVM) y regresión logística (LR) han demostrado ser más robustos en la clasificación de características similares ⁽⁷⁾. La combinación de ambos tipos de algoritmos ha demostrado su eficacia en estudios previos ⁽⁸⁾⁽⁹⁾⁽⁷⁾, que alcanzaron una alta precisión superior a entre los 96% al 99% para clasificar las hojas, que en estos modelos es una tasa bastante confiable.

Por lo que en esta investigación se formuló la siguiente pregunta de investigación ¿En qué medida la clasificación de especies de árboles forestales amazónicos a partir de características de hojas se mejorará utilizando un modelo híbrido de aprendizaje automático supervisado?

Así mismo se tuvo como objetivo: Desarrollar e implementar un modelo híbrido de aprendizaje automático supervisado para clasificar especies de árboles forestales amazónicos utilizando características de hojas. Y como objetivos específicos incrementar los índices de sensibilidad, especificidad, precisión y F1-Score en la clasificación de especies de árboles forestales amazónicos.

CAPÍTULO I: MARCO TEÓRICO

1.1. Antecedentes

En el 2023, se propone un enfoque que implica el procesamiento de la hoja para extraer características como la imagen refinada en color, imagen de vena, histograma de proyección XY, forma artesanal, características de textura y descriptores de Fourier. Estos atributos se transforman mediante codificadores basados en redes neuronales y se utiliza un modelo de máquinas de vectores de soporte (SVM) para clasificar las hojas. El enfoque propuesto para la clasificación de hojas logró una precisión del 99.58%, superando los métodos actuales de última generación, y es aplicable a otras tareas que carecen de datos o recursos de cómputo. ⁽⁹⁾

En el 2022, un estudio analítico proporcionó diversos métodos utilizados en el procesamiento de imágenes para el reconocimiento de plantas a través de sus hojas. El artículo revisa diferentes técnicas utilizadas por investigadores que consideran diferentes características y clasificadores. El análisis muestra que tanto las Máquinas de Vector de Soporte (SVM) como la Red Neural Convolutiva (CNN) son positivamente dominantes entre otros métodos en términos de precisión. Por lo tanto, el trabajo concluye que la SVM y la CNN son los métodos más efectivos para el reconocimiento de hojas vegetales. ⁽⁵⁾

En el 2021, presenta un conjunto de datos de imágenes de hojas de diez especies de la selva amazónica peruana. Proponen una solución de software de extremo a extremo para automatizar el proceso de identificación de especies. La propuesta incluye un algoritmo de eliminación de fondo para alimentar una CNN previamente entrenada por el conjunto de datos ImageNet. Los resultados muestran una precisión de entrenamiento de 96.64% y una precisión de prueba de 96.52% en el modelo VGG-19. La interpretación visual del modelo evidencia que las

venaciones de hojas tienen la mayor correlación en la tarea de reconocimiento de plantas. ⁽¹⁰⁾

En el 2021, se propone un sistema automatizado para identificar y clasificar especies vegetales mediante técnicas de aprendizaje automático. El artículo discute los desafíos que enfrentan los botánicos en la identificación y clasificación de especies vegetales debido a su gran número y alta similitud entre algunas especies. El sistema propuesto implica el preprocesamiento, segmentación, extracción de características y clasificación de imágenes de hojas usando varios algoritmos de aprendizaje automático como Máquina de vectores de soporte (SVM), K-vecino más cerca (K-NN) y Bosque Aleatorio (RF). La precisión de estos algoritmos fue comparada, teniendo como resultados: k-NN con una precisión del 84%, SVM con un 88% y RF con un 90%. ⁽¹¹⁾

En el 2021, un trabajo de investigación compara los métodos tradicionales de reconocimiento de imágenes de las hojas de plantas con modelos de aprendizaje profundo, que funcionan mejor debido a su capacidad para explorar características detalladas de la imagen y tienen una alta precisión de reconocimiento. Y menciona que las redes neuronales convolucionales son los modelos de aprendizaje profundo más efectivos en este campo. ⁽⁶⁾

En 2019, propone un modelo de Red Neural Convolutiva (CNN) basado en Deep Learning llamado AyurLeaf para la clasificación de plantas medicinales utilizando características foliares como forma, tamaño, color, textura, etc. El modelo propuesto logró una precisión de clasificación de 96.76% en el conjunto de datos AyurLeaf tras la validación de 5 cruces. La clasificación se realiza utilizando clasificadores Softmax y SVM. ⁽⁸⁾

En el 2019, se presenta un enfoque novedoso para el reconocimiento de especies vegetales utilizando un enfoque de arquitectura dual de

aprendizaje profundo (DenseNet). La metodología propuesta utiliza arquitecturas MobileNet y Densenet-121 como extractores de características y clasificadores de aprendizaje automático como análisis discriminante lineal, regresión logística multinomial (LR), Naive Bayes, árbol de clasificación y regresión, vecino k más cercano, clasificador de bosque aleatorio, clasificador de embolsado y perceptrón multicapa para clasificación. El enfoque se prueba en conjuntos de datos estándar (Flavia, Folio y Hoja sueca) y recopilados a medida (Leaf-12). La arquitectura DenseNet con clasificador LR produjo las mayores precisiones de 98.71%, 96.38%, 99.41% y 99.39% para conjuntos de datos Flavia, Folio, Swedish leaf y Leaf-12, respectivamente. ⁽⁷⁾

1.2. Bases teóricas

1.2.1. Aprendizaje automático

“El aprendizaje automático estudia la construcción de modelos capaces de aprender ciertas estructuras a partir de la información proporcionada por los datos. Es decir, el aprendizaje automático se centra en encontrar patrones en los datos de tal forma que podamos usar dichos patrones en puntos que no han sido observados previamente”. ⁽¹²⁾

1.2.2. Aprendizaje supervisado

“El aprendizaje supervisado se centra en el desarrollo, a partir de un conjunto de datos conocido, de un modelo matemático capaz de predecir el valor correspondiente de un nuevo dato. En el aprendizaje supervisado asumimos como conocido el llamado conjunto de entrenamiento (*training sample*). Cada dato de dicho conjunto está formado por las variables explicativas o conjunto de características (*features*) y la variable respuesta”. ⁽¹²⁾

Las aplicaciones del aprendizaje supervisado abarcan diversas áreas existiendo dos tipos principales de la misma:

- Clasificación: Se puede utilizar el aprendizaje supervisado para clasificar datos en diferentes categorías o clases. Por ejemplo, clasificar correos electrónicos como spam o no spam, clasificar imágenes en diferentes objetos o clasificar pacientes en grupos de diagnóstico médico. ⁽¹²⁾
- Regresión: El aprendizaje supervisado también se utiliza para predecir o estimar valores numéricos. Por ejemplo, predecir el precio de una vivienda en función de sus características, estimar el rendimiento de un vehículo según sus especificaciones técnicas, etc. ⁽¹²⁾

1.2.2.1. Redes neuronales

“Una red neuronal es un modelo computacional inspirado en el funcionamiento del cerebro humano. Se utiliza para procesar información y resolver problemas complejos de manera eficiente. Está compuesta por un conjunto interconectado de unidades básicas llamadas neuronas o nodos, que trabajan en conjunto para realizar tareas de aprendizaje automático”. ⁽¹³⁾

1.2.2.2. Máquinas de vectores de soporte (SVM)

Es un tipo de algoritmo de aprendizaje automático supervisado utilizado para la clasificación y regresión de datos. Su objetivo principal es encontrar un hiperplano en un espacio dimensional superior que permita separar los datos de diferentes clases de manera óptima. En términos más simples, las SVM buscan encontrar la mejor forma de dividir o clasificar conjuntos de datos en grupos distintos, utilizando una función de decisión basada en un conjunto de características. Estas características pueden ser numéricas o categóricas, y las SVM intentan encontrar el límite de

decisión más óptimo para separar las diferentes clases de datos.
(14)

1.2.2.3. Aprendizaje profundo

“El aprendizaje profundo es un subconjunto del aprendizaje automático basado en redes neuronales artificiales. El proceso de aprendizaje se llama profundo porque la estructura de redes neuronales artificiales se compone de varias capas de entrada, salida y ocultas. Cada capa contiene unidades que transforman los datos de entrada en información que la capa siguiente puede usar para realizar una tarea de predicción determinada. Gracias a esta estructura, una máquina puede aprender a través de su propio procesamiento de datos”.⁽¹⁵⁾

1.2.2.4. Redes convolucionales (CNN)

“La CNN es un tipo de Red Neuronal Artificial que procesa sus capas imitando corteza visual del cerebro humano para identificar distintas características en las entradas. Para ello, la CNN contiene varias capas ocultas especializadas y con una jerarquía: esto significa que las primeras capas detectan propiedades o formas básicas y se van especializando hasta llegar a capas más profundas capaces de reconocer formas complejas como un rostro o una silueta. La red neuronal por sí misma ha de reconocer una gran cantidad de imágenes para que la pueda captar las características únicas de cada objeto y a su vez poder generalizarlo. Cada imagen se trata de una matriz de píxeles cuyo valor va de 0 a 255 pero se normaliza para la red neuronal de 0 a 1”.⁽¹⁶⁾

1.2.2.4.1. Aprendizaje por transferencia (Transfer learning)

Es una técnica de aprendizaje automático profundo que aprovecha el conocimiento adquirido al entrenar un modelo de red neuronal en una tarea específica para mejorar el rendimiento en otra tarea relacionada. Esto se logra mediante un reentrenamiento más eficiente en términos de tiempo y datos, lo que permite adaptar el conocimiento previo del modelo a una nueva tarea con menor costo computacional y de recursos. ⁽¹⁷⁾

1.2.2.4.2. Métricas de Evaluación

Las métricas de rendimiento se utilizan para mejorar los modelos de clasificación ya que puede haber falsas predicciones, subajustes y sobreajustes. Entre las métricas de rendimiento está la exactitud, precisión, métrica de exhaustividad (Recall) y F1_Score. Todas estas métricas se obtienen de Scikit-learn la cual es una herramienta con algoritmos de aprendizaje de *Machine Learning* que ayudan en el momento de evaluar el modelo de red neuronal. ⁽¹⁸⁾

1.2.3. Identificación de especies de árboles forestales amazónicos

“Se ha señalado que la identificación de las especies forestales es un requisito indispensable en el planeamiento, desarrollo y ejecución de casi todas las labores taxonómicas, jugando un papel importante, tanto en el plan de aprovechamiento integral de los bosques como en la comercialización de productos forestales. Todas las labores forestales están directa o indirectamente relacionadas con la identificación de las especies vegetales. Existen varios métodos utilizados, los métodos más comunes son: Análisis morfológico, Clave de identificación, Análisis genético, Análisis de huellas digitales químicas, Tecnologías de imágenes”. ⁽¹⁹⁾

1.2.3.1. Análisis morfológico de las hojas

“La identificación de las características morfológicas de las hojas permite distinguir y clasificar estas especies, lo que contribuye a la comprensión de la diversidad vegetal y la conservación de los ecosistemas amazónicos”.⁽²⁰⁾

“La calidad morfológica de una planta hace referencia a un conjunto de caracteres, tanto de naturaleza cualitativa como cuantitativa, sobre la forma y estructura de la planta. Algunas características morfológicas de las hojas que se utilizan en el análisis incluyen: Forma, Margen, Venación, Textura y Color”.⁽²¹⁾

1.3. Definición de términos básicos

- **Modelo híbrido:** Se refiere a la combinación o integración de diferentes métodos o algoritmos, en este caso, la combinación de dos modelos para la extracción de características y la clasificación de las especies.⁽²²⁾
- **Extracción de características:** Es un proceso de transformar los datos originales en un conjunto de características significativas que faciliten la tarea de clasificación, reconocimiento de patrones y otros análisis.⁽²³⁾
- **Clasificación:** En el aprendizaje de máquina es un proceso en el que un algoritmo aprende a asignar elementos de datos a categorías predefinidas. Se basa en el análisis de patrones y características de los datos para realizar predicciones precisas sobre nuevas muestras no etiquetadas.⁽²⁴⁾
- **Evaluación de modelos:** Incluye medidas de rendimiento como la precisión, la sensibilidad, la especificidad y la matriz de confusión.⁽²⁵⁾

- **Especies de árboles forestales amazónicos:** Se refiere a las diferentes variedades de árboles que se encuentran en la selva amazónica, que es conocida por su alta biodiversidad. ⁽²⁶⁾
- **Matriz de confusión:** Es un conjunto de valores que contabilizan el grado de semejanza entre observaciones emparejadas: un conjunto de datos bajo control (CDC) y un conjunto de datos de referencia (CDR), para los que se ha establecido una clasificación ⁽²⁷⁾
- **Precisión:** La precisión es el reflejo cualitativo del grado con que la exactitud satisface las exigencias de rigor de una medición. Con esta definición podemos entender que es la proporción de predicciones positivas que son correctas. ⁽²⁸⁾
- **Recall:** Recall o sensibilidad es una medida que permite conocer la proporción de casos positivos que fueron correctamente clasificados. En un modelo perfecto el recall es igual a 1 para cada clase. Desde el punto de vista analítico un investigador busca aumentar el recall sin afectar el valor de la accuracy ⁽²⁹⁾
- **F1-Score:** La medida F1-score fusiona las métricas accuracy con recall, presentando diferencias en el rendimiento de un clasificador que no son revelados únicamente con la accuracy. Es directamente proporcional al aumento de las dos medidas. ⁽²⁹⁾

CAPÍTULO II: VARIABLES E HIPÓTESIS

2.1. Variables y su operacionalización

Variable independiente (X): Modelo híbrido de aprendizaje automático supervisado

Es el software desarrollado para la clasificación de especies de árboles forestales, que estará implementado con algoritmos y técnicas de aprendizaje supervisado, en cual se combinan métodos y enfoques para extraer características, aprender patrones y realizar la clasificación o predicción de manera eficiente y precisa.

- **Definición operacional:** Se implementarán diferentes modelos de aprendizaje automático supervisado definidos previa investigación y estado de arte, en la extracción de características y clasificación de las hojas.

- **Indicadores:**
 - Tiempo de entrenamiento
 - Precisión en entrenamiento
 - Perdida en entrenamiento
 - Precisión en validación
 - Perdida en validación

Variable dependiente (Y): Clasificación de especies de árboles forestales amazónicos a partir de las características de hojas

La clasificación de especies de árboles forestales amazónicos a partir de las características de hojas se refiere a la capacidad de identificar y distinguir diferentes especies de árboles en la región amazónica a través del análisis de características específicas de sus hojas.

- **Definición operacional:** Se medirá la tasa de precisión de la clasificación de especies de árboles forestales amazónicos a partir de las características de las hojas. Esta precisión se determinará comparando las etiquetas de especies reales de las hojas con las etiquetas de especies asignadas por el modelo de clasificación.
- **Indicadores:**
 - Índice de Precisión
 - Índice de Sensibilidad
 - Índice de Especificidad
 - F1-Score

2.2. Formulación de la hipótesis

2.2.1. Hipótesis General

Un modelo híbrido de aprendizaje automático supervisado mejora la clasificación de las especies de árboles forestales amazónicos utilizando características de hojas.

2.2.2. Hipótesis específicas

- Si se utiliza el modelo híbrido de aprendizaje automático supervisado incrementa el índice de Precisión en la clasificación de especies de árboles forestales amazónicos.
- Si se utiliza el modelo híbrido de aprendizaje automático supervisado incrementa el índice de sensibilidad en la clasificación de especies de árboles forestales amazónicos.
- Si se utiliza el modelo híbrido de aprendizaje automático supervisado incrementa el índice de Especificidad en la clasificación de especies de árboles forestales amazónicos.
- Si se utiliza el modelo híbrido de aprendizaje automático supervisado incrementa la Métrica F1-score en la clasificación de especies de árboles forestales amazónicos.

CAPÍTULO III: METODOLOGÍA

3.1. Diseño metodológico

- **Tipo de Investigación**

La investigación es experimental del tipo comparativo, dado que el modelo híbrido de aprendizaje automático supervisado busca comparar diferentes modelos de aprendizaje automático supervisado en términos de extracción de características y clasificación de especies de árboles forestales amazónicos. Se analizarán y evaluarán los resultados de cada combinación de modelo para determinar cuál ofrece un mejor rendimiento en la clasificación. Esta combinación de modelos es una intervención o tratamiento que se aplica en el proceso de clasificación.

- **Diseño de la Investigación**

La investigación pertenece al Diseño Experimento Factorial de un solo grupo. Debido a que se busca encontrar la combinación óptima de modelos de aprendizaje automático para obtener mejor desempeño en la clasificación de árboles forestales a partir de las características de las hojas en un solo dataset.

Su esquema es:

	A₁+B₁	O₁
	A₁+B₂	O₂
	A₂+B₁	O₃
G:	A₂+B₂	O₄
	A₃+B₁	O₅
	A₃+B₂	O₆

Donde:

G: Dataset de hojas

A₁₋₆+B₁₋₆: Tratamiento del modelo híbrido aplicando diferentes modelos de aprendizaje para extracción características y clasificación.

O₁₋₆: Medición de los objetos post prueba en cada tratamiento.

A₁: Algoritmo de extracción de características VGG-19.

A₂: Algoritmo de extracción de características MobileNet.

A₃: Algoritmo de extracción de características DenseNet.

B₁: Algoritmo de clasificación SVN.

B₂: Algoritmo de clasificación LR.

3.2. Población y muestra

- **Población:**

La población está conformada por un conjunto de datos (Dataset) de un total de 152,320 imágenes de hojas de 40 especies de árboles forestales. El dataset fue generado por el proyecto “Sistema de reconocimiento offline y online de las 30 especies forestales maderables vulnerables a la tala ilegal, y de mayor importancia económica y ecológica, mediante algoritmos de *machine learning* y *cloud computing* como propuesta de mejora del Plan de Gestión Forestal de las empresas del sector forestal maderable - Caso de estudio: Región Loreto” ejecutado por el Instituto de Investigaciones de la Amazonía Peruana y financiado por FONDECYT.

- **Muestra:**

La investigación se llevó a cabo utilizando una muestra de selección que incluyó un procesamiento de imágenes. Se seleccionaron imágenes específicas del lado envés de las hojas, donde las venas estuvieran claramente visibles. Posteriormente se generó el dataset de entrenamiento, validación y prueba, se aplicó una distribución aleatoria y equitativa para cada clase:

- Entrenamiento 70%
- Validación 20%
- Pruebas 10%

3.3. Técnicas e instrumentos.

- **Técnica de recolección de datos**
 - Observación
- **Instrumento de recolección de datos**
 - Cuaderno de notas
 - Ficha de observación (Ver anexo 3)

3.4. Procedimientos de recolección de datos

Se configuran los entornos de programación para entrenamiento de cada configuración de algoritmo habilitando el reporte de resultados de entrenamiento con los siguientes datos:

- Tiempo de entrenamiento
- Exactitud en entrenamiento
- Pérdida en entrenamiento
- Exactitud en validación
- Pérdida en validación

Se configuran los datos de prueba y se prepara el script de pruebas para generar reporte con los siguientes datos:

- Precisión
- Sensibilidad
- Especificidad
- Métrica F1-Score

3.5. Técnica de Procesamiento y análisis de datos

Los datos se analizarán de acuerdo a los Formatos de Observación de cada uno de los indicadores, junto a la Matriz de confusión (utilizado para modelos de clasificación de aprendizaje automático supervisado), y serán registrados en una Hoja de cálculo Microsoft Excel, el procesamiento y análisis de la información recopilada se llevará a cabo utilizando librerías estadísticas de Python, como NumPy, Pandas y SciPy.

3.6. Aspectos éticos

Basado en los requisitos y condiciones del reglamento de investigación del Consejo Nacional de Ciencia, Tecnología e Innovación Tecnológica (CONCYTEC), a través del Código Nacional de Integridad Científica, para la investigación se tendrán en cuenta los siguientes aspectos éticos (CONCYTEC, 2021):

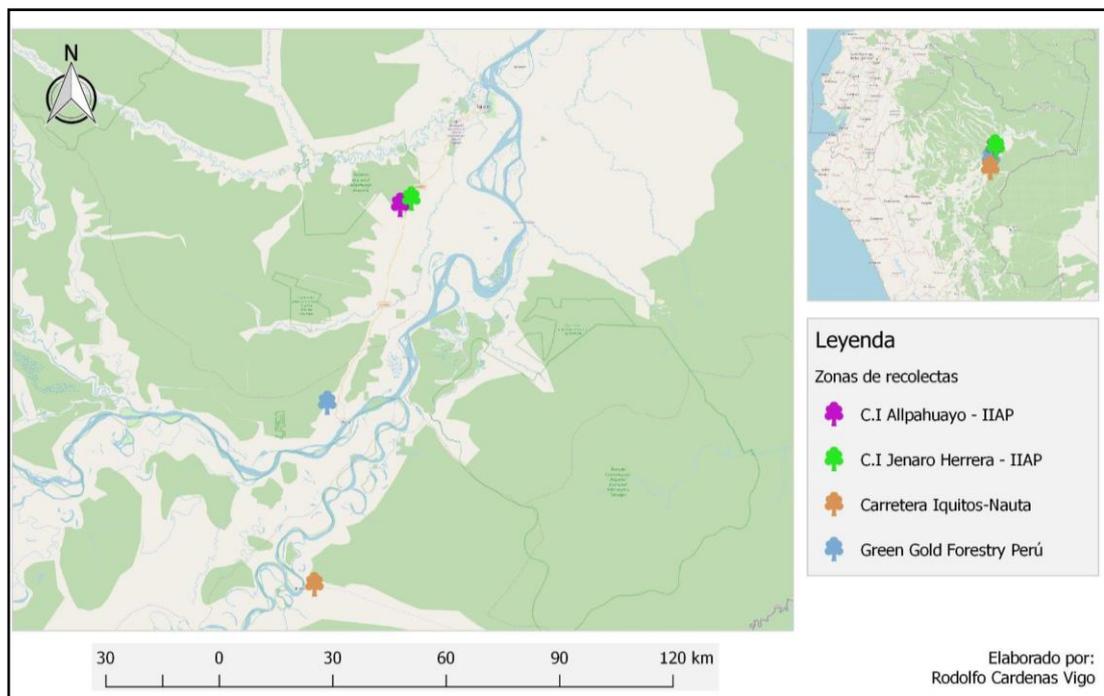
- Honestidad y veracidad en los resultados de la investigación.
- La investigación y sus participantes mantienen su imparcialidad y confidencialidad en la información.
- Transparencia y responsabilidad del tesista en el desarrollo y metodología de la investigación.
- Respeto a los procedimientos y protocolos, antes, durante y después de la investigación

CAPÍTULO IV: RESULTADOS

4.1. PREPARACIÓN DE DATASET

4.1.1. El dataset: está conformado por imágenes de hojas en primer plano recolectadas de 40 tipos especies de árboles forestales maderables en pie en el ámbito de la carretera Iquitos-Nauta, Estación Biológica José Álvarez Alonso (C.I Allpahuayo) del IIAP, Centro de Investigación Jenaro Herrera (CIJH) del IIAP y parcelas permanentes de la empresa Green Gold Forestry Perú.

Figura N° 01. Ubicación de recolectas de imágenes de hojas de árboles en pie



Fuente: Elaboración Propia.

Se utilizaron diferentes dispositivos celulares y una cámara semi profesional para generar las imágenes de las cuales se lista a continuación:

Tabla N° 01. Lista de dispositivos celulares utilizados para generación de imágenes de hojas de árboles forestales amazónicos

#	Modelo de Cámara	MPx	Apertura	Resolución	Formato
1	NIKON D3500	24.2	f/1.5	6000 x 4000	JPEG
2	SM-A705MN	32	f/1.7	4032 x 3024	JPEG

3	SM-A105M	13	f/1.9	4128 x 3096	JPEG
4	SM-A305G	16	f/2.0	4608 x 2128	JPEG
5	FIG-LX3	13	f/2.2	4160 x 3120	JPEG
6	Iphone 6	8	f/2.2	3264 x 2448	JPEG
7	SM-A325M	64	f/1.8	2084 x 4624	JPEG
8	M2103K19PG	48	f/1.79	1792 x 4000	JPEG

Fuente: Elaboración Propia.

4.1.2. Resumen del dataset: se detalla a continuación el resumen de la base de datos de las imágenes, incluyendo la cantidad de fotografías por especie y el tipo de cámara utilizado para su captura.

Tabla Nº 02. Lista de especies con el tipo de dispositivo celular y el total de imágenes por cada especie

Nº	Especies	Cámara	Sub Total	Total
1	<i>Anaueria brasiliensis</i>	SM-A305G	480	2164
		SM-A325M	484	
		FIG-LX3	241	
		NIKON D3500	479	
		M2103K19PG	480	
2	<i>Aniba rosaeodora</i>	SM-A105M	1547	6562
		SM-A305G	1537	
		SM-A705MN	1547	
		NIKON D3500	1529	
		FIG-LX3	402	
3	<i>Apuleia leiocarpa</i>	SM-A305G	801	3453
		SM-A325M	800	
		FIG-LX3	420	
		NIKON D3500	629	
		M2103K19PG	803	

4	<i>Calophyllum longifolium</i>	NIKON D3500	961	3200
		SM-A305G	639	
		SM-A325M	643	
		FIG-LX3	316	
		M2103K19PG	641	
5	<i>Brosimum parinarioides</i>	SM-A305G	685	2673
		SM-A325M	681	
		FIG-LX3	114	
		NIKON D3500	515	
		M2103K19PG	678	
6	<i>Brosimum rubescens</i>	SM-A305G	878	3809
		SM-A325M	872	
		FIG-LX3	363	
		NIKON D3500	820	
		M2103K19PG	876	
7	<i>Brosimum utile</i>	SM-A305G	842	3635
		SM-A325M	819	
		FIG-LX3	463	
		NIKON D3500	669	
		M2103K19PG	842	
8	<i>Caraipa utilis</i>	SM-A305G	640	2901
		SM-A325M	638	
		FIG-LX3	337	
		NIKON D3500	644	
		M2103K19PG	642	
9	<i>Carapa guianensis</i>	SM-A305G	805	3338
		SM-A325M	802	
		FIG-LX3	275	
		NIKON D3500	664	

		M2103K19PG	792	
10	<i>Cariniana decandra</i>	SM-A305G	480	2145
		SM-A325M	459	
		FIG-LX3	244	
		NIKON D3500	481	
		M2103K19PG	481	
11	<i>Caryocar glabrum</i>	SM-A305G	828	3458
		SM-A325M	8 46	
		FIG-LX3	456	
		NIKON D3500	480	
		M2103K19PG	848	
12	<i>Cedrela odorata</i>	SM-A105M	1304	5526
		SM-A305G	1303	
		SM-A705MN	1302	
		NIKON D3500	1302	
		Iphone 6	127	
		FIG-LX3	188	
13	<i>Cedrelinga cateniformis</i>	SM-A105M	1232	5279
		SM-A305G	1230	
		SM-A705MN	1232	
		NIKON D3500	1232	
		Iphone 6	176	
		FIG-LX3	177	
14	<i>Ceiba pentandra</i>	SM-A305G	800	3451
		SM-A325M	800	
		FIG-LX3	422	
		NIKON D3500	634	
		M2103K19PG	795	

15	<i>Ceiba samauma</i>	SM-A305G	480	2161
		SM-A325M	483	
		FIG-LX3	240	
		NIKON D3500	478	
		M2103K19PG	480	
16	<i>Clarisia racemosa</i>	SM-A305G	482	2144
		SM-A325M	477	
		FIG-LX3	235	
		NIKON D3500	480	
		M2103K19PG	470	
17	<i>Dipteryx micrantha</i>	SM-A105M	1248	8581
		SM-A305G	1890	
		SM-A325M	638	
		SM-A705MN	1248	
		NIKON D3500	1799	
		FIG-LX3	775	
		Iphone 6	340	
		M2103K19PG	643	
18	<i>Eschweilera coriacea</i>	SM-A305G	641	2878
		SM-A325M	642	
		FIG-LX3	313	
		NIKON D3500	641	
		M2103K19PG	641	
19	<i>Guazuma Crinita</i>	SM-A305G	508	1379
		SM-A325M	254	
		FIG-LX3	108	
		NIKON D3500	254	
		M2103K19PG	255	
20	<i>Hevea guianensis</i>	SM-A305G	645	2852

		SM-A325M	639	
		FIG-LX3	295	
		NIKON D3500	637	
		M2103K19PG	636	
21	<i>Hymenaea courbaril</i>	SM-A305G	794	3225
		SM-A325M	640	
		FIG-LX3	368	
		NIKON D3500	791	
		M2103K19PG	632	
22	<i>Hymenaea oblongifolia</i>	SM-A305G	891	3735
		SM-A325M	909	
		FIG-LX3	160	
		NIKON D3500	890	
		M2103K19PG	885	
23	<i>Iryanthera elliptica</i>	SM-A305G	640	2882
		SM-A325M	640	
		FIG-LX3	313	
		NIKON D3500	648	
		M2103K19PG	641	
24	<i>Iryanthera grandis</i>	SM-A305G	440	1956
		SM-A325M	439	
		FIG-LX3	196	
		NIKON D3500	440	
		M2103K19PG	441	
25	<i>Iryanthera laevis</i>	SM-A305G	753	3405
		SM-A325M	761	
		FIG-LX3	536	
		NIKON D3500	591	
		M2103K19PG	764	

26	<i>Iryanthera tricornis</i>	SM-A305G	1013	4383
		SM-A325M	1014	
		FIG-LX3	526	
		NIKON D3500	817	
		M2103K19PG	1013	
27	<i>Maquira coriacea</i>	SM-A305G	665	2977
		SM-A325M	660	
		FIG-LX3	317	
		NIKON D3500	671	
		M2103K19PG	664	
28	<i>Ocotea aciphylla</i>	SM-A305G	480	2161
		SM-A325M	480	
		FIG-LX3	239	
		NIKON D3500	482	
		M2103K19PG	480	
29	<i>Ormosia coccinea</i>	SM-A305G	641	2887
		SM-A325M	640	
		FIG-LX3	326	
		NIKON D3500	639	
		M2103K19PG	641	
30	<i>Osteophloeum platyspermum</i>	SM-A305G	1203	5032
		SM-A325M	1117	
		FIG-LX3	664	
		NIKON D3500	867	
		M2103K19PG	1181	
31	<i>Otoba glycyarpa</i>	SM-A105M	1260	5538
		SM-A305G	1268	
		SM-A705MN	1281	
		NIKON D3500	1271	

		Iphone 6	322	
		FIG-LX3	136	
32	<i>Otoba parvifolia</i>	SM-A105M	1712	7271
		SM-A305G	1716	
		SM-A705MN	1713	
		NIKON D3500	1745	
		FIG-LX3	385	
33	<i>Parahancornia peruviana</i>	SM-A305G	874	3826
		SM-A325M	887	
		FIG-LX3	331	
		NIKON D3500	853	
		M2103K19PG	881	
34	<i>Pseudolmedia laevis</i>	SM-A305G	640	2902
		SM-A325M	644	
		FIG-LX3	336	
		NIKON D3500	642	
		M2103K19PG	640	
35	<i>Simaruba amara</i>	SM-A105M	1216	5182
		SM-A305G	1210	
		SM-A705MN	1216	
		NIKON D3500	980	
		Iphone 6	388	
		FIG-LX3	172	
36	<i>Sloanea floribunda</i>	SM-A305G	476	2139
		SM-A325M	474	
		FIG-LX3	235	
		NIKON D3500	476	
		M2103K19PG	478	
37	<i>Swietenia macrophylla</i>	SM-A105M	1568	6436

		SM-A305G	1572	
		SM-A705MN	1586	
		NIKON D3500	1564	
		FIG-LX3	146	
38	<i>Vatairea erythrocarpa</i>	SM-A305G	649	2979
		SM-A325M	643	
		FIG-LX3	391	
		NIKON D3500	647	
		M2103K19PG	649	
39	<i>Virola flexuosa</i>	SM-A105M	1040	4344
		SM-A305G	1042	
		SM-A705MN	1042	
		NIKON D3500	1030	
		FIG-LX3	190	
40	<i>Virola pavonis</i>	SM-A105M	1832	7491
		SM-A305G	1840	
		SM-A705MN	1842	
		NIKON D3500	1841	
		FIG-LX3	136	
Total				152320

Fuente: Elaboración Propia

4.2. PROCESAMIENTO DEL DATASET

En el procesamiento de datos, se priorizó resaltar la estructura de las venas, tal como mencionan Vizcarra et al. (2021). Además, Quach et al. (2023) señalan que los algoritmos de aprendizaje automático pueden capturar el patrón de las venas mediante un vector de características, lo que permite diferenciar entre diferentes especies.

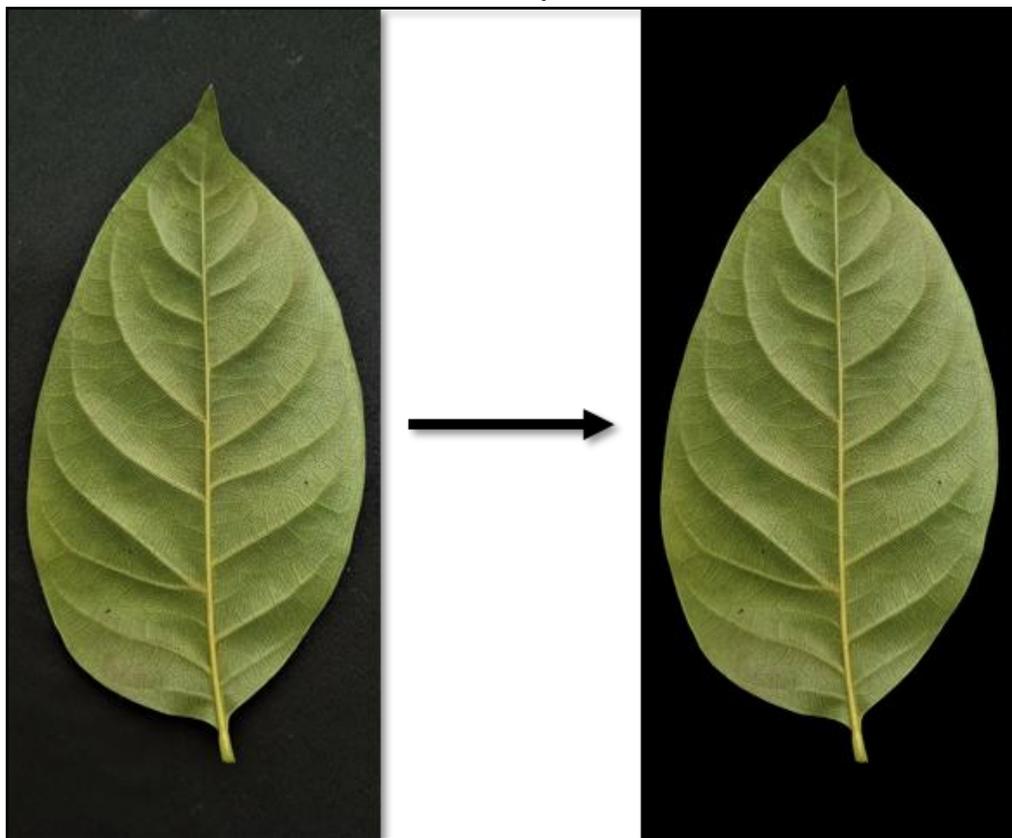
Para lograr esto, se implementaron los siguientes procesos y en el Anexo 7 se encuentra el código fuente:

4.2.1. Eliminación de fondo:

Consiste en separar el objeto de interés, en este caso las hojas, del fondo de la imagen. Esto se logra utilizando la librería “rembg” en el entorno Python ⁽³⁰⁾ que encapsula internamente modelos de deep learning para detectar y eliminar elementos no deseados que rodean a la hoja, para este caso aplicamos el modelo “isnet-general-use” y en imágenes donde falló el modelo anterior aplicamos “u2net”

Fuente: Elaboración propia

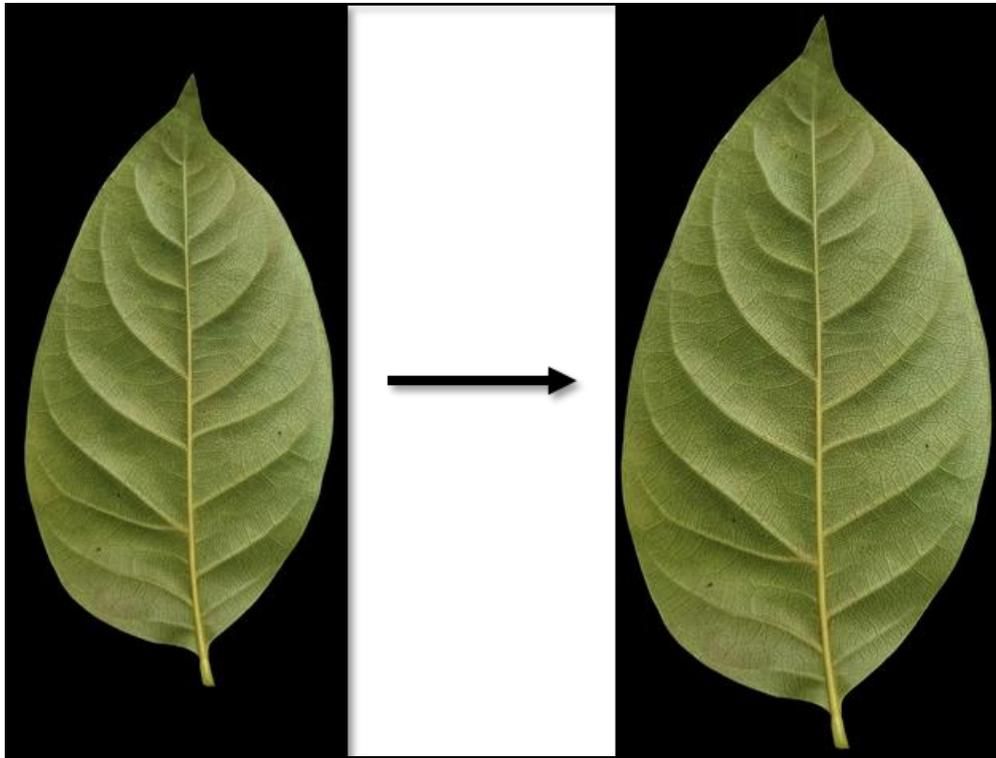
Figura N° 02. Muestra del resultado de eliminación de fondo de una imagen de hoja



4.2.2. Extracción del objeto de interés:

Después de eliminar el fondo, se procede a extraer el objeto de interés, que en este caso corresponde a la hoja misma. Para llevar a cabo este proceso, se utilizó la librería OpenCV2 en el entorno de Python. Se

Figura N° 03. Muestra del resultado de extracción de píxeles de contornos de la imagen de una hoja



empleó la función 'findContours' para detectar los contornos de la hoja y generar una caja delimitadora que engloba su posición. Posteriormente, se extrajeron los píxeles que se encuentran dentro de esta caja delimitadora, correspondientes a la propia hoja.

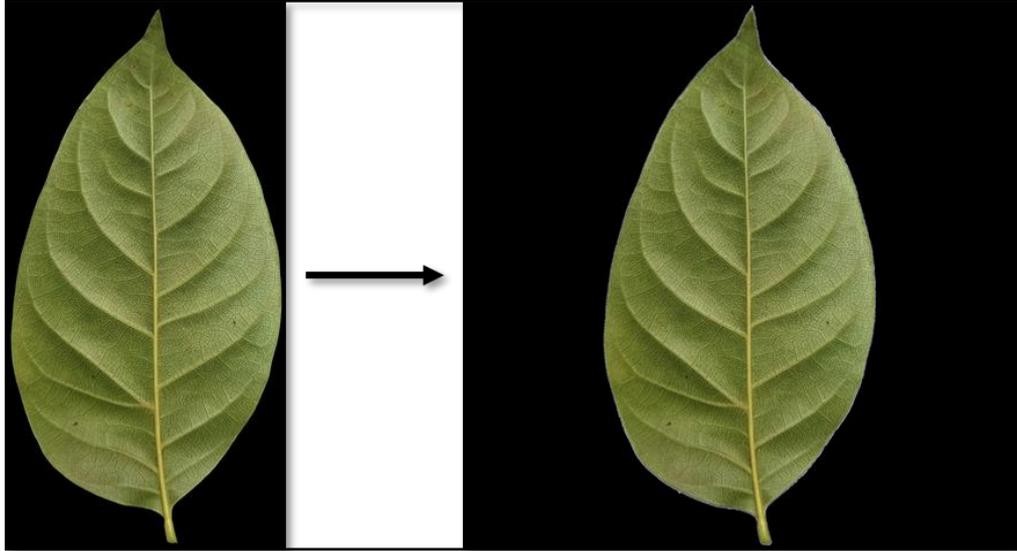
Fuente: Elaboración propia

4.2.3. Redimensionado de imágenes:

A partir del objeto de interés: luego de extraer la hoja, se orienta a asegurar dimensiones adecuadas para la entrada en algoritmos de redes neuronales convolucionales (CNN), al tiempo que conserva el aspecto original de las imágenes. Este proceso, implementado mediante una función, escala las imágenes para ajustarlas a un tamaño específico para este caso (2044x2044 píxeles), preservando la

proporción original y agregando relleno según sea necesario. Esta preparación es esencial para proporcionar datos uniformes y compatibles con los algoritmos de CNN, manteniendo la integridad visual de las hojas en el proceso de análisis.

Figura N° 04. Muestra del resultado de redimensión de la imagen de una hoja



Fuente: Elaboración propia

4.2.4. Selección de imágenes con la cara inferior (envés) de la hoja:

Se llevó a cabo una selección específica de imágenes que muestran la cara inferior o envés de las hojas, enfocándose en aquellas donde las venas son claramente visibles y se aprecian de manera nítida. Se procuró elegir hojas limpias y saludables para esta selección. Esta región de la hoja suele exhibir patrones de venas distintivos que pueden ser de relevancia significativa para los algoritmos de CNN.

Figura N° 05. Muestra del resultado de selección de la imagen "envés" de una hoja

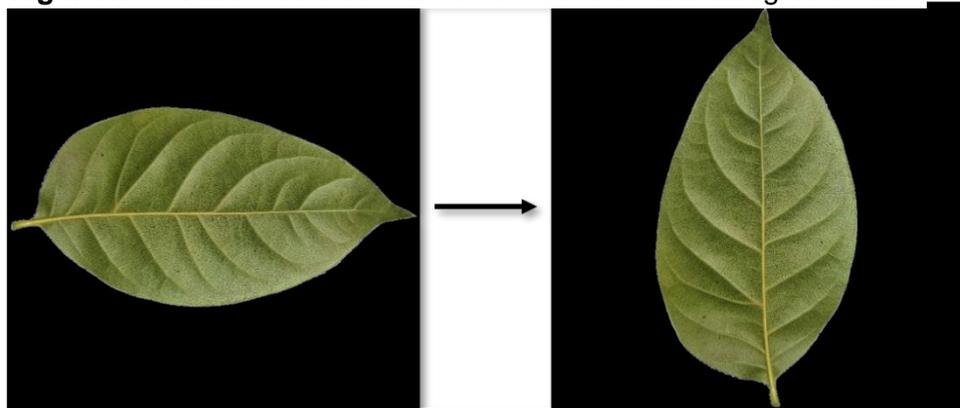


Fuente: Elaboración propia

4.2.5. Rotación de imágenes:

En algunos casos, las imágenes pueden requerir rotación para alinear de forma horizontal a una orientación vertical. Esta acción facilita el análisis de las venas, ya que las redes neuronales convolucionales presentan limitaciones para lograr la invariancia ante cambios de rotación. La rotación de las imágenes ayuda a compensar estas limitaciones, permitiendo un análisis más efectivo de los patrones venosos en las hojas al proporcionar una orientación consistente y deseada para el modelo.

Figura N° 06. Muestra del resultado de rotación de la imagen de una



Fuente: Elaboración propia

4.2.6. Generación de dataset de entrenamiento:

Se dividieron las imágenes de hojas en conjuntos de entrenamiento, validación y pruebas utilizando una distribución aleatoria del 70%, 20% y 10%, respectivamente. Estas listas aleatorias contienen rutas de archivos y nombres de especies para cada conjunto y guardadas en archivos de texto separados por comas. Estos archivos se utilizaron con entrada para los algoritmos de CNN.

Tabla N° 03. Tabla de cantidad de imágenes por datasets

Dataset	Cantidad de imágenes
Entrenamiento	28457
Validación	8084
Prueba	4244
Total	40785

Fuente: Elaboración propia

A continuación, se presenta el resumen del datasets de imágenes procesadas, incluyendo la cantidad de fotografías por especie y el tipo de cámara utilizado en su captura:

Tabla N° 04. Resumen de la cantidad de imágenes a nivel de especie y cámaras después de procesar

N°	Especie	Cámara	Sub Total	Total
1	<i>Anaueria brasiliensis</i>	SM-A305G	95	494
		SM-A325M	139	
		FIG-LX3	2	

		NIKON D3500	121	
		M2103K19PG	137	
2	<i>Aniba rosaeodora</i>	SM-A105M	414	1810
		SM-A305G	566	
		SM-A705MN	408	
		NIKON D3500	342	
		FIG-LX3	80	
3	<i>Apuleia leiocarpa</i>	SM-A305G	193	607
		SM-A325M	116	
		FIG-LX3	26	
		NIKON D3500	176	
		M2103K19PG	96	
4	<i>Calophyllum longifolium</i>	NIKON D3500	278	1176
		SM-A305G	303	
		SM-A325M	245	
		FIG-LX3	84	
		M2103K19PG	266	
5	<i>Brosimum parinarioides</i>	SM-A305G	205	586
		SM-A325M	120	
		FIG-LX3	21	
		NIKON D3500	85	
		M2103K19PG	155	
6	<i>Brosimum rubescens</i>	SM-A305G	289	988
		SM-A325M	165	
		FIG-LX3	63	
		NIKON D3500	230	
		M2103K19PG	241	
7	<i>Brosimum utile</i>	SM-A305G	142	755
		SM-A325M	136	

		FIG-LX3	45	
		NIKON D3500	198	
		M2103K19PG	234	
8	<i>Caraipa utilis</i>	SM-A305G	208	745
		SM-A325M	168	
		FIG-LX3	41	
		NIKON D3500	195	
		M2103K19PG	133	
9	<i>Carapa guianensis</i>	SM-A305G	317	1269
		SM-A325M	275	
		FIG-LX3	92	
		NIKON D3500	277	
		M2103K19PG	308	
10	<i>Cariniana decandra</i>	SM-A305G	128	431
		SM-A325M	105	
		NIKON D3500	100	
		M2103K19PG	98	
11	<i>Caryocar glabrum</i>	SM-A305G	332	1054
		SM-A325M	230	
		FIG-LX3	146	
		NIKON D3500	84	
		M2103K19PG	262	
12	<i>Cedrela odorata</i>	SM-A105M	238	1247
		SM-A305G	408	
		SM-A705MN	219	
		NIKON D3500	332	
		Iphone 6	40	
		FIG-LX3	10	
13	<i>Cedrelinga cateniformis</i>	SM-A105M	427	1813

		SM-A305G	475	
		SM-A705MN	399	
		NIKON D3500	397	
		Iphone 6	73	
		FIG-LX3	42	
14	<i>Ceiba pentandra</i>	SM-A305G	321	1029
		SM-A325M	262	
		FIG-LX3	125	
		NIKON D3500	226	
		M2103K19PG	95	
15	<i>Ceiba samauma</i>	SM-A305G	87	347
		SM-A325M	75	
		FIG-LX3	28	
		NIKON D3500	75	
		M2103K19PG	82	
16	<i>Clarisia racemosa</i>	SM-A305G	182	440
		SM-A325M	87	
		FIG-LX3	26	
		NIKON D3500	129	
		M2103K19PG	16	
17	<i>Dipteryx micrantha</i>	SM-A105M	286	1862
		SM-A305G	563	
		SM-A325M	159	
		SM-A705MN	281	
		NIKON D3500	176	
		FIG-LX3	66	
		Iphone 6	42	
		NIKON D3500	121	

		M2103K19PG	105	
		FIG-LX3	63	
18	<i>Eschweilera coriacea</i>	SM-A305G	165	
		SM-A325M	167	
		FIG-LX3	38	
		NIKON D3500	135	
		M2103K19PG	111	
19	<i>Guazuma crinita</i>	SM-A305G	264	
		SM-A325M	102	
		FIG-LX3	37	603
		NIKON D3500	86	
		M2103K19PG	114	
20	<i>Hevea guianensis</i>	SM-A305G	136	
		SM-A325M	142	
		FIG-LX3	53	547
		NIKON D3500	134	
		M2103K19PG	82	
21	<i>Hymenaea courbaril</i>	SM-A305G	140	
		SM-A325M	154	
		FIG-LX3	73	720
		NIKON D3500	217	
		M2103K19PG	136	
22	<i>Hymenaea oblongifolia</i>	SM-A305G	175	
		SM-A325M	209	
		FIG-LX3	24	824
		NIKON D3500	197	
		M2103K19PG	219	
23	<i>Iryanthera elliptica</i>	SM-A305G	182	
		SM-A325M	167	711

		FIG-LX3	73	
		NIKON D3500	167	
		M2103K19PG	122	
24	<i>Iryanthera grandis</i>	SM-A305G	71	395
		SM-A325M	83	
		FIG-LX3	35	
		NIKON D3500	115	
		M2103K19PG	91	
25	<i>Iryanthera laevis</i>	SM-A305G	182	599
		SM-A325M	145	
		FIG-LX3	82	
		NIKON D3500	67	
		M2103K19PG	123	
26	<i>Iryanthera tricornis</i>	SM-A305G	260	884
		SM-A325M	225	
		FIG-LX3	45	
		NIKON D3500	182	
		M2103K19PG	172	
27	<i>Maquira coriacea</i>	SM-A305G	190	605
		SM-A325M	148	
		FIG-LX3	30	
		NIKON D3500	141	
		M2103K19PG	96	
28	<i>Ocotea aciphylla</i>	SM-A305G	192	628
		SM-A325M	164	
		FIG-LX3	27	
		NIKON D3500	145	
		M2103K19PG	100	
29	<i>Ormosia coccinea</i>	SM-A305G	201	809

		SM-A325M	239	
		FIG-LX3	33	
		NIKON D3500	202	
		M2103K19PG	134	
30	<i>Osteophloeum platyspermum</i>	SM-A305G	367	1479
		SM-A325M	307	
		FIG-LX3	164	
		NIKON D3500	323	
		M2103K19PG	318	
31	<i>Otoba glycyarpa</i>	SM-A105M	405	2061
		SM-A305G	529	
		SM-A705MN	470	
		NIKON D3500	512	
		Iphone 6	142	
		FIG-LX3	3	
32	<i>Otoba parvifolia</i>	SM-A105M	642	2608
		SM-A305G	567	
		SM-A705MN	623	
		NIKON D3500	680	
		FIG-LX3	96	
33	<i>Parahancornia peruviana</i>	SM-A305G	285	988
		SM-A325M	177	
		FIG-LX3	52	
		NIKON D3500	253	
		M2103K19PG	221	
34	<i>Pseudolmedia laevis</i>	SM-A305G	250	816
		SM-A325M	193	
		FIG-LX3	47	
		NIKON D3500	168	

		M2103K19PG	158	
35	<i>Simaruba amara</i>	SM-A105M	216	1159
		SM-A305G	350	
		SM-A705MN	312	
		NIKON D3500	243	
		Iphone 6	23	
		FIG-LX3	15	
36	<i>Sloanea floribunda</i>	SM-A305G	145	570
		SM-A325M	120	
		FIG-LX3	26	
		NIKON D3500	151	
		M2103K19PG	128	
37	<i>Swietenia macrophylla</i>	SM-A105M	592	2223
		SM-A305G	603	
		SM-A705MN	431	
		NIKON D3500	569	
		FIG-LX3	28	
38	<i>Vatairea erythrocarpa</i>	SM-A305G	229	783
		SM-A325M	147	
		FIG-LX3	74	
		NIKON D3500	217	
		M2103K19PG	116	
39	<i>Virola flexuosa</i>	SM-A105M	248	1250
		SM-A305G	402	
		SM-A705MN	282	
		NIKON D3500	303	
		FIG-LX3	15	
40	<i>Virola pavonis</i>	SM-A105M	401	2254
		SM-A305G	766	

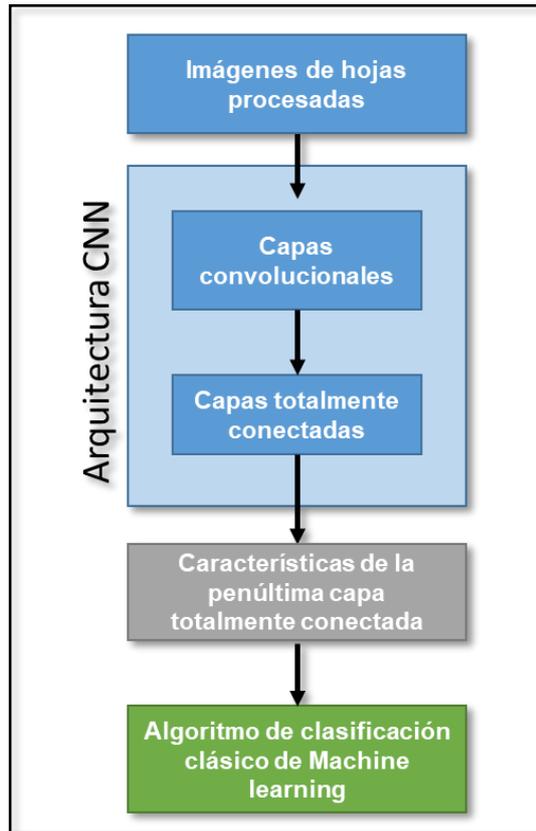
		SM-A705MN	485	
		NIKON D3500	568	
		FIG-LX3	34	
Total				40785

Fuente: Elaboración propia

4.3. DESARROLLO DE MODELO HÍBRIDO

Se presenta el concepto lógico del modelo híbrido. Este enfoque combina el uso de un modelo de CNN (pre entrenada con ajuste fino) para extraer características de la penúltima capa totalmente conectada, que proporciona una representación abstracta de la imagen, capturando las características importantes de las hojas. Posteriormente, se emplea un algoritmo de clasificación clásico de *machine learning* para predecir las clases (Figura 1) y en el Anexo 8 se encuentra el código fuente para ejecutar la predicción del modelo híbrido.

Figura N° 07. Arquitectura lógica de modelo híbrido



Fuente: Elaboración propia

4.3.1. ENTRENAMIENTO DE LOS MODELOS DE CNN

Los modelos de CNN se entrenaron empleando pesos pre-entrenados y aplicando ajuste fino sin congelar ninguna capa. Se utilizaron imágenes de entrada de 512x512 píxeles como entrada para el proceso de entrenamiento. Este se realizó a lo largo de 20 épocas, utilizando un tamaño de lote de 32 imágenes para cada red, como se detalla en la tabla 5. La arquitectura detallada de los modelos utilizados en este estudio se encuentra disponible en el Anexo 4.

En el Anexo 5 se encuentran las gráficas correspondientes al proceso de entrenamiento y validación de los modelos. Se destaca que, en todos los modelos, tanto la curva de precisión como la de la función de pérdida, presentan un rápido incremento y descenso, respectivamente, en las primeras

épocas del entrenamiento. Sin embargo, solo el modelo MobileNet muestra una notable similitud entre las curvas de precisión y pérdida, indicando una buena concordancia y capacidad de generalización.

Tabla N° 05. Configuración de parámetros de los modelos de CNN.

Hiperparámetros	VGG19	MobileNet	DenseNet
	Valores		
Optimizador	Adam		
<i>Image Size</i>	512 x 512		
Pesos pres entrenados	ImageNet		
Función de pérdida	<i>categorical crossentropy</i>		
Épocas	20		
Tamaño de lote	32		20
Función de activación	Relu		
Función de clasificación	Softmax		
Taza de aprendizaje	10 ⁻⁴		

Fuente: Elaboración propia

Los modelos de CNN fueron entrenados en una tarjeta GPU instalada en una *Workstation* con las siguientes características:

- Procesador Intel Core i9-9900K, Memoria RAM de 128 GB (4x32GB) 3200 MHz, tarjeta de video NVIDIA TITAN RTX 24 GB GDDR6 Profesional, Disco duro de estado sólido (SSD) Sata de 1 TB M.2 y un disco duro rígido de 7200RPM de 1 TB.

En la tabla 6, se muestra los resultados del entrenamiento de tres modelos de redes neuronales convolucionales (VGG-19, MobileNet y DenseNet). Se observa que VGG-19 y MobileNet alcanzan altos niveles de precisión durante el entrenamiento, con valores especialmente notables en MobileNet y logrando un tiempo de entrenamiento bajo en comparación a los otros modelos. En términos de pérdida durante el entrenamiento, VGG-19 y

MobileNet muestran valores más bajos, indicando un mejor ajuste a los datos de entrenamiento. Sin embargo, al examinar los resultados en el conjunto de validación, MobileNet destaca con una precisión significativamente alta y una pérdida baja, sugiriendo una mejor capacidad de generalización en datos no vistos en comparación con los otros modelos.

Tabla N° 06. Resultados de entrenamiento de los modelos CNN

	VGG-19	MobileNet	DenseNet
Tiempo entrenamiento	300.343 min	149.728 min	249.467 min
Precisión en entrenamiento	0.9950	0.9956	0.8390
Pérdida en entrenamiento	0.0168	0.0238	0.5249
Precisión en validación	0.9806	0.9973	0.9042
Pérdida en validación	0.0868	0.0146	0.3370

Fuente: Elaboración propia

4.3.2. ENTRENAMIENTO DE ALGORITMOS MACHINE LEARNING

Tras completar el entrenamiento de los algoritmos de CNN, se generó un archivo en formato h5 que almacena las características extraídas del dataset de imágenes de entrenamiento, validación y pruebas. Estas características provienen de la penúltima capa del modelo de CNN entrenado.

Tabla N° 07. Cantidad de características que se extrae en cada modelo de CNN

	VGG19	MobileNet	DenseNet
Cantidad de características	128	1024	1024

Fuente: Elaboración propia

Se estandarizaron las características eliminando la media y escalando a la varianza unitaria, para ello se utilizó la función *StandardScaler* de *scikit-learn* en Python. La fórmula que aplica la función para realizar esta estandarización es la siguiente:

$$z = (x - u) / s$$

Donde:

- x , es el valor original de la característica.
- u , es la media de las muestras de entrenamiento.
- s , es la desviación estándar de las muestras de entrenamiento.

Esta fórmula calcula el puntaje Z (z-score) para cada valor de la característica, restando la media y dividiendo por la desviación estándar. Este proceso de estandarización hace que la característica tenga una media de cero y una desviación estándar de uno, lo que ayuda a que las características estén en una escala común y facilita la comparación y el procesamiento de los datos.

Al igual que una investigación anterior ⁽³¹⁾, se aplicó un proceso iterativo busca optimizar los hiperparámetros del algoritmo SVM utilizando validación cruzada. Se exploró una variedad de kernels y valores de C (de 0.8 a 1) para determinar la combinación que maximiza la precisión del modelo. Se ajusta el SVM con cada combinación, y mediante validación cruzada con 10 folds, se evalúa su rendimiento. La selección de los hiperparámetros se basa en la mayor precisión promedio obtenida en la validación cruzada. Este flujo se representa matemáticamente como:

Dado un conjunto de kernels K y valores de C , se prueba cada combinación $k_i \in K$ y $c_j \in C$. Se ajusta el SVM con el kernel k_i y el valor de $C = c_j$, y se evalúa su rendimiento mediante validación cruzada, calculando la precisión promedio P_{ji} . Se selecciona la combinación con la máxima precisión promedio como la configuración óptima: $(k^*, c^*) = \operatorname{argmax}_{k_i \in K, c_j \in C} P_{ij}$. Con esto se busca encontrar los hiperparámetros que maximizan la capacidad predictiva del modelo SVM.

En cuanto al algoritmo de regresión logística (LR) para todos los casos se aplicó la penalización L2, como lo menciona otra investigación ⁽³²⁾, ofrece regularización, controla el sobreajuste, reduce la varianza del modelo y puede mejorar su rendimiento al manejar multicolinealidad y aumentar la robustez ante datos atípicos, lo que lleva a un mejor rendimiento general del modelo.

Los algoritmos de *machine learning* fueron entrenados en CPU haciendo uso de la capacidad de paralelismo de la Supercomputadora Manatí del Instituto de Investigaciones de la Amazonía Peruana, se usó dos nodos de procesamiento con las siguientes características:

- 2 Procesadores Intel Broadwell 14-Cores E5-2680V4 2.4GHz, Memoria RAM de 64 GB Memoria (8x8GB).

En la tabla 8 se presentan los resultados del entrenamiento de modelos SVM utilizando diferentes extractores de características y configuraciones de *kernels*. Se observa que los tiempos de entrenamiento para VGG-19, MobileNet y DenseNet son de 8.577 segundos, 7.104 segundos y 1642.696 segundos, respectivamente. Se destaca que MobileNet logra la más alta precisión tanto en entrenamiento (0.9932) como en validación (0.9916), superando a VGG-19 en términos de precisión. A pesar de que VGG-19 muestra una precisión respetable en ambas métricas, MobileNet destaca con valores más altos en el conjunto de validación. Esto indica que MobileNet tiene una mejor capacidad para generalizar y hacer predicciones precisas sobre datos no vistos en comparación con VGG-19. Además, se observa que se utilizaron diferentes kernels para cada modelo, con el kernel "rbf" para VGG-19 y "linear" para MobileNet.

Tabla N° 08. Resultados de entrenamiento de SVM

SVM			
Extractor de característica	VGG-19	MobileNet	DenseNet
Tiempo entrenamiento	8.577 s	7.104 s	1642.696 s
Kernel	rbf	linear	linear

Parámetro de penalización (C)	1.0	0.8	0.9
Precisión en entrenamiento	0.8833	0.9932	0.3255
Precisión en validación	0.8977	0.9916	0.3317

Fuente: Elaboración propia

En la tabla 9, se muestran los resultados del entrenamiento de modelos de regresión logística (LR) utilizando diferentes extractores de características: VGG-19, MobileNet y DenseNet. Los tiempos de entrenamiento para VGG-19 y MobileNet son de 6.049 segundos y 40.8 segundos, respectivamente. En términos de precisión, MobileNet muestra la más alta precisión tanto en entrenamiento (0.9949) como en validación (0.9926), superando a VGG-19. Aunque VGG-19 logra una precisión respetable en ambas métricas, MobileNet destaca con valores más altos en el conjunto de validación. Esto sugiere que MobileNet tiene una mejor capacidad para generalizar y hacer predicciones precisas sobre datos no vistos en comparación con VGG-19 en el contexto de la regresión logística. Es relevante destacar que el tiempo de entrenamiento para MobileNet es considerablemente mayor que para VGG-19 en este contexto, lo que indica una diferencia significativa en la eficiencia de entrenamiento entre estos modelos.

Tabla N° 09. Resultados de entrenamiento de LR

LR			
Extractor de característica	VGG-19	MobileNet	DenseNet
Tiempo entrenamiento	6.049 s	40.8 s	22.060 s
Kernel	-	-	-
Parámetro de penalización (C)	-	-	-
Precisión en entrenamiento	0.8837	0.9949	0.335
Precisión en validación	0.898	0.9926	0.2746

Fuente: Elaboración propia

4.3.3. PRUEBAS DEL MODELO HÍBRIDO

Tabla N° 10. Resultados de la prueba de los algoritmos CNN y *Machine learning*

Modelo		Precisión	Sensibilidad	Especificidad	F1-Score
CNN	VGG-19	0.9662	0.9653	0.9991	0.9651
	MobileNet	0.9882	0.9878	0.9997	0.9877
	DenseNet	0.8613	0.8498	0.9961	0.8448
Híbrido	VGG-19+SVM (RBF-1.0)	0.8977	0.8784	0.9974	0.8806
	VGG-19+LR	0.8791	0.8597	0.9969	0.8625
	MobileNet-19+SVM (linear-0.8)	0.9916	0.9889	0.9998	0.9891
	MobileNet+LR	0.9926	0.9907	0.9998	0.9906
	DenseNet +SVM (linear-0.9)	0.3317	0.2654	0.9823	0.2911
	DenseNet+LR	0.3384	0.2746	0.9825	0.3021

Fuente: Elaboración propia

La tabla 10, muestra la comparación de métricas de evaluación para todos los modelos usando el dataset de pruebas que tiene 4244 imágenes de hojas. Se observa que, en términos de precisión, tanto MobileNet+LR como MobileNet-19+SVM (linear-0.8) sobresalen con puntajes superiores, alcanzando valores de 0.9926 y 0.9916, respectivamente. Estos modelos tienen la capacidad más alta para clasificar correctamente las muestras en comparación con los demás.

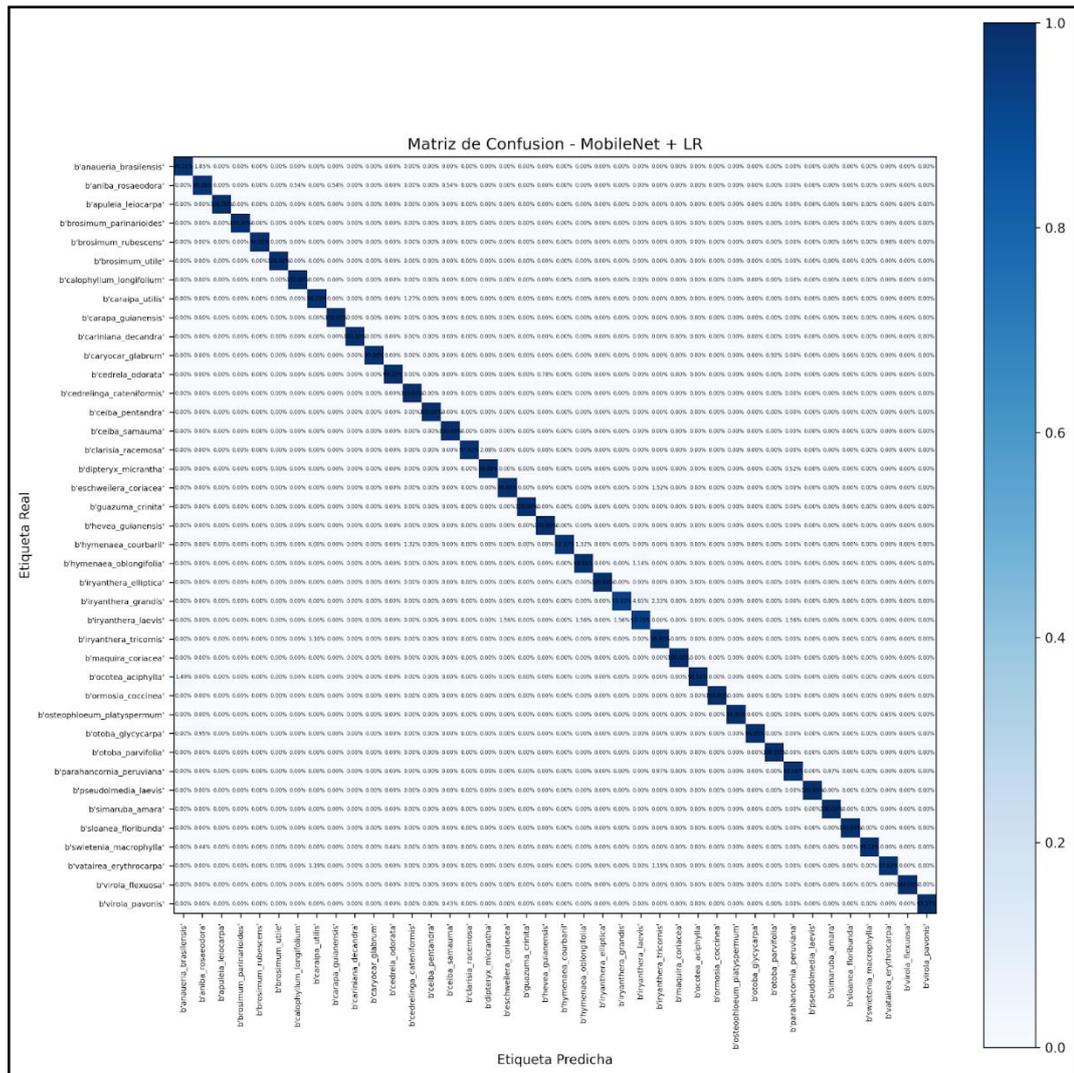
En cuanto a la sensibilidad, que refleja la capacidad de un modelo para identificar correctamente las muestras positivas, MobileNet+LR y MobileNet-19+SVM (linear-0.8) también obtienen los puntajes más altos (0.9907 y 0.9889 respectivamente).

La especificidad, indicador de la capacidad para identificar correctamente las muestras negativas, es alta en general para todos los modelos y combinaciones de modelos, con puntajes cercanos o superiores a 0.996 siendo MobileNet+LR con un puntaje superior de 9998.

El F1-Score, que es una medida de precisión y sensibilidad combinadas, destaca nuevamente a MobileNet+LR y MobileNet-19+SVM (linear-0.8) como los modelos con los puntajes más altos (0.9906 y 0.9891 respectivamente).

Es importante destacar que MobileNet y las combinaciones de MobileNet, con LR y SVM, demuestran un mejor desempeño en términos de precisión y capacidad para clasificar correctamente las muestras en comparación con otros modelos y combinaciones. Sin embargo, se observa un bajo rendimiento en algunas combinaciones específicas, como DenseNet+SVM (linear-0.9) y DenseNet+LR, donde se muestran valores inferiores en todas las métricas evaluadas.

Figura N° 08. Matriz de confusión de modelo híbrido MobileNet+LR



Fuente: Elaboración propia

4.4. CONTRASTACIÓN DE HIPÓTESIS

De acuerdo con la finalidad de la investigación, se ha realizado un análisis para observar si existen diferencias con la utilización de un modelo híbrido de aprendizaje automático supervisado en los procesos de identificación de alrededor de 40 especies de árboles forestales a partir de imágenes de sus hojas. A continuación, se presentan los análisis por cada hipótesis de investigación para este trabajo.

4.4.1. Hipótesis Específica 1:

Se ha planteado para la hipótesis específica 1, que la implementación del modelo híbrido de aprendizaje automático supervisado podría aumentar el índice de precisión en la clasificación de especies de árboles forestales amazónicos. Los resultados muestran que, el modelo híbrido MobileNet+LR alcanzó una precisión del 0.9926, superando a los modelos CNN por un promedio de 5.4 puntos porcentuales.

Los resultados respaldan la hipótesis planteada, sugiriendo que la combinación de MobileNet con regresión logística (LR) ha demostrado ser efectiva para mejorar la precisión en la clasificación de especies de árboles forestales. Este modelo híbrido muestra una capacidad superior para discriminar y clasificar correctamente las especies en comparación con otros modelos CNN evaluados en los mismos conjuntos de datos de prueba.

En conclusión, la estrategia de utilizar un modelo de extracción de características como MobileNet, combinado con un clasificador como regresión logística (LR), ha contribuido al aumento del índice de Precisión, en la clasificación de especies de árboles forestales amazónicos, respaldando así la hipótesis planteada

4.4.2. Hipótesis Específica 2:

Se ha planteado para la hipótesis específica 2, que la implementación del modelo híbrido de aprendizaje automático supervisado podría aumentar el índice de sensibilidad en la clasificación de especies de árboles forestales amazónicos. Los resultados muestran que, el modelo híbrido MobileNet+LR alcanzó una sensibilidad de 0.9907, superando a los modelos CNN por un promedio de 5.64 puntos porcentuales.

Los resultados sustentan la hipótesis, ya que el modelo híbrido demostró una sensibilidad superior al clasificar las especies de árboles forestales. La combinación de MobileNet con regresión logística (LR) ha demostrado ser eficaz para identificar correctamente las muestras positivas entre las especies,

superando la capacidad de otros modelos CNN evaluados en el mismo contexto de datos de prueba.

En conclusión, el uso del modelo híbrido ha contribuido al aumento del índice de Sensibilidad, en la clasificación de especies de árboles forestales amazónicos, respaldando así la hipótesis planteada.

4.4.3. Hipótesis Específica 3:

Se ha planteado para la hipótesis específica 3, que el uso del modelo híbrido de aprendizaje automático supervisado podría aumentar el índice de especificidad en la clasificación de especies de árboles forestales amazónicos. Los resultados reflejan que el modelo híbrido MobileNet+LR alcanzó una especificidad de 0.9998, y los modelos de CNN un rendimiento inferior por solo 0.15 puntos porcentuales en promedio.

Esta observación respalda la hipótesis planteada, ya que el modelo híbrido demostró una alta especificidad en la identificación correcta de las muestras negativas dentro de las especies de árboles forestales. La combinación de MobileNet con regresión logística ha mostrado ser eficaz para distinguir adecuadamente las muestras negativas, superando la capacidad de otros modelos CNN evaluados en el mismo conjunto de datos de prueba.

En conclusión, el uso del modelo híbrido ha contribuido al aumento del índice de Especificidad en la clasificación de especies de árboles forestales amazónicos, en línea con la hipótesis formulada.

4.4.4. Hipótesis Específica 4:

Se ha planteado para la hipótesis específica 4, que el uso del modelo híbrido de aprendizaje automático supervisado podría aumentar la métrica F1-score en la clasificación de especies de árboles forestales amazónicos. Los resultados obtenidos muestran que el modelo híbrido MobileNet+LR alcanzó

un F1-score de 0.9906, superando a los modelos CNN por un promedio de 5.8 puntos porcentuales.

Esta observación respalda la hipótesis formulada, ya que el modelo híbrido demostró un alto F1-score en la clasificación de especies de árboles forestales. La combinación de MobileNet con regresión logística ha mostrado ser efectiva para proporcionar un equilibrio entre precisión y sensibilidad en la clasificación, superando la capacidad de otros modelos CNN evaluados en el mismo conjunto de datos de prueba.

En conclusión, el uso del modelo híbrido ha contribuido al aumento del F1-score en la clasificación de especies de árboles forestales amazónicos, confirmando la hipótesis planteada.

4.4.5. Hipótesis General:

Después de analizar los resultados y contrastar con la hipótesis general planteada, se concluye que la investigación respalda la efectividad del modelo híbrido en la clasificación de especies de árboles forestales amazónicos.

En primer lugar, se observa que el modelo híbrido logró altos niveles de precisión, sensibilidad, especificidad y F1-score en la clasificación de las especies. Esto sugiere que el modelo fue capaz de identificar con precisión tanto las especies de árboles forestales, así como las muestras negativas. La precisión en la clasificación de las especies alcanzó valores superiores a 0.99, lo que indica una alta exactitud del modelo en la identificación de las especies de árboles.

En resumen, los resultados obtenidos respaldan la hipótesis general, mostrando que el uso del modelo híbrido de aprendizaje automático supervisado proporciona una herramienta eficaz y precisa para la clasificación de especies de árboles forestales basada en características de hojas. Esto sugiere que el modelo híbrido podría ser valioso en aplicaciones prácticas para la identificación precisa y eficiente de especies forestales.

CAPÍTULO V: DISCUSIÓN DE LOS RESULTADOS

La preservación de los bosques es crucial para el equilibrio ecológico y la vida en el planeta, especialmente en la Amazonía peruana, donde se estima la existencia de 2,500 especies forestales, pero solo unas 600 están reconocidas oficialmente. La falta de información adecuada dificulta la identificación precisa de estas especies, lo que puede conducir a problemas como el tráfico ilegal y la deforestación. Tradicionalmente, la identificación de especies forestales ha recaído en especialistas, pero con los avances tecnológicos, se buscan métodos automatizados para clasificar especies basadas en características de hojas.

Las hojas son una fuente valiosa de información para la identificación de árboles y, aunque su uso es común, la similitud entre las hojas de diferentes especies puede dificultar la identificación precisa. La inteligencia artificial ha permitido el desarrollo de algoritmos de redes neuronales convolucionales (CNN), SVM y regresión logística (LR), que han demostrado ser efectivos en la clasificación de hojas. Estos métodos han superado la precisión del 96% al 99%, lo que indica su fiabilidad en la clasificación.

Varios estudios han destacado la efectividad de métodos de aprendizaje automático en la identificación precisa de especies vegetales a partir de imágenes de hojas. Se han propuesto enfoques como SVM, alcanzando una precisión del 99.58%, y se ha evidenciado que tanto SVM como CNN son métodos efectivos para el reconocimiento de hojas. Otros trabajos ⁽⁵⁾, ⁽⁶⁾, ⁽⁸⁾ y ⁽⁹⁾, presentaron software que identifica especies amazónicas con una precisión de entrenamiento del 96.64%, y de prueba del 96.52%, usando VGG-19 ⁽¹⁰⁾. Asimismo, se empleó CNN para reconocer plantas ayurvédicas, superando significativamente a un perceptrón multicapa. Un enfoque basado en DenseNet, que combina CNN con varios clasificadores, logró precisiones superiores al 98% en diferentes conjuntos de datos de hojas. Estos estudios demuestran la fortaleza y eficacia de estas técnicas en la precisa identificación de especies vegetales a partir de sus hojas.

En relación con la hipótesis sobre la mejora en la clasificación de las especies de árboles forestales amazónicos mediante un modelo híbrido de aprendizaje automático supervisado utilizando características de hojas, los resultados del modelo MobileNet+LR corroboran exitosamente esta premisa. Este modelo específico logró un excepcional 99% de precisión en la identificación de diferentes especies forestales a partir de características de hojas. La combinación de MobileNet y Regresión Logística demostró una capacidad notable para discernir y clasificar con precisión las diversas especies, superando con creces las expectativas planteadas. Estos resultados validan efectivamente la hipótesis inicial sobre la mejora de la clasificación de especies forestales amazónicas mediante el uso de un modelo híbrido basado en características de hojas y técnicas de aprendizaje automático supervisado.

En conclusión, los resultados de este estudio confirman la efectividad sobresaliente del modelo híbrido MobileNet+LR en la clasificación de especies de árboles forestales amazónicos a partir de características de hojas. Este enfoque logró una impresionante precisión del 99%, lo que indica su capacidad para identificar con gran precisión las especies arbóreas. Los hallazgos refuerzan la hipótesis de que un modelo de aprendizaje automático supervisado, especialmente la combinación de MobileNet y Regresión Logística, puede mejorar significativamente la clasificación de especies basada en características de hojas. Estos resultados abren oportunidades para aplicar eficientemente técnicas de aprendizaje automático en la preservación de la biodiversidad en la Amazonía, proporcionando herramientas precisas y ágiles para el reconocimiento y la gestión de especies forestales, con posibles implicaciones en la conservación y protección de estos ecosistemas vitales.

CAPÍTULO VI: PROPUESTA

La investigación presentada en este estudio, que se enfoca en el desarrollo y aplicación de un modelo híbrido de aprendizaje automático para la clasificación de especies de árboles forestales utilizando características de hojas, plantea una contribución significativa tanto en el ámbito científico como en la conservación de la biodiversidad.

Desde una perspectiva de conservación de la biodiversidad, esta investigación busca aportar una solución innovadora para la identificación precisa y rápida de especies forestales, un desafío crítico en la preservación de los ecosistemas. La implementación de este modelo híbrido de aprendizaje automático podría mejorar drásticamente la eficacia del reconocimiento de especies forestales, lo que a su vez podría fortalecer las estrategias de conservación, monitoreo y gestión de los bosques amazónicos, salvaguardando así la biodiversidad y los hábitats de las comunidades locales e indígenas que dependen de ellos.

Desde la perspectiva académica, este estudio representa una valiosa contribución al campo de la clasificación de especies forestales mediante técnicas de aprendizaje automático. La utilización de un modelo híbrido, como la combinación de MobileNet y Regresión Logística, ofrece un enfoque novedoso y prometedor en la identificación precisa de especies forestales a partir de características de hojas. Los resultados y metodología obtenidos aquí pueden servir de base para investigaciones posteriores en la mejora y expansión de modelos de clasificación de especies forestales en otros ecosistemas y regiones geográficas.

Basándonos en los resultados y avances logrados en esta investigación, se plantea la propuesta de implementar este modelo híbrido en programas de monitoreo de la biodiversidad y manejo forestal sostenible. La aplicación práctica de este enfoque en el terreno podría fortalecer los esfuerzos de conservación, proporcionar información detallada sobre la diversidad de especies forestales y contribuir a estrategias de gestión forestal más efectivas. Se sugiere además la realización de estudios complementarios para mejorar

la versatilidad y robustez del modelo, adaptándolo a una mayor diversidad de especies y entornos forestales. En última instancia, este proyecto tiene el potencial de impulsar un cambio significativo en la forma en que se comprende, gestiona y preserva la riqueza biológica de los bosques amazónicos y, por extensión, de otros ecosistemas a nivel global.

CAPÍTULO VII: CONCLUSIONES

Entre las conclusiones de este trabajo de investigación, se tienen las siguientes:

- Se ha desarrollado e implementado un modelo híbrido de aprendizaje automático supervisado, siendo el de mejores resultados el modelo MobileNet+LR, que ha permitido clasificar eficientemente hasta 40 especies de árboles forestales amazónicos a partir de las características de sus hojas en imágenes.
- De acuerdo a los resultados obtenidos, se puede señalar que el modelo híbrido de aprendizaje automático supervisado, logra mejorar el proceso de clasificación de las especies de árboles forestales amazónicos a partir de las características de sus hojas en imágenes, siendo el modelo MobileNet+LR que destaca por sus índices de mejor resultado, de este modo se cumple la Hipótesis General.
- Se ha demostrado que se obtiene un alto índice de Precisión del 99.26% con el uso del modelo híbrido de MobileNet+LR, incrementando así la capacidad de clasificación de árboles forestales amazónicos, por sobre los modelos de CNN evaluados que en promedio llegan al 93.86%.
- Se ha demostrado que se obtiene un alto índice de Sensibilidad del modelo híbrido de MobileNet+LR de 99.07%, incrementando así la capacidad de clasificación de árboles forestales amazónicos, por sobre los modelos de CNN evaluados que en promedio llegan al 93.43%. Esto nos destaca la eficiencia del modelo para clasificar correctamente a las 40 especies de árboles (en caso que lo sean, ejemplo: Reconocer correctamente cuando es una hoja de la especie *Cedrela odorata*).
- Se ha demostrado que se obtiene un alto índice de Especificidad de 99.98% del modelo híbrido de MobileNet+LR, incrementando así la capacidad de clasificación de árboles forestales amazónicos, por sobre

los modelos de CNN evaluados que en promedio llegan al 99.74% pero tienen bajos índices de Precisión y Sensibilidad. Esto nos destaca la eficiencia del modelo para clasificar correctamente cuando no es una de las 40 especies de árboles (en caso que no lo sea, ejemplo: Reconocer correctamente cuando no es una hoja de la especie *Cedrela odorata* y pertenece a la especie *Cedrelinga ceteniformis*).

- Se ha demostrado que se obtiene un alto índice de F1-score de 99.06% del modelo híbrido de MobileNet+LR, incrementando así la capacidad de clasificación de árboles forestales amazónicos, por sobre los modelos de CNN evaluados que en promedio llegan al 92.78%. Esto nos destaca que el modelo tiene un alto rendimiento de clasificación de 40 especies de árboles forestales amazónicos, para el propósito de la investigación.

CAPÍTULO VIII: RECOMENDACIONES

- Se recomienda continuar con la investigación de modelos híbridos para la identificación de características de imágenes de hojas, como desarrollar la aplicación del método híbrido sin técnicas de pre-procesamiento y utilizando data de imágenes de hojas de herbarios.
- Se recomienda impulsar futuras investigaciones de forma interdisciplinaria con especialistas forestales, botánicos, ecólogos, biólogos y otros, que se encuentren relacionados al trabajo con especies arbóreas, para lograr una mejor complementación de la investigación, que permita una visión más global de problemáticas específicas sobre la protección, conservación y uso de especies forestales amazónicas de alta explotación, como el cedro, que en Perú se tiene 10 de las 19 subespecies identificadas a nivel mundial.
- Se recomienda para futuras investigaciones, realizar estudios sobre otras partes de identificación de las especies forestales amazónicas, como la textura del tronco, frutos, flores, semillas, y demás rasgos de identificación botánica.
- Se recomienda impulsar futuras investigaciones para identificación de especies de fauna silvestre amazónica, como de la familia de felinos (Jaguar, Tigre, Tigrillo, Leopardo, otros), teniendo en cuenta su importancia para conservación y la reducción de la caza y tráfico ilegal, de la biodiversidad de los bosques amazónicos, que aumentan su probabilidad de extinción.
- Se recomienda continuar con investigaciones relacionadas a la aplicación y experimentación de algoritmos de redes neuronales convolucionales del campo de la Inteligencia Artificial, una disciplina que ha cobrado mayor popularidad con el avance de la tecnología que nos facilita su estudio.

CAPÍTULO IX: REFERENCIAS BIBLIOGRÁFICAS

1. **Aquae Fundación.** AQUAE FUNDACIÓN. <https://www.fundacionaquae.org/>. [Online] 11 Agosto 2021. <https://www.fundacionaquae.org/wiki/dia-mundial-del-agua-la-importancia-los-arboles-preservar-planeta/>.
2. **(CPM), Confederación Peruana de la Madera.** *Compendio de información técnica de 32 especies forestales*. 2° Edición. Lima, Perú : s.n., 2008. p. 78.
3. **Chao, .** *Pueblos de los bosques: cifras mundiales*. Reino Unido : Forest Peoples Programme., 2012.
4. **Verly, .** <https://matanativa.com.br/>. [Online] 11 Marzo 2021. <https://matanativa.com.br/identificacao-de-especies-florestais/>.
5. *A Review on Classification Methods for Plants Leaves Recognition*. **Suwais, , Alhetii, and Al_Dosary, .** 2, 2022, International Journal of Advanced Computer Science and Applications, Vol. 13.
6. *A Review of Plant Phenotypic Image Recognition Technology Based on Deep Learning*. **Xiong, , et al.** 1, 2021, Electronics, Vol. 10.
7. *DDLAt: dual deep learning architecture for classification of plant species*. **Sundara Subitha, and Kumar Vajravelu, .** 12, 2019, The Insitution of Engineering and Technology Journals, Vol. 13, pp. 2176-2182.
8. *AyurLeaf: a deep learning approach for classification of medicinal plants*. **Dileep, and Pournami, .** Kochi : s.n., 2019, TENCON 2019 - 2019 IEEE Region 10 Conference (TENCON), pp. 321-325.
9. *Leaf recognition using convolutional neural networks based features*. *Multimedia Tools and Applications*. **Quach, Boi M., et al.** 2021, Computer Vision and Pattern Recognition.
10. *The Peruvian Amazon forestry dataset: A leaf image classification corpus*. **Vizcarra, , et al.** 2021, Ecological Informatics, Vol. 62.
11. *Machine learning for plant species classification using leaf vein morphometric*. **Malarvizhi, , et al.** 4, Abril 2021, International Journal of Engineering Research & Technology (IJERT), Vol. 10.
12. **Valenzuela Gonzáles, .** *Aprendizaje supervisado: Métodos, Propiedades y Aplicaciones*. Málaga : Facultad de Ciencias de la Universidad de Málaga, 2022.
13. **Matich, .** *Redes Neuronales: Conceptos básicos y aplicaciones*. s.l. : Universidad Tecnológica Nacional, 2001.
14. **Chique Rodriguez, .** *Medium*. [Online] 2 Septiembre 2020. <https://medium.com/@csarchiquerodriguez/maquina-de-soporte-vectorial-svm-92e9f1b1b1ac>.
15. **Microsoft.** Microsoft. [Online] 08 Octubre 2023. <https://learn.microsoft.com/es-es/azure/machine-learning/concept-deep-learning-vs-machine-learning?view=azureml-api-2#deep-learning-machine-learning-and-ai>.
16. **Artola Moreno, .** *Clasificación de imágenes usando redes neuronales convolucionales en Python*. s.l. : Universidad de Sevilla, 2019.
17. *A Survey on Transfer Learning*. **Pan, and Yang, .** 2010, IEEE Transactions on Knowledge and Data Engineering, p. 22.

18. **Gómez Ramírez**, . Data Science Engineer at DataSource.ai. *DataSource.ai*. [Online] 25 Septiembre 2023. <https://www.datasource.ai/es/data-science-articles/metricas-de-evaluacion-de-modelos-en-el-aprendizaje-automatico>.
19. *Identificación y descripción de diecinueve especies forestales del bosque húmedo tropical (bh-t) colonia Angamos (Río Yavarí) y Jenaro Herrera*. **Baluarte Vásquez, Juan Romel and Aróstegui Vargas**, . 1, 1990, Folia Amazónica, Vol. 2, pp. 37-69.
20. **Ramírez Durán**, , **Insuasty Burbano**, and **Murcia Pardo**, . *Variedades de Caña de Azúcar empleadas para la agroindustria panelera de Colombia*. [ed.] Susana Nivia Gil. Barbosa : Carvajal Soluciones de Comunicación, 2014.
21. **Navarro, Rafael M., Villar Salvador, and Del Campo**, . Morfología y establecimiento de los plantones. *Calidad de planta forestal para la restauración en ambientes mediterráneos. Estado actual de conocimientos*. 2006, pp. 67-88.
22. *Hybrid learning machines*. **Abraham**, , **Corchado**, and **Corchado**, . 2009, Neurocomputing.
23. *A review on feature selection and feature extraction for text classification*. **Shah, Foram P. and Patel**, . Chennai : s.n., 2016, 2016 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET), pp. 2264-2268.
24. *Classification techniques in machine learning: applications and issues*. **Soofi, A A and Awan**, . 1, 2017, urnal of Basic & Applied Sciences, Vol. 13.
25. *Model Evaluation, Model Selection, and Algorithm Selection in Machine Learning*. **Raschka**, . Noviembre 2020, Machine Learning.
26. *Towards a dynamic list of Amazonian tree species*. **Steege**, , et al. 2019, Scientific Reports.
27. *Control estricto de matrices de confusión por medio de distribuciones multinomiales*. **Ariza López**, , **Rodríguez Avi**, and **Alba Fernández**, . 21, 2018, Revista Internacional de Ciencia y Tecnología de la Información Geográfica (Geofocus), pp. 215-226.
28. *Accuracy and Precision in Enfineering*. **Gan Acosta**, , **Gan cuba**, **Wilson Antonio and Figueroa Coello**, . 12, 2008, Revista Colombiana de Tecnologías de Avanzada, Vol. 1.
29. *Estandarización de métricas de rendimiento para clasificadores Machine y Deep Learning*. **Borja Robalino**, and **Monleon Gatino**, . 30, Febrero 2020, Iberian Journal of Information Systems and Technologies.
30. **Gatis**, . Rembg. [Online] <https://github.com/danielgatis/rembg>.
31. *Multileveled ternary pattern and iterative ReliefF based bird sound classification*. **Tuncer**, , **Dogan**, and **Akbal**, . Mayo 2021, Applied Acoustics, Vol. 176.
32. *Best practices for machine learning applications*. **B.**, and **Hall**, . 2016, Computer Science.

ANEXOS

Anexo 1: Matriz de consistencia

Problema de Investigación	Objetivo de la Investigación	Hipótesis de la Investigación	Tipo de diseño de estudio	Población de estudio y procesamiento	Instrumento de recolección
<p>Problema General: ¿En qué medida la clasificación de especies de árboles forestales amazónicos a partir de características de hojas se mejorará utilizando un modelo híbrido de aprendizaje automático supervisado?</p> <p>Problemas específicos:</p> <ul style="list-style-type: none"> • ¿En qué medida el modelo híbrido de aprendizaje automático supervisado mejorará el Índice de Sensibilidad en la clasificación de especies de árboles forestales amazónicos? • ¿En qué medida el modelo híbrido de aprendizaje automático supervisado mejorará el Índice de 	<p>Objetivo General Desarrollar e implementar un modelo híbrido de aprendizaje automático supervisado para clasificar especies de árboles forestales amazónicos utilizando características de hojas.</p> <p>Objetivo Específicos</p> <ul style="list-style-type: none"> • Incrementar el Índice de Sensibilidad en la clasificación de especies de árboles forestales amazónicos. • Incrementar el Índice de Especificidad en la clasificación de especies de árboles forestales amazónicos. 	<p>Hipótesis General Un modelo híbrido de aprendizaje automático supervisado mejorará la clasificación de las especies de árboles forestales amazónicos utilizando características de hojas</p> <p>Hipótesis específicas</p> <ul style="list-style-type: none"> • Si se utiliza el modelo híbrido de aprendizaje automático supervisado incrementa el índice de sensibilidad en la clasificación de especies de árboles forestales amazónicos. 	<p>Tipo de Investigación La investigación es experimental del tipo comparativo</p> <p>Diseño de la Investigación La investigación pertenece al Diseño Experimento Factorial de un solo grupo. Debido a que se busca encontrar la combinación óptima de modelos de aprendizaje automático para obtener mejor desempeño en la clasificación de árboles forestales a partir de las características de</p>	<p>Población y Muestra:</p> <p>Población Se clasificaron 42 especies de hojas. Se tiene 2 mil fotos por cada especie, que hacen un total de 84 mil fotos de hojas.</p> <p>Muestra La investigación se realizó con todos los elementos de la población, en consecuencia, estuvo constituido por el 100% de la población por conveniencia.</p>	<p>Matriz de confusión Cuaderno de notas Fichas de observación</p>

Problema de Investigación	Objetivo de la Investigación	Hipótesis de la Investigación	Tipo de diseño de estudio	Población de estudio y procesamiento	Instrumento de recolección
<p>Especificidad en la clasificación de especies de árboles forestales amazónicos?</p> <ul style="list-style-type: none"> • ¿En qué medida el modelo híbrido de aprendizaje automático supervisado mejorará el Índice de Precisión en la clasificación de especies de árboles forestales amazónicos? • ¿En qué medida el modelo híbrido de aprendizaje automático supervisado mejorará la métrica F1-score en la clasificación de especies de árboles forestales amazónicos? 	<ul style="list-style-type: none"> • Incrementar el Índice de Precisión en la clasificación de especies de árboles forestales amazónicos. • Incrementar F1-Score en la clasificación de especies de árboles forestales amazónicos. 	<ul style="list-style-type: none"> • Si se utiliza el modelo híbrido de aprendizaje automático supervisado incrementa el índice de Especificidad en la clasificación de especies de árboles forestales amazónicos. • Si se utiliza el modelo híbrido de aprendizaje automático supervisado incrementa el índice de Precisión en la clasificación de especies de árboles forestales amazónicos. • Si se utiliza el modelo híbrido de aprendizaje automático supervisado incrementa F1-score en la 	<p>las hojas en un solo dataset.</p>		

Problema de Investigación	Objetivo de la Investigación	Hipótesis de la Investigación	Tipo de diseño de estudio	Población de estudio y procesamiento	Instrumento de recolección
		clasificación de especies de árboles forestales amazónicos.			

Anexo 2: Tabla de operacionalización de variables

Variable	Definición conceptual	Definición operacional	Indicador	Instrumento
<p>Variable de independiente</p> <p>Modelo híbrido de aprendizaje automático supervisado</p>	<p>Es el modelo desarrollado para la clasificación de especies de árboles forestales, que estará implementado con algoritmos y técnicas de aprendizaje supervisado, en cual se combinan métodos y enfoques para extraer características, aprender patrones y realizar la clasificación o predicción de manera eficiente y precisa.</p>	<p>Se implementarán diferentes modelos de aprendizaje automático supervisado definidos previa investigación y estado de arte, en la extracción de características y clasificación de las hojas.</p>	<ul style="list-style-type: none"> • Tiempo de entrenamiento • Exactitud en entrenamiento • Perdida en entrenamiento • Exactitud en validación • Perdida en validación 	<p>Cuaderno de notas</p> <p>Fichas de observación</p>
<p>Variable dependiente</p> <p>Clasificación de especies de árboles forestales amazónicos a partir de las características de hojas</p>	<p>La clasificación de especies de árboles forestales amazónicos a partir de las características de hojas se refiere a la capacidad de identificar y distinguir diferentes especies de árboles en la región amazónica a través del análisis de características específicas de sus hojas.</p>	<p>Se medirá la tasa de precisión de la clasificación de especies de árboles forestales amazónicos a partir de las características de las hojas. Esta precisión se determinará comparando las etiquetas de especies reales de las hojas con las etiquetas de especies asignadas por el modelo de clasificación.</p>	<ul style="list-style-type: none"> • Índice de Sensibilidad • Índice de Especificidad • Índice de Precisión • F1-Score 	<p>Matriz de confusión</p> <p>Fichas de observación</p>

Anexo 3: Instrumento(s) de recolección de datos

Ficha de observación para la variable independiente: Modelo híbrido de aprendizaje automático supervisado

	VGG-19	MobileNet	DenseNet
Tiempo entrenamiento			
Precisión en entrenamiento			
Pérdida en entrenamiento			
Precisión en validación			
Pérdida en validación			
SVM			
Tiempo entrenamiento			
Training Accuracy			
Training Hinge Loss			
Validation Accuracy			
Validation Hinge Loss			
LR			
Tiempo entrenamiento			
Training Accuracy			
Training Hinge Loss			
Validation Accuracy			
Validation Hinge Loss			

Ficha de observación para la variable dependiente: Clasificación de especies de árboles forestales amazónicos a partir de las características de hojas

Modelo		Precisión	Sensibilidad	Especificidad	F1-Score
CNN	VGG-19				
	MobileNet				
	DenseNet				
Híbrido	VGG-19+SVM				
	VGG-19+LR				
	MobileNet-19+SVM				
	MobileNet+LR				
	DenseNet+SVM				
	DenseNet+LR				

Anexo 4: Arquitecturas de las redes neuronales

a. Arquitectura VGG-19

```
Model: "VGG-19"
```

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 512, 512, 3)]	0
block1_conv1 (Conv2D)	(None, 512, 512, 64)	1792
block1_conv2 (Conv2D)	(None, 512, 512, 64)	36928
block1_pool (MaxPooling2D)	(None, 256, 256, 64)	0
block2_conv1 (Conv2D)	(None, 256, 256, 128)	73856
block2_conv2 (Conv2D)	(None, 256, 256, 128)	147584
block2_pool (MaxPooling2D)	(None, 128, 128, 128)	0
block3_conv1 (Conv2D)	(None, 128, 128, 256)	295168
block3_conv2 (Conv2D)	(None, 128, 128, 256)	590880
block3_conv3 (Conv2D)	(None, 128, 128, 256)	590880
block3_conv4 (Conv2D)	(None, 128, 128, 256)	590880
block3_pool (MaxPooling2D)	(None, 64, 64, 256)	0
block4_conv1 (Conv2D)	(None, 64, 64, 512)	1180160
block4_conv2 (Conv2D)	(None, 64, 64, 512)	2359808
block4_conv3 (Conv2D)	(None, 64, 64, 512)	2359808
block4_conv4 (Conv2D)	(None, 64, 64, 512)	2359808
block4_pool (MaxPooling2D)	(None, 32, 32, 512)	0
block5_conv1 (Conv2D)	(None, 32, 32, 512)	2359808
block5_conv2 (Conv2D)	(None, 32, 32, 512)	2359808
block5_conv3 (Conv2D)	(None, 32, 32, 512)	2359808
block5_conv4 (Conv2D)	(None, 32, 32, 512)	2359808
block5_pool (MaxPooling2D)	(None, 16, 16, 512)	0
flatten (Flatten)	(None, 131072)	0
fc1 (Dense)	(None, 128)	16777344
fc2 (Dense)	(None, 128)	16512
output (Dense)	(None, 40)	5160

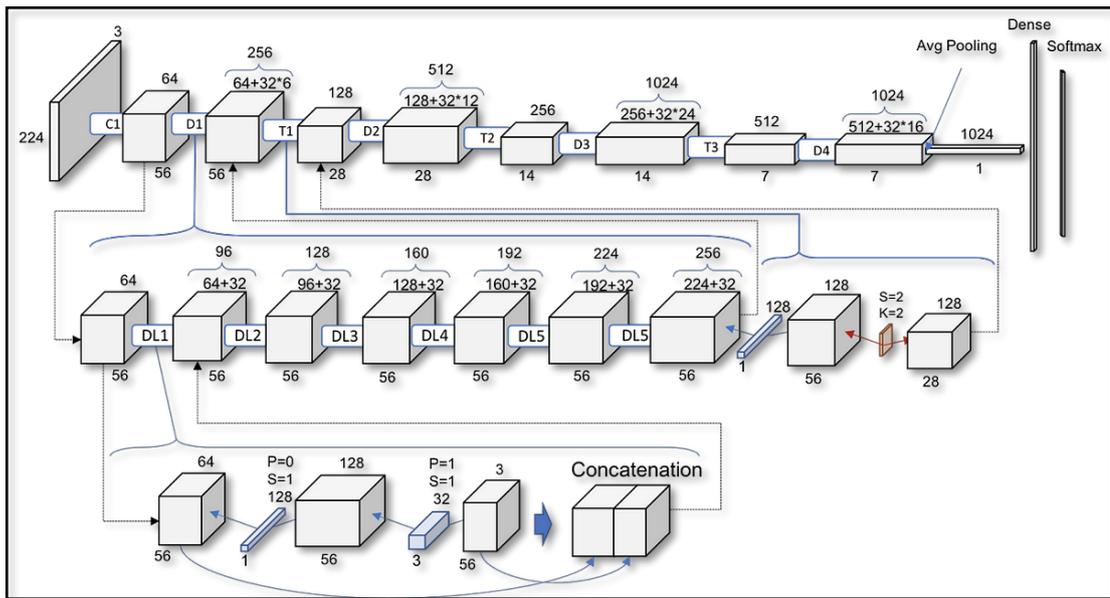
```
=====  
Total params: 36,823,400  
Trainable params: 36,823,400  
Non-trainable params: 0  
=====
```

b. Arquitectura MobileNet

Model: 'MobileNet'		
Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 512, 512, 3)]	0
conv1 (Conv2D)	(None, 256, 256, 32)	864
conv1_bn (BatchNormalization)	(None, 256, 256, 32)	128
conv1_relu (ReLU)	(None, 256, 256, 32)	0
conv_dw_1 (DepthwiseConv2D)	(None, 256, 256, 32)	288
conv_dw_1_bn (BatchNormalization)	(None, 256, 256, 32)	128
conv_dw_1_relu (ReLU)	(None, 256, 256, 32)	0
conv_pw_1 (Conv2D)	(None, 256, 256, 64)	2048
conv_pw_1_bn (BatchNormalization)	(None, 256, 256, 64)	256
conv_pw_1_relu (ReLU)	(None, 256, 256, 64)	0
conv_pad_2 (ZeroPadding2D)	(None, 257, 257, 64)	0
conv_dw_2 (DepthwiseConv2D)	(None, 128, 128, 64)	576
conv_dw_2_bn (BatchNormalization)	(None, 128, 128, 64)	256
conv_dw_2_relu (ReLU)	(None, 128, 128, 64)	0
conv_pw_2 (Conv2D)	(None, 128, 128, 128)	8192
conv_pw_2_bn (BatchNormalization)	(None, 128, 128, 128)	512
conv_pw_2_relu (ReLU)	(None, 128, 128, 128)	0
conv_dw_3 (DepthwiseConv2D)	(None, 128, 128, 128)	1152
conv_dw_3_bn (BatchNormalization)	(None, 128, 128, 128)	512
conv_dw_3_relu (ReLU)	(None, 128, 128, 128)	0
conv_pw_3 (Conv2D)	(None, 128, 128, 128)	16384
conv_pw_3_bn (BatchNormalization)	(None, 128, 128, 128)	512
conv_pw_3_relu (ReLU)	(None, 128, 128, 128)	0
conv_pad_4 (ZeroPadding2D)	(None, 129, 129, 128)	0
conv_dw_4 (DepthwiseConv2D)	(None, 64, 64, 128)	1152
conv_dw_4_bn (BatchNormalization)	(None, 64, 64, 128)	512
conv_dw_4_relu (ReLU)	(None, 64, 64, 128)	0
conv_pw_4 (Conv2D)	(None, 64, 64, 256)	32768
conv_pw_4_bn (BatchNormalization)	(None, 64, 64, 256)	1024
conv_pw_4_relu (ReLU)	(None, 64, 64, 256)	0
conv_dw_5 (DepthwiseConv2D)	(None, 64, 64, 256)	2304
conv_dw_5_bn (BatchNormalization)	(None, 64, 64, 256)	1024
conv_dw_5_relu (ReLU)	(None, 64, 64, 256)	0
conv_pw_5 (Conv2D)	(None, 64, 64, 256)	65536
conv_pw_5_bn (BatchNormalization)	(None, 64, 64, 256)	1024
conv_pw_5_relu (ReLU)	(None, 64, 64, 256)	0
conv_pad_5 (ZeroPadding2D)	(None, 65, 65, 256)	0
conv_dw_6 (DepthwiseConv2D)	(None, 32, 32, 256)	2304
conv_dw_6_bn (BatchNormalization)	(None, 32, 32, 256)	1024
conv_dw_6_relu (ReLU)	(None, 32, 32, 256)	0
conv_pw_6 (Conv2D)	(None, 32, 32, 512)	131072
conv_pw_6_bn (BatchNormalization)	(None, 32, 32, 512)	2048
conv_pw_6_relu (ReLU)	(None, 32, 32, 512)	0
conv_dw_7 (DepthwiseConv2D)	(None, 32, 32, 512)	4608
conv_dw_7_bn (BatchNormalization)	(None, 32, 32, 512)	2048
conv_dw_7_relu (ReLU)	(None, 32, 32, 512)	0
conv_pw_7 (Conv2D)	(None, 32, 32, 512)	262144
conv_pw_7_bn (BatchNormalization)	(None, 32, 32, 512)	2048
conv_pw_7_relu (ReLU)	(None, 32, 32, 512)	0
conv_dw_8 (DepthwiseConv2D)	(None, 32, 32, 512)	4608
conv_dw_8_bn (BatchNormalization)	(None, 32, 32, 512)	2048
conv_dw_8_relu (ReLU)	(None, 32, 32, 512)	0
conv_pw_8 (Conv2D)	(None, 32, 32, 512)	262144
conv_pw_8_bn (BatchNormalization)	(None, 32, 32, 512)	2048
conv_pw_8_relu (ReLU)	(None, 32, 32, 512)	0
conv_dw_9 (DepthwiseConv2D)	(None, 32, 32, 512)	4608
conv_dw_9_bn (BatchNormalization)	(None, 32, 32, 512)	2048
conv_dw_9_relu (ReLU)	(None, 32, 32, 512)	0
conv_pw_9 (Conv2D)	(None, 32, 32, 512)	262144
conv_pw_9_bn (BatchNormalization)	(None, 32, 32, 512)	2048
conv_pw_9_relu (ReLU)	(None, 32, 32, 512)	0
conv_dw_10 (DepthwiseConv2D)	(None, 32, 32, 512)	4608
conv_dw_10_bn (BatchNormalization)	(None, 32, 32, 512)	2048
conv_dw_10_relu (ReLU)	(None, 32, 32, 512)	0
conv_pw_10 (Conv2D)	(None, 32, 32, 512)	262144
conv_pw_10_bn (BatchNormalization)	(None, 32, 32, 512)	2048
conv_pw_10_relu (ReLU)	(None, 32, 32, 512)	0
conv_dw_11 (DepthwiseConv2D)	(None, 32, 32, 512)	4608
conv_dw_11_bn (BatchNormalization)	(None, 32, 32, 512)	2048
conv_dw_11_relu (ReLU)	(None, 32, 32, 512)	0
conv_pw_11 (Conv2D)	(None, 32, 32, 512)	262144
conv_pw_11_bn (BatchNormalization)	(None, 32, 32, 512)	2048
conv_pw_11_relu (ReLU)	(None, 32, 32, 512)	0
conv_pad_12 (ZeroPadding2D)	(None, 33, 33, 512)	0
conv_dw_12 (DepthwiseConv2D)	(None, 16, 16, 512)	4608
conv_dw_12_bn (BatchNormalization)	(None, 16, 16, 512)	2048
conv_dw_12_relu (ReLU)	(None, 16, 16, 512)	0
conv_pw_12 (Conv2D)	(None, 16, 16, 1024)	524288
conv_pw_12_bn (BatchNormalization)	(None, 16, 16, 1024)	4096
conv_pw_12_relu (ReLU)	(None, 16, 16, 1024)	0
conv_dw_13 (DepthwiseConv2D)	(None, 16, 16, 1024)	9216
conv_dw_13_bn (BatchNormalization)	(None, 16, 16, 1024)	4096
conv_dw_13_relu (ReLU)	(None, 16, 16, 1024)	0
conv_pw_13 (Conv2D)	(None, 16, 16, 1024)	1048576
conv_pw_13_bn (BatchNormalization)	(None, 16, 16, 1024)	4096
conv_pw_13_relu (ReLU)	(None, 16, 16, 1024)	0
Flatten (Flatten)	(None, 262144)	0
dense (Dense)	(None, 1024)	268436480
dropout (Dropout)	(None, 1024)	0
dense_1 (Dense)	(None, 1024)	1049500
dropout_1 (Dropout)	(None, 1024)	0
dense_2 (Dense)	(None, 40)	41000

Total params: 272,755,944
Trainable params: 272,734,056
Non-trainable params: 21,888

c. Arquitectura DenseNet



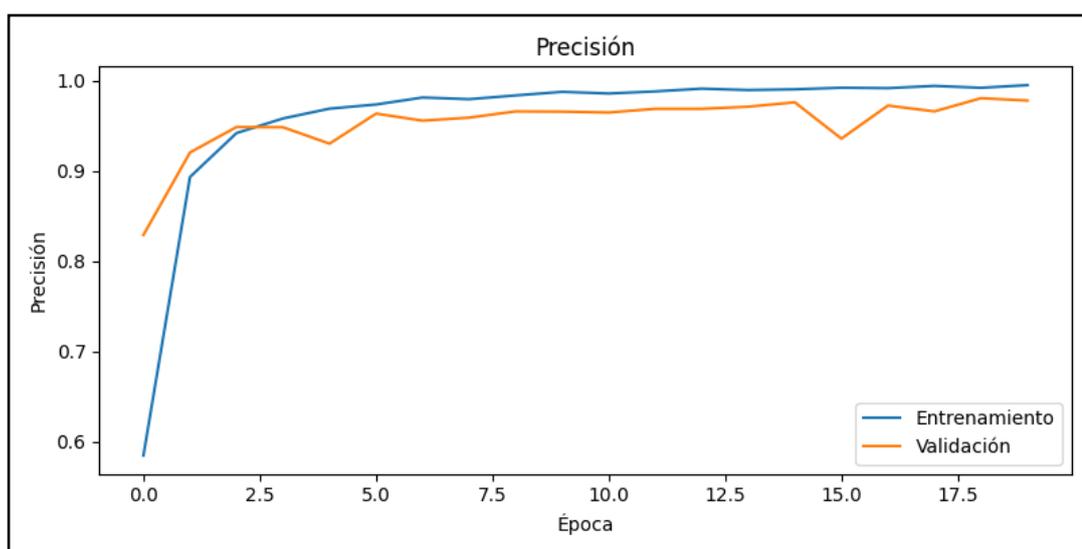
Fuente: Towards Data Science. 2018. Disponible en: <https://towardsdatascience.com/understanding-and-visualizing-densenets-7f688092391a>

Anexo 5: Curvas de entrenamiento de modelos de CNN

5. Resultados de entrenamiento del modelo VGG-19

En figura a continuación, se observa que la curva de la precisión en el entrenamiento y validación del modelo VGG-19 aumenta rápidamente en las primeras épocas y luego mantiene una pendiente mínima de crecimiento. Así mismo se observa que en la validación hay algunos picos de caída de la precisión.

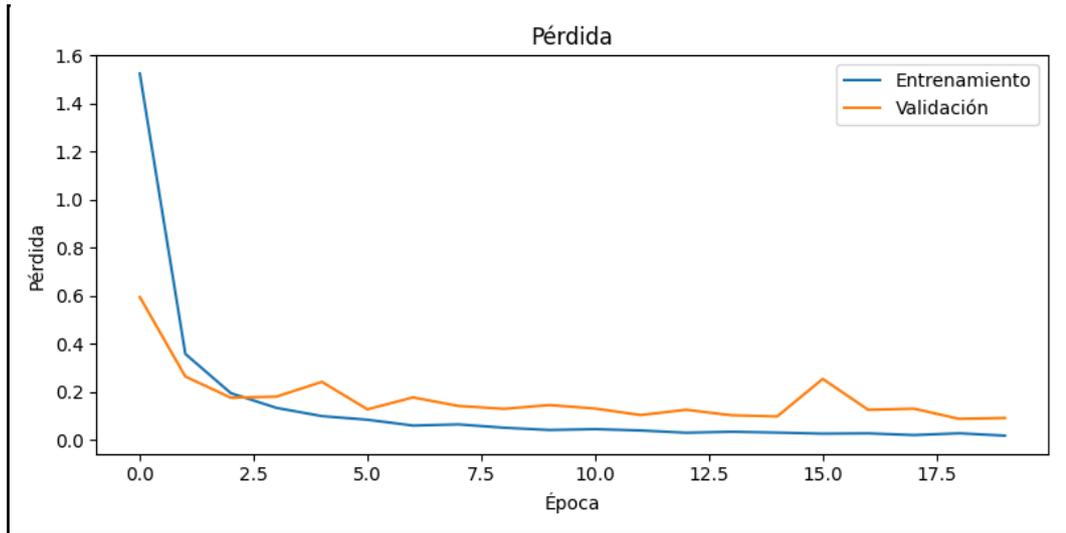
Curva de la precisión en el entrenamiento y validación del modelo VGG-19



Fuente: Elaboración propia

En la figura a continuación, se observa que la curva de la función de pérdida en el entrenamiento y validación del modelo VGG-19 disminuye rápidamente en las primeras épocas y luego mantiene una pendiente mínima de descenso. Así mismo se observa que en la validación hay algunos picos de aumento en la pérdida.

Curva de la función de pérdida en el entrenamiento y validación del modelo VGG-19

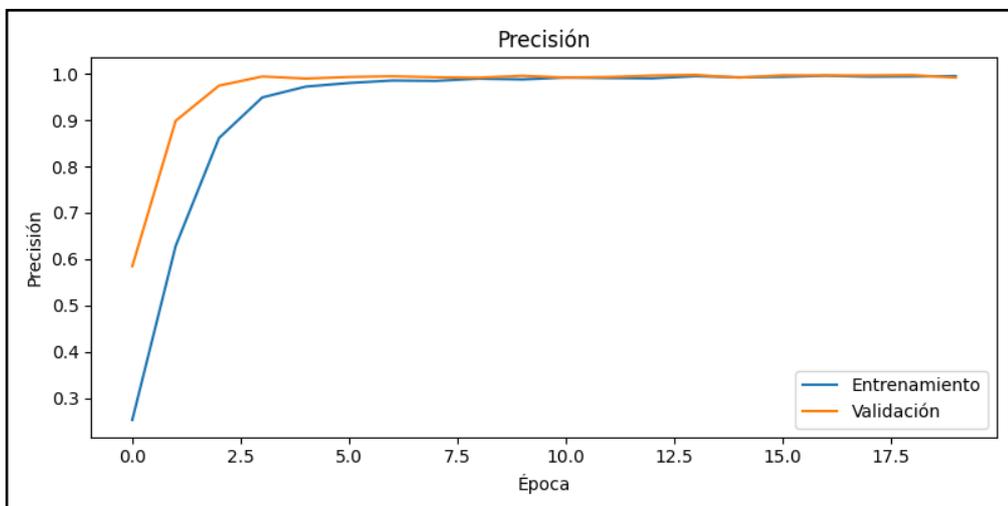


Fuente: Elaboración propia

6. Resultados de entrenamiento del modelo MobileNet

En la figura a continuación, se observa que la curva de la precisión en el entrenamiento y validación del modelo MobileNet aumenta rápidamente en las primeras épocas y luego mantiene una pendiente mínima de crecimiento. Se observa que la curva de entrenamiento y validación hay una buena concordancia o similitud por lo que está logrando una buena generalización.

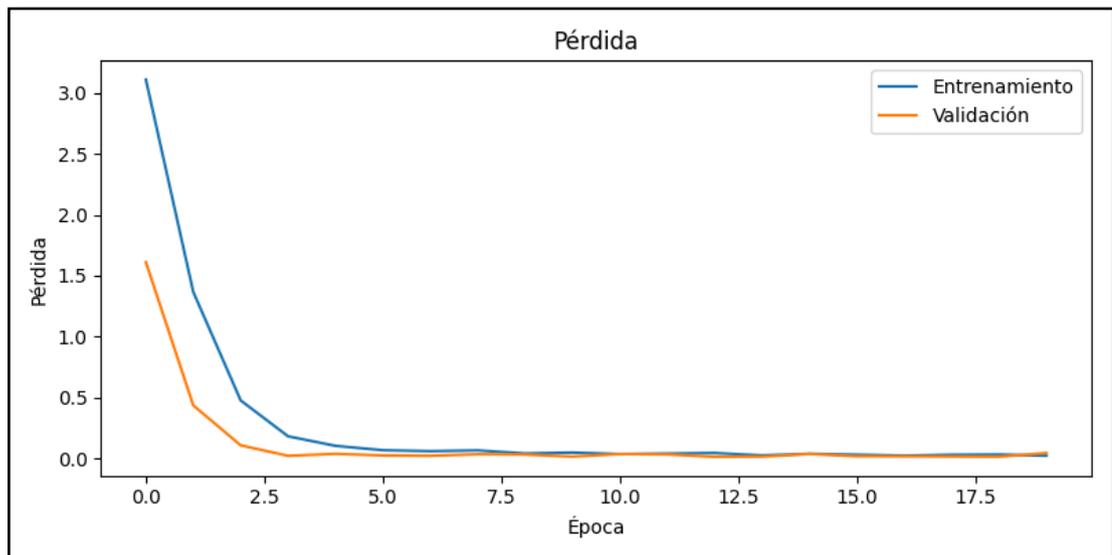
Curva de la precisión en el entrenamiento y validación del modelo MobileNet



Fuente: Elaboración propia

En la figura a continuación, se observa que la curva de la función de pérdida en el entrenamiento y validación del modelo MobileNet disminuye rápidamente en las primeras épocas y luego mantiene una pendiente mínima de descenso. Así mismo se observa que en la curva de entrenamiento y validación hay una buena concordancia.

Curva de la función de pérdida en el entrenamiento y validación del modelo MobileNet

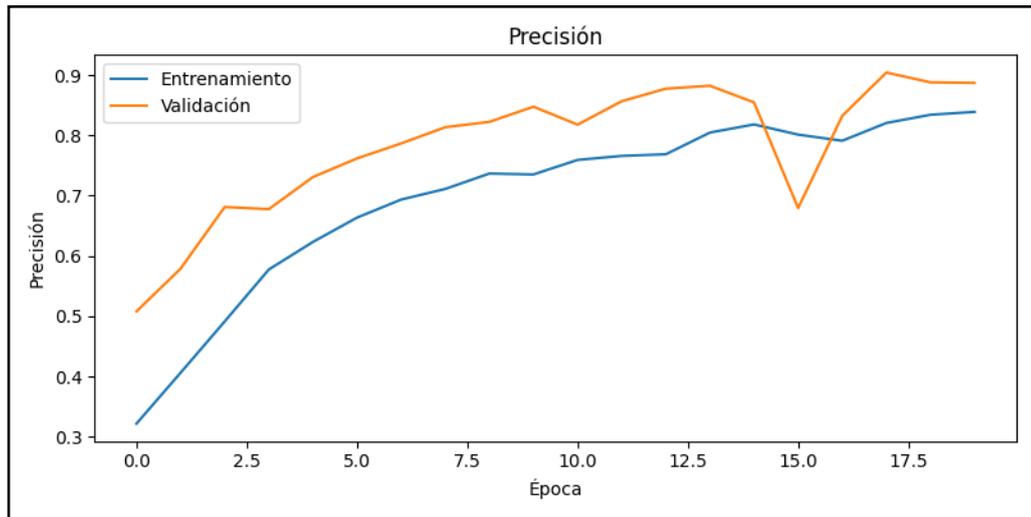


Fuente: Elaboración propia

7. Resultados de entrenamiento del modelo DenseNet

En la figura a continuación, se observa que la curva de la precisión en el entrenamiento y validación del modelo DenseNet aumenta gradualmente durante la mitad de las épocas y luego tiene un descenso significativo y en las últimas épocas mantiene un crecimiento aceptable. Así mismo se observa que en la curva de entrenamiento y validación hay una leve diferencia por lo que está logrando una generalización baja en el modelo.

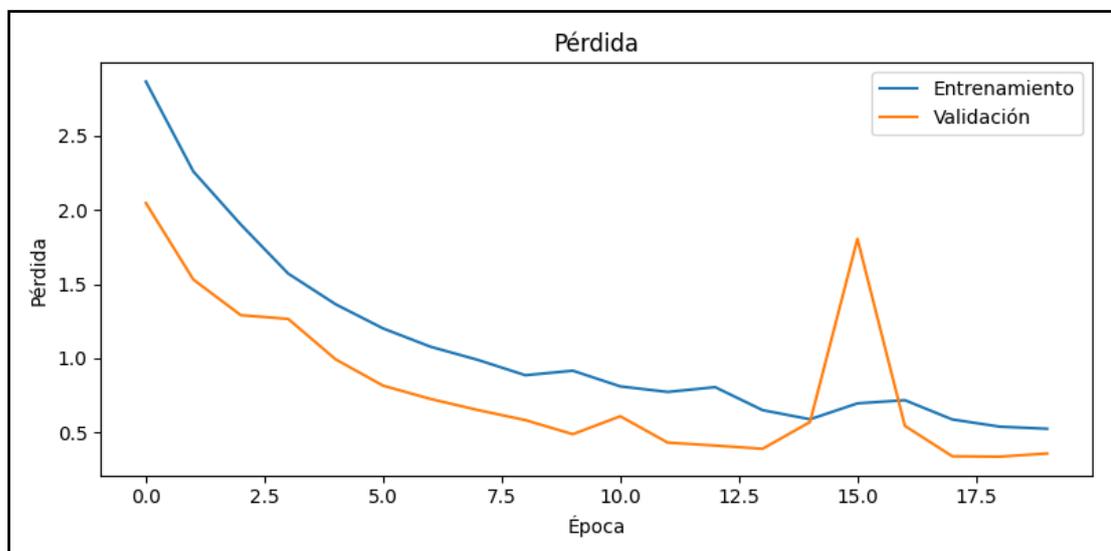
Curva de la función de pérdida en el entrenamiento y validación del modelo DenseNet



Fuente: Elaboración propia

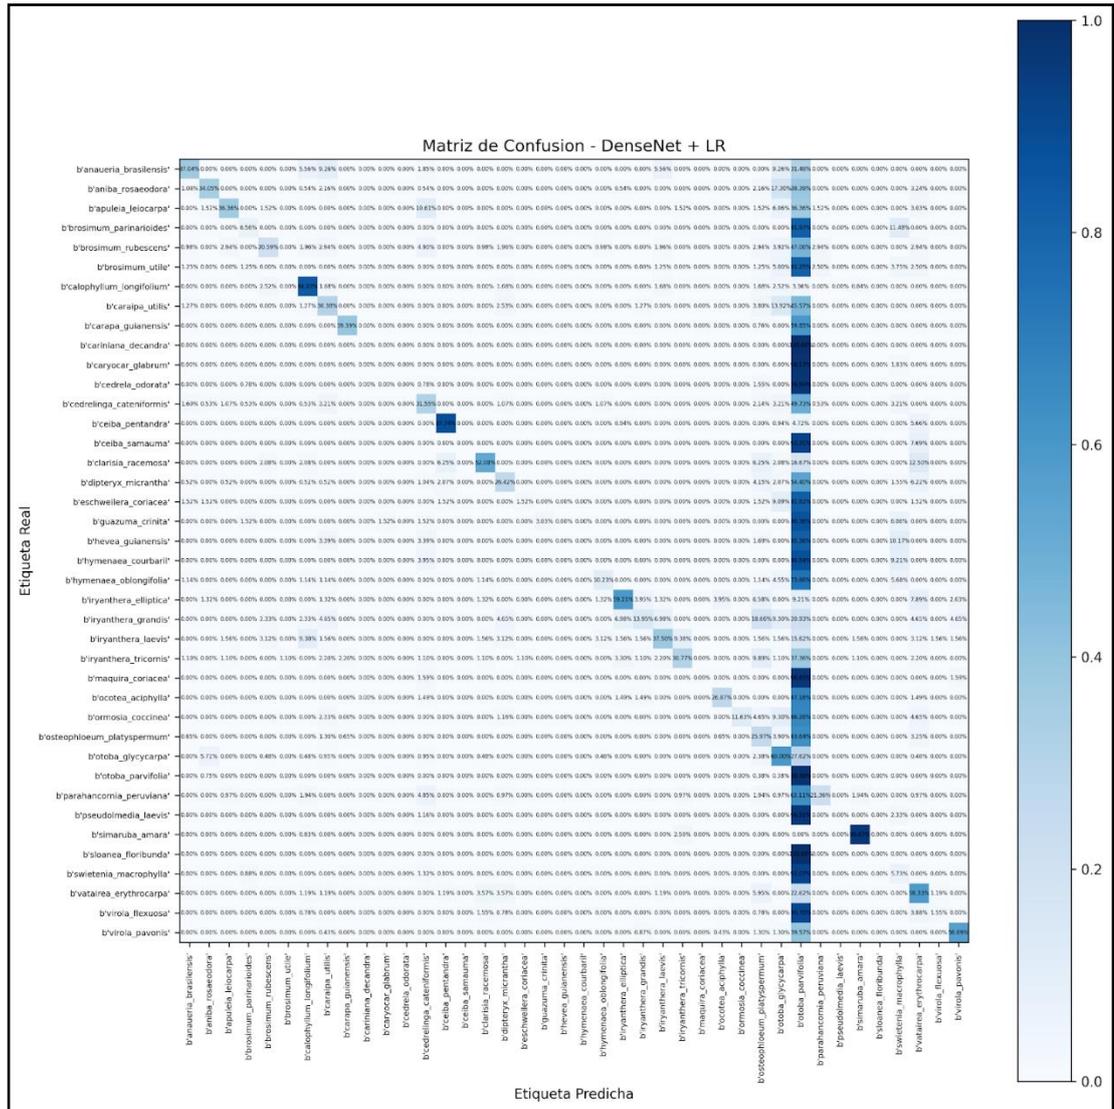
En la figura a continuación, se observa que la curva de la función de pérdida en el entrenamiento y validación del modelo DenseNet disminuye progresivamente durante la mitad de las épocas y luego en las últimas épocas en el entrenamiento desciende hasta tener una pérdida baja. Así mismo se observa que en la curva de validación se tiene un leve incremento, por lo que no está teniendo una buena concordancia.

Curva de la función de pérdida en el entrenamiento y validación del modelo DenseNet



Fuente: Elaboración propia

Matriz de confusión de DenseNet+LR usando dataset de prueba



Fuente: Elaboración propia

Anexo 7: Código fuente para el procesamiento del datasets

El código contiene las funciones de eliminación de fondo, extracción de objeto de interés, redimensionamiento y rotación desde una carpeta de imágenes.

```
import os
from rembg import remove, new_session
from PIL import Image
import os
import cv2
import numpy as np

model_name = "isnet-general-use"
session = new_session(model_name)

def resize_with_padding(original_image, target_size):
    original_height, original_width = original_image.shape[:2]
    scaling_factor = min(target_size[0] / original_width,
target_size[1] / original_height)
    new_width = int(original_width * scaling_factor)
    new_height = int(original_height * scaling_factor)
    resized_image = cv2.resize(original_image, (new_width, new_height))

    canvas = np.zeros((target_size[1], target_size[0], 4),
dtype=np.uint8)
    x_offset = (target_size[0] - new_width) // 2
    y_offset = (target_size[1] - new_height) // 2
    canvas[y_offset:y_offset+new_height, x_offset:x_offset+new_width] =
resized_image

    return canvas

def get_bboxes(contour, label='Hojas'):
    x, y, w, h = cv2.boundingRect(contour)
    aumento = 50
    x -= aumento
    y -= aumento
    w += 2 * aumento
    h += 2 * aumento
    # Asegurarse de que los valores no sean negativos
    x = max(x, 0)
    y = max(y, 0)
    box = np.array([
        x,
        y,
        x + w,
        y + h
```

```

    ])
    return box

def get_largest_contour(image):
    gray = cv2.cvtColor(np.array(image), cv2.COLOR_BGR2GRAY)
    contours, _ = cv2.findContours(gray, cv2.RETR_EXTERNAL,
cv2.CHAIN_APPROX_SIMPLE)
    if contours:
        largest_contour = max(contours, key=cv2.contourArea)
        return largest_contour
    else:
        return None

def fill_background_with_black(image):
    alpha_channel = image[:, :, 3]
    image[alpha_channel == 0] = [0, 0, 0, 255]
    return image

def remove_fondo(img, target_size):
    img_np = np.array(img)
    #output = remove(img_np)
    output = remove(img_np, session=session)
    largest_contour = get_largest_contour(output)
    # Obtenemos los bordes
    box = get_bboxes(largest_contour)

    output = output[box[1]:box[3], box[0]:box[2]]

    if box[2] - box[0] > box[3] - box[1]:
        output = np.rot90(output)

    output = resize_with_padding(output, target_size)
    output = fill_background_with_black(output)

    return output

# Función para recorrer una carpeta y sus subcarpetas
def procesar_carpeta_entrada(entrada, salida):
    for directorio_raiz, directorios, archivos in os.walk(entrada):
        for archivo in archivos:
            # Construir rutas de entrada y salida
            ruta_entrada = os.path.join(directorio_raiz, archivo)
            ruta_salida = os.path.join(salida,
os.path.relpath(ruta_entrada, entrada))
            # Asegurarse de que el directorio de salida exista
            if not os.path.exists(ruta_salida):

```

```
        os.makedirs(os.path.dirname(ruta_salida),
exist_ok=True)
        # Abrir la imagen y procesarla
        try:
            remove_fondo(ruta_entrada,ruta_salida,target_size=(2
048, 2048))
        except (IOError, OSError):
            print(f"El archivo {ruta_entrada} no es una imagen
válida y no se procesará.")
        except Exception as e:
            print(f"Error al procesar el archivo
{ruta_entrada}: {str(e)}")

        print("Imagen procesada: ", ruta_salida)

# Directorio de entrada con fotos y subcarpetas
directorio_entrada = ""

# Directorio de salida para las fotos procesadas
directorio_salida = ""

procesar_carpeta_entrada(directorio_entrada, directorio_salida)
```

Anexo 8: Código fuente para ejecutar la predicción del modelo híbrido

```
import os
import tensorflow as tf
from tensorflow.keras.models import Model
from rembg import remove, new_session
from PIL import Image
import os
import cv2
import numpy as np
import matplotlib.pyplot as plt
import joblib

model_name = "isnet-general-use"
session = new_session(model_name)
##Archivo con el nombre de las clases en orden alfabético en minúscula
LABELS_PATH = "labels.txt"

def resize_with_padding(original_image, target_size):
    original_height, original_width = original_image.shape[:2]
    scaling_factor = min(target_size[0] / original_width,
target_size[1] / original_height)
    new_width = int(original_width * scaling_factor)
    new_height = int(original_height * scaling_factor)
    resized_image = cv2.resize(original_image, (new_width, new_height))

    canvas = np.zeros((target_size[1], target_size[0], 4),
dtype=np.uint8)
    x_offset = (target_size[0] - new_width) // 2
    y_offset = (target_size[1] - new_height) // 2
    canvas[y_offset:y_offset+new_height, x_offset:x_offset+new_width] =
resized_image

    return canvas

def get_bboxes(contour, label='Hojas'):
    x, y, w, h = cv2.boundingRect(contour)
    aumento = 50
    x -= aumento
    y -= aumento
    w += 2 * aumento
    h += 2 * aumento
    # Asegurarse de que los valores no sean negativos
    x = max(x, 0)
    y = max(y, 0)
    box = np.array([
        x,
        y,
```

```

        x + w,
        y + h
    ])
    return box

def get_largest_contour(image):
    gray = cv2.cvtColor(np.array(image), cv2.COLOR_BGR2GRAY)
    contours, _ = cv2.findContours(gray, cv2.RETR_EXTERNAL,
cv2.CHAIN_APPROX_SIMPLE)
    if contours:
        largest_contour = max(contours, key=cv2.contourArea)
        return largest_contour
    else:
        return None

def fill_background_with_black(image):
    alpha_channel = image[:, :, 3]
    image[alpha_channel == 0] = [0, 0, 0, 255]
    return image

def remove_fondo(img, target_size):
    img_np = np.array(img)
    #output = remove(img_np)
    output = remove(img_np, session=session)
    largest_contour = get_largest_contour(output)
    # Obtenemos los bordes
    box = get_bboxes(largest_contour)

    output = output[box[1]:box[3], box[0]:box[2]]

    if box[2] - box[0] > box[3] - box[1]:
        output = np.rot90(output)

    output = resize_with_padding(output, target_size)
    output = fill_background_with_black(output)

    return output

def preprocessing(img):
    image = remove_fondo(img, target_size = (512, 512) )
    output_image = Image.fromarray(image)

    processed_image_path = "temp/image_without_background.png"
    output_image.save(processed_image_path)

    with open(LABELS_PATH, 'r') as file:
        labels = file.read().splitlines()

```

```

    return processed_image_path, labels

def make_prediction(img, cnn_model, cnn_feature_extractor_model,
lr_model, svm_model):
    processed_image_path, labels = preprocessing(img)

    img = tf.keras.preprocessing.image.load_img(processed_image_path,
target_size=(512, 512))
    img_array = tf.keras.preprocessing.image.img_to_array(img)
    img_array = np.expand_dims(img_array, axis=0)
    img_array_preprocessed = preprocess_function(img_array)

    features =
cnn_feature_extractor_model.predict(img_array_preprocessed)
    svm_prediction = svm_model.predict(features)
    lr_prediction = lr_model.predict(features)

    prediction = cnn_model.predict(img_array_preprocessed)
    predicted_class_index = np.argmax(prediction, axis=1)
    predicted_label = labels[predicted_class_index[0]]

    # Convertir las predicciones a texto
    svm_prediction_text = ''.join([chr(int(code)) for code in
svm_prediction[0]])
    lr_prediction_text = ''.join([chr(int(code)) for code in
lr_prediction[0]])

    return svm_prediction_text, lr_prediction_text, predicted_label,
processed_image_path

def select_classification_method(slected_model):
    if slected_model == "VGG-19":
        model = "vgg19"
        preprocess_function = getattr(tf.keras.applications,
model).preprocess_input
    elif slected_model == "MobileNet":
        model = "mobilenet"
        preprocess_function = getattr(tf.keras.applications,
model).preprocess_input
    elif slected_model == "DenseNet-121":
        model = "densenet"
        preprocess_function = getattr(tf.keras.applications,
model).preprocess_input

    MODEL_CNN_PATH = os.path.join(model, "512x512/model.h5")
    MODEL_CNN_FEATURE_EXTRACTOR_PATH = os.path.join(model,
"512x512/feature_extractor.h5")
    MODEL_LR_PATH = os.path.join(model, "512x512/lr_model.pkl")

```

```
MODEL_SVM_PATH = os.path.join(model, "512x512/svm_model.pkl")

    return MODEL_CNN_PATH, MODEL_CNN_FEATURE_EXTRACTOR_PATH,
MODEL_LR_PATH, MODEL_SVM_PATH, preprocess_function

classification_method="MobileNet"

MODEL_CNN_PATH, MODEL_CNN_FEATURE_EXTRACTOR_PATH, MODEL_LR_PATH,
MODEL_SVM_PATH, preprocess_function =
select_classification_method(classification_method)

cnn_model=tf.keras.models.load_model(MODEL_CNN_PATH)
cnn_feature_extractor_model=tf.keras.models.load_model(MODEL_CNN_FEATUR
E_EXTRACTOR_PATH)
lr_model=joblib.load(MODEL_LR_PATH)
svm_model =joblib.load(MODEL_SVM_PATH)

path_IMG="caryocar_glabrum.a32_20211026_072324.jpg"
img = Image.open(path_IMG)

svm_prediction, lr_prediction, predicted_label, processed_image_path =
make_prediction(img, cnn_model, cnn_feature_extractor_model, lr_model,
svm_model)
print("svm_prediction",svm_prediction)
print("lr_prediction",lr_prediction)
print("cnn_prediction",predicted_label)
```