**UNIVERSIDAD CATÓLICA SANTO TORIBIO DE MOGROVEJO**

**FACULTAD DE INGENIERÍA**

**ESCUELA DE INGENIERÍA DE SISTEMAS Y COMPUTACIÓN**

# Implementación de una API con base en redes neuronales convolucionales para la validación e identificación de árboles en Chiclayo

**TESIS PARA OPTAR EL TÍTULO DE**

**INGENIERO DE SISTEMAS Y COMPUTACIÓN**

**AUTOR**

**Cinthia Nayeli Sanchez Cieza**

**ASESOR**

**Huilder Juanito Mera Montenegro**

https://orcid.org/0000-0001-6830-5415

**Chiclayo, 2025**

# Implementación de una API con base en redes neuronales convolucionales para la validación e identificación de árboles en Chiclayo

PRESENTADA POR

**Cinthia Nayeli Sanchez Cieza**

A la Facultad de Ingeniería de la
Universidad Católica Santo Toribio de Mogrovejo
para optar el título de

**INGENIERO DE SISTEMAS Y COMPUTACIÓN**

APROBADA POR

Hector Miguel Zelada Valdivieso
PRESIDENTE

Ricardo David Iman Espinoza
SECRETARIO

Huilder Juanito Mera Montenegro
VOCAL

## Dedicatoria

A Dios por bendecirme abundantemente día tras día

A mis padres Pablo y Clara por toda su dedicación y amor incondicional.

A mi hermano Jhair por su admiración y ser motivación en mi vida.

A quienes me acompañan en la vida, por los instantes felices compartidos y el aliento espiritual que me impulsó a perseverar en este camino.

## Agradecimientos

A la Universidad Católica Santo Toribio de Mogrovejo, por brindarme la oportunidad de formarme profesionalmente y a su planta docente por compartir sus conocimientos durante mi formación académica.

A mi asesor Mgtr. Huilder Mera Montenegro, por su dirección profesional, paciencia y aliento continuo que fueron fundamentales para alcanzar los objetivos propuestos en esta investigación.

Implementación de una api con base en redes neuronales convolucionales para la validación e identificación de especies de árboles en Chiclayo

INFORME DE ORIGINALIDAD

| 14% | 14% | 2% | 3% |
|---|---|---|---|
| INDICE DE SIMILITUD | FUENTES DE INTERNET | PUBLICACIONES | TRABAJOS DEL ESTUDIANTE |

FUENTES PRIMARIAS

| | | |
|---|---|---|
| 1 | www.miraflores.gob.pe<br>Fuente de Internet | 4% |
| 2 | hdl.handle.net<br>Fuente de Internet | 2% |
| 3 | tesis.usat.edu.pe<br>Fuente de Internet | 2% |
| 4 | www.riego.mx<br>Fuente de Internet | 1% |
| 5 | upc.aws.openrepository.com<br>Fuente de Internet | 1% |
| 6 | datos.gob.es<br>Fuente de Internet | <1% |
| 7 | repositorio.ucv.edu.pe<br>Fuente de Internet | <1% |
| 8 | repositorio.upea.bo<br>Fuente de Internet | <1% |
| 9 | vdocuments.net<br>Fuente de Internet | <1% |
| 10 | Submitted to Universidad Internacional de la Rioja<br>Trabajo del estudiante | <1% |
| 11 | www.buenastareas.com<br>Fuente de Internet | <1% |
| 12 | repositorio.unap.edu.pe<br>Fuente de Internet | <1% |

repositorio.utc.edu.ec

**Índice**

**Resumen**.....**6**

**Abstract** .....**7**

**Introducción**.....**8**

**Materiales y métodos**.....**19**

**Resultados y discusión**.....**23**

**Conclusiones**.....**36**

**Recomendaciones** .....**37**

**Referencias**.....**37**

**Anexos**.....**41**

## Resumen

En esta investigación se implementó una API REST basada en redes neuronales convolucionales para la validación e identificación de especies de árboles en Chiclayo, permitiendo abordar la problemática de la carencia de herramientas tecnológicas eficientes para una adecuada gestión del arbolado urbano, donde la falta de identificación precisa de especies dificulta su conservación y manejo sostenible. Utilizando la metodología CRISP-DM, se desarrollaron dos modelos con arquitectura ResNet50: uno de validación que alcanzó 98.43% de precisión en la clasificación binaria de árboles, y otro de identificación de especies con 96% de precisión media. Para el entrenamiento, se generaron dos conjuntos de datos: uno basado en CIFAR-100 con 60,000 imágenes diversas y otro específico con 2568 imágenes de árboles nativos de Chiclayo. La API desarrollada identifica con alta precisión cinco especies arbóreas nativas de Chiclayo, presentando una efectividad del 100% para Palmera Real, 97% para Algarrobo y Ponciano, y 93% para Ficus y Molle, con tiempos de respuesta de 2-10 segundos por consulta. La validación del correcto funcionamiento de la API se realizó a través de una aplicación web que integra sus servicios, facilitando pruebas exhaustivas mediante captura y carga de imágenes para comprobar la efectividad del sistema de reconocimiento.

**Palabras clave:** API REST, Redes neuronales convolucionales, Identificación de especies arbóreas

## Abstract

In this research, a REST API based on convolutional neural networks was implemented for the validation and identification of tree species in Chiclayo, allowing to address the problem of the lack of efficient technological tools for proper management of urban trees, where the lack of accurate identification of species hinders their conservation and sustainable management. Using the CRISP-DM methodology, two models were developed with ResNet50 architecture: one for validation that achieved 98.43% accuracy in the binary classification of trees, and another for species identification with 96% average accuracy. For training, two datasets were generated: one based on CIFAR-100 with 60,000 diverse images and another specific one with 2568 images of native trees from Chiclayo. The API developed identifies with high accuracy five native tree species of Chiclayo, presenting an effectiveness of 100% for Palmera Real, 97% for Algarrobo and Ponciano, and 93% for Ficus and Molle, with response times of 2-10 seconds per query. The validation of the correct functioning of the API was carried out through a web application that integrates its services, providing exhaustive tests by capturing and uploading images to check the effectiveness of the recognition system.


**Keywords:** API REST, Convolutional neural networks, Tree species identification

**Introducción**

El estudio y reconocimiento de las especies arbóreas en áreas urbanas se han vuelto esenciales para avanzar en la gestión de recursos, además de mejorar la calidad medioambiental de las ciudades. El incremento y la potenciación de áreas con vegetación pueden mitigar la presencia de contaminantes climáticos que permanecen poco tiempo en el aire, los cuales ejercen un impacto significativo en el calentamiento global y están estrechamente relacionados con más de 7 millones de muertes prematuras anuales atribuidas a la contaminación atmosférica [1]. En 2019, la Comisión Económica de las Naciones Unidas para Europa (UNECE), lanzó el "Desafío de los Árboles en las Ciudades" [2], en el que se buscaba que los ciudadanos conozcan con precisión las especies de árboles presentes en su planificación urbana, sin embargo, la falta de identificación precisa y rápida de árboles dificultó este proceso. Es por eso, que la capacidad de estas técnicas para reconocer y clasificar especies arbóreas, como señalan [3] y [4], puede potenciar la planificación del paisaje urbano.

Según estadísticas de la Organización de las Naciones Unidas (ONU), más del 55% de la población mundial vive en áreas urbanas, y se proyecta que esta cifra aumentará a casi el 70% para el año 2050 [5]. Esta urbanización creciente subraya la importancia de gestionar de manera efectiva los recursos naturales en entornos urbanos, incluidos los árboles, para garantizar la calidad de vida de los habitantes de las ciudades. En América Latina y el Caribe, la población urbana alcanza el 81% y se proyecta que seguirá aumentando en las próximas décadas, convirtiéndose en una de las regiones más urbanizadas del planeta con tendencias de crecimiento urbano que superan el promedio global y generan desafíos significativos para la planificación urbana sostenible [6]. En Perú, un país con una rica diversidad de especies arbóreas, se estima que más del 75% de la población vive en áreas urbanas [7], y como lo indica [8], existe problemas urbanos como la falta de áreas verdes, lo que genera un "histórico déficit de bienestar ambiental" especialmente en zonas de vivienda social, donde las características de las coberturas vegetales son deficientes para proporcionar beneficios naturales importantes como aire limpio, sombra, reducción del calor y espacios para la recreación. Esto significa que una gran parte de la población está expuesta a los problemas ambientales y de calidad del aire que pueden mitigarse con la presencia de árboles en las zonas urbanas. Dicha realidad no es ajena con la situación que vive la población de la ciudad de Chiclayo, pues se observa un problema crítico de expansión urbana descontrolada, con un índice de crecimiento que alcanzó un valor preocupante de 1.93 en el período 2004-2017, no obstante, el índice de áreas verdes por habitante es significativamente bajo [9].

Frente a esta realidad ambiental, considerando estos alarmantes porcentajes de urbanización y la necesidad de preservar el patrimonio natural, el gobierno del Perú en 2021, a través del Ministerio del Ambiente (MINAM), en su Eje Estratégico Perú Natural y como meta del bicentenario, desarrolló una iniciativa nacional denominada "Árboles Patrimoniales" [10]. Esta iniciativa busca reconocer y poner en valor los árboles patrimoniales; sin embargo, el proceso se implementa mediante fichas técnicas manuales, lo que genera un procedimiento lento, susceptible a errores, siendo necesario contar con el apoyo de expertos botánicos para su correcta identificación y registro. La misma situación se reproduce en los gobiernos regionales y locales del Perú, donde las municipalidades enfrentan desafíos equivalentes. Al respecto, se tuvo la oportunidad de entrevistar al responsable de la Subgerencia de Parques y Jardines que impulsa el cuidado de áreas verdes en el centro de la ciudad de Chiclayo, quien manifestó que utilizan el mismo tipo de documentación, registrando los árboles en fichas técnicas manuales mediante recorridos con un experto, limitándose a las avenidas principales. Este método les demanda considerable tiempo y esfuerzo, además de que no mantienen un registro actualizado, siendo los últimos datos de varios años atrás, lo que evidencia la necesidad urgente de implementar una solución que permita identificar eficientemente las especies arbóreas existentes en estas áreas.

Para comprender mejor la problemática relacionada con la identificación de árboles y desarrollar soluciones efectivas, es fundamental analizar los factores que dificultan el adecuado reconocimiento y valoración de los recursos arbóreos urbanos. Un factor clave es la alta variabilidad morfológica, donde características como forma de hojas, textura de corteza y estructura general pueden variar significativamente incluso en una misma especie, dificultando la identificación visual, especialmente bajo condiciones ambientales adversas con altos niveles de contaminación. Por ello, sistemas automatizados basados en redes neuronales profundas están demostrando gran potencial para abordar esta variabilidad morfológica, alcanzando niveles cercanos a expertos humanos, como muestra el estudio [11]. Esto sugiere la importancia de desarrollar algoritmos más robustos para contrarrestar dicha variabilidad mediante el aprendizaje de patrones complejos a partir de grandes volúmenes de datos. De la misma forma, otro factor limitante crítico es la escasez de conjuntos de datos de imágenes representativos, diversificados y bien etiquetados, que capturen fielmente las diversas condiciones de iluminación, ángulos, etapas de crecimiento y entornos urbanos, dificultando la generalización de los modelos, como destaca [12]. Además, la contaminación lumínica y atmosférica urbana afecta significativamente la calidad de las imágenes, introduciendo distorsiones que obstaculizan la extracción de características relevantes, por lo que es crucial implementar

técnicas avanzadas de preprocesamiento y mejora de imágenes específicas para estos entornos adversos previo al reconocimiento.

Las causas principales del problema de identificación precisa de especies de árboles en entornos urbanos pueden atribuirse, en gran medida, a la falta de un inventario exhaustivo y actualizado de árboles en las ciudades [13]. En la ciudad de Trujillo, Perú, se evidencia la carencia de un inventario centralizado de las áreas verdes urbanas. Si bien se tenían identificadas 488 áreas verdes distribuidas por la ciudad, la densidad de área verde por persona era de solo 3.04 m², muy por debajo de los 9 m² recomendados por la Organización Mundial de la Salud [14]. Además, como señalan [15], la falta de información detallada sobre la especie, tamaño, estructura y estado de salud de los árboles dificulta aún más la gestión adecuada de los recursos vegetales en entornos urbanos. Por ejemplo, un estudio en Jaén, Perú, [16] señala la importancia de contar con información detallada sobre cada árbol, como género, especie, estado general, riesgos, necesidades de mantenimiento, condición fitosanitaria y estatus de protección, para una adecuada evaluación y gestión del arbolado urbano. La carencia de esta información detallada puede dificultar la implementación de programas de manejo integrado de plagas, podas de seguridad y otras acciones de conservación del arbolado. En el caso de Chiclayo, las principales causas que llevaron a la poda agresiva indiscriminada de 23 árboles en la Avenida Balta parecen haber sido la carencia de un inventario detallado y actualizado del arbolado urbano, la falta de evaluaciones previas sobre las especies, edad y estado de los árboles antes de iniciar la obra de renovación, el aparente desconocimiento por parte de la gestión municipal sobre el valor ecológico de los árboles maduros, la omisión de recomendaciones técnicas de entidades como Servicio Nacional Forestal y de Fauna Silvestre (SERFOR), y la ausencia de procesos participativos que involucra a la ciudadanía [17].

Las consecuencias de la falta de reconocimiento preciso de especies de árboles en entornos urbanos son significativas y pueden tener un impacto negativo en diversos aspectos de la planificación urbana y la calidad de vida. Es crucial identificar con precisión las especies de árboles con riesgo de caída para implementar medidas preventivas adecuadas y evitar posibles daños a la infraestructura urbana y a los residentes locales [18]. Por ejemplo, en la ciudad de Piura, Perú, la falta de un sistema preciso de identificación de especies llevó a que comenzara la tala de 21 árboles, incluyendo seis ejemplares de la especie algarrobo en peligro de extinción, en el Parque Néstor Martos para dar paso a la construcción del llamado "Parque de las Aguas", generando protestas y denuncias por parte de vecinos y organizaciones ambientales, quienes señalan que el proyecto reducirá drásticamente las áreas verdes [19]. Además, sin un sistema adecuado de identificación y validación de árboles, ciudades como Chiclayo corren el riesgo de

perder su valioso patrimonio arbóreo, sufrir impactos ambientales negativos y deteriorar su paisaje urbano, lo que a su vez genera conflictos sociales por decisiones no justificadas técnicamente sobre la tala de árboles.

A pesar de los avances tecnológicos, las aplicaciones actuales para la identificación de especies arbóreas aún enfrentan desafíos significativos como el preprocesamiento de datos, la escasez de imágenes de ciertas especies y la distribución desigual de categorías, lo que afecta su utilidad en contextos locales como Chiclayo. Asimismo, estas aplicaciones ofrecen un número restringido de consultas gratuitas y requieren pagos para un uso ilimitado, haciéndolas poco accesibles para el usuario promedio. Además, carecen de la capacidad para validar si la imagen proporcionada corresponde realmente a un árbol, lo que compromete su precisión y confiabilidad. Ante esta problemática, la presente investigación busca responder la siguiente pregunta: ¿Cómo validar e identificar especies de árboles en Chiclayo a través de la detección y clasificación automática de rasgos visuales relevantes presentes en imágenes? Como producto de esta tesis, se implementó un modelo basado en redes neuronales convolucionales, el cual será expuesto como una API REST, permitiendo validar e identificar de manera precisa los árboles nativos de Chiclayo.

Esta investigación se justifica desde cuatro dimensiones complementarias. En el ámbito científico, la investigación proporciona un marco de referencia para futuros estudios sobre redes neuronales convolucionales aplicadas a la identificación de especies arbóreas, promoviendo el acceso a información actualizada sobre la flora local y el uso de terminología botánica precisa. Económicamente, el proyecto adopta un modelo de código abierto con uso gratuito ilimitado, facilitando su adopción y accesibilidad. Se proyecta su sostenibilidad futura a través de una organización sin fines de lucro que garantice su viabilidad mediante financiamiento externo, permitiendo que las contribuciones recibidas sean reinvertidas en el mejoramiento continuo de la plataforma, la profundización de la investigación y la ampliación de la base de datos de imágenes para un entrenamiento más robusto del modelo.

La justificación social se fundamenta en beneficios ambientales concretos como la reducción de temperatura urbana hasta en 2 grados Celsius, purificación del aire mediante absorción de gases contaminantes, conservación de biodiversidad, mitigación de ruido y promoción de la salud mental, según lo destacado por el MINAM. Igualmente, la investigación se alineó con iniciativas como "Árboles Patrimoniales" [20] para preservar el patrimonio forestal. Desde la perspectiva tecnológica, el proyecto implementa redes neuronales convolucionales con capacidad excepcional para capturar características visuales complejas [21], desarrollando una

API innovadora que valida eficientemente imágenes e identifica de forma confiable las especies arbóreas nativas de Chiclayo, facilitando esta tarea crítica para los usuarios finales.

Por ello, se realizó esta investigación teniendo como objetivo general implementar una API REST con base en redes neuronales convolucionales para la validación e identificación de especies de árboles en Chiclayo, y teniendo en cuenta los siguientes objetivos específicos: generar datasets de imágenes, incluyendo un dataset con imágenes de diversas escenas y otro con imágenes y características de especies de árboles en Chiclayo; implementar un modelo de aprendizaje automático para validar la presencia de árboles en una imagen; implementar un modelo de aprendizaje automático para identificar diferentes especies de árboles en Chiclayo a partir de imágenes; construir una API REST que integre los modelos de validación e identificación de especies de árboles en Chiclayo; y validar el funcionamiento de la API REST para asegurar el cumplimiento de la validación y la identificación de especies de árboles en Chiclayo.

Entre los antecedentes más relevantes para esta investigación se encuentran los trabajos de Capecchi et al. [22], quienes abordaron la necesidad de realizar inventarios detallados de árboles urbanos mediante técnicas de aprendizaje automático; Ringland et al. [23], que exploraron el uso de Mask R-CNN para la detección de árboles individuales en imágenes aéreas; Homan y Preez [24], que desarrollaron técnicas de aprendizaje profundo semi-supervisado para la identificación de especies a partir de imágenes naturales y Blanco et al. [25], que propusieron un equipo portátil para la detección de especies maderables peruanas.

Como resultado de esta investigación, se obtendrá una API REST funcional que permitirá a usuarios y organizaciones automatizar el proceso de validación e identificación de especies arbóreas nativas de Chiclayo. Esta herramienta tecnológica contribuirá significativamente a la gestión eficiente de los recursos arbóreos urbanos, facilitando procesos de inventario forestal y apoyando la toma de decisiones informadas por parte de las autoridades municipales para la preservación del patrimonio natural de la ciudad.

## Revisión de literatura

### Antecedentes

Capecchi et al. [22] abordaron en su investigación un desafío clave para las municipalidades italianas: la necesidad de realizar inventarios detallados de árboles urbanos a nivel individual de manera rentable. Para ello, exploraron el uso de técnicas de aprendizaje automático, específicamente redes neuronales convolucionales (CNN). Los autores desarrollaron una metodología que combina datos de sensores remotos, imágenes de Google Street View y

aplicaciones de reconocimiento de especies vegetales basadas en CNN. A través de la segmentación de copas de árboles utilizando datos de detección y localización de la luz (LiDAR), el índice de vegetación de diferencia normalizada (NDVI), extracción de imágenes desde Google Street View y clasificación con CNN entrenadas localmente. Aunque enfrentaron limitaciones en la identificación de especies en áreas privadas y parques, lograron obtener una precisión media del 0.73 en su inventario. Sin embargo, en el reconocimiento de los 3 árboles más comunes obtuvo mejores resultados: Pinus pinea 0,87; Tilia aeuropea 0,87 y Platanus hybrida 0,89. Esta investigación reveló la importancia de emplear la detección automática para facilitar la planificación de la forestación urbana.

Ringland et al. [23] identificaron como problemática la necesidad de obtener mediciones detalladas de árboles individuales, como delineación de copas y alturas, de manera eficiente para inventarios forestales en plantaciones jóvenes, ya que los enfoques tradicionales no permitían caracterizar y mapear eficientemente las prácticas de cultivo de alimentos a lo largo de las carreteras. Exploraron el uso de una red neuronal convolucional basada en regiones de máscaras (Mask R-CNN) aplicada a imágenes de alta resolución capturadas con un vehículo aéreo no tripulado de una plantación. Entrenaron el modelo Mask R-CNN con combinaciones de bandas espectrales e información topográfica derivada de las imágenes. Los mejores resultados se obtuvieron con la combinación de índice de vegetación NDVI y un modelo de altura de copas, en el cual el estudio de reconocimiento de las 7 especies de árboles comunes de una de las zonas de Tailandia logró una precisión de puntuación F1 del 84,68% en detección de copas individuales, una intersección sobre unión del 91,27% en delineación de copas y alta correlación con un coeficiente de determinación del 0,97 entre alturas estimadas y medidas in situ. Este estudio pionero demostró el gran potencial de Mask RCNN para obtener eficientemente la identificación completa de árboles individuales.

Asimismo, la investigación de Homan y Preez [24] identificó como problemática que los trabajos previos sobre clasificación de especies de plantas se enfocaban predominantemente en construir modelos a partir de atributos aislados de las plantas. Por lo tanto, existía la necesidad de herramientas que pudieran asistir en la identificación de especies en entornos naturales del mundo real, este estudio realizado en Estados Unidos ha explorado el uso de técnicas de aprendizaje profundo para la identificación automática de especies de árboles a partir de imágenes naturales. Estos autores desarrollaron una metodología novedosa de dos fases: reconocimiento de características de árboles como hojas y corteza, seguido de la clasificación de especies utilizando un método de aprendizaje semisupervisado que aprovecha datos

etiquetados y no etiquetados. Compilaron un dataset de diferentes especies de árboles del noreste de Estados Unidos utilizando la plataforma iNaturalist y emplearon un modelo de red neuronal convolucional EfficientNet-B0 y un enfoque llamado FixMatch, logrando en las 5 especies más comunes una precisión de 94.04% para la clasificación de especies por hojas y 83.04% de precisión para la clasificación por corteza. Este proyecto resalta el uso del aprendizaje semi-supervisado para la identificación automática de especies comunes de árboles a partir de imágenes, aprovechando de esta manera datos etiquetados y no etiquetados.

Blanco et al. [25], hacen mención que en Perú existe la necesidad de contar con herramientas tecnológicas para la identificación de especies maderables debido al extenso comercio de madera y el requerimiento de controlar la tala ilegal en la Amazonía peruana. Este estudio sugiere un instrumento electrónico portátil capaz de identificar 11 especies maderas de la selva peruana, utilizando métodos de procesamiento de imágenes y CNN. Implementaron un algoritmo que emplea filtros de color, umbrales y otras operaciones para dividir la hoja y posteriormente insertarla en una red neurona. Tras analizar diversas arquitecturas, seleccionaron MobileNet, dado que demostró el rendimiento óptimo, con una precisión media del 98.64% al reconocer las 11 especies de madera. Esta investigación no solo expone la problemática de que los procedimientos actuales de identificación exigen labor manual implicando ineficiencia en términos de tiempo, coste y exactitud, sino que sugiere la implementación de algoritmos dedicados exclusivamente a la identificación de cada categoría de especies arbóreas.

## Bases teóricas

### Concepto de un API (Interfaz de Programación de Aplicaciones)

Las API ofrecen un canal para que los elementos de software se interactúen entre ellos. Además, ofrece una interfaz de programación a un componente de software que frecuentemente se publica y puede ser empleado por programadores que no son los creadores originales de la API. Las API juegan un papel crucial en la valoración de la usabilidad de reutilizar software, ya que pueden detectar zonas problemáticas y ofrecer sugerencias para optimizar la API.

### Tipos de API

#### API REST (Representational State Transfer)

API que utiliza protocolos abiertos como HTTP el cual contiene a métodos como GET, POST, PUT, DELETE diseñadas para interactuar con recursos que son objetos, datos o servicios a los que puede acceder un cliente. Asimismo, una API REST se puede implementar utilizando cualquier lenguaje de programación, siendo los más habituales: Java, Python .NET entre otros.

Su función consta de no vincular las implementaciones de la API en el servidor o de las aplicaciones cliente con ninguna implementación concreta, es por eso que se formulan solicitudes y se obtienen respuestas utilizando el protocolo antes mencionado.

**Arquitectura de una API REST**

Es un modelo de arquitectura de software que consta de un conjunto coordinado de restricciones arquitectónicas aplicadas a los componentes, conectores y datos dentro de un sistema hipermedia distribuido. REST se enfoca en las funciones de los componentes, las restricciones sobre su interacción con otros componentes, y la interpretación de los datos, ignorando los detalles de implementación y la sintaxis de protocolo [26].

**Restricciones de REST**

Las restricciones arquitectónicas de REST son: interacción sin estado, interfaz uniforme, identificación de recursos, manipulación de recursos a través de representaciones, mensajes autodescriptivos, y la utilización de hipermedia como el motor del estado de la aplicación (HATEOAS). Estas restricciones permiten propiedades deseables como rendimiento, escalabilidad, sencillez, modificabilidad, visibilidad, portabilidad y fiabilidad [27].

**Importancia de la descripción de servicios**

La descripción de servicios juega un papel importante en el acceso a un servicio. Permite la creación automática de esqueletos de código, búsquedas más fáciles y la clasificación de servicios. Los lenguajes de descripción de servicios están diseñados para ser consumidos por máquinas [28].

**Estándares de descripción de servicios**

El estándar WSDL (Web Services Description Language) especifica un método para describir las interfaces de un servicio web a nivel sintáctico y cómo invocarlo. SAWSDL (Anotación Semántica para WSDL y XML Schema) define mecanismos para añadir anotaciones semánticas a los componentes de WSDL.

**Descripción semántica de servicios REST**

Un lenguaje de descripción semántica para servicios REST debe cumplir con las restricciones del estilo arquitectónico REST, ser expresivo para describir cómo acceder y representar los recursos, y proporcionar medios para transformar las representaciones en triples RDF. El principal problema es que no existe un formato de descripción estándar legible por máquinas.

**Funcionamiento de una Red Neuronal Convolucional (CNN)**

Según Lee et al. [29], las red neuronal convolucional (CNN) es una nueva tecnología que ha

demostrado excelentes capacidades de reconocimiento con grandes conjuntos de datos, lo cual reemplaza la necesidad de diseñar funciones hechas a mano. Ahmad et al. [30] explican que, al utilizar una CNN, la imagen se debe tomar como una matriz 3D, donde la dimensión de profundidad representa los canales de color rojo, verde o azul, a menos que se trate de una imagen en escala de grises, en cuyo caso debe convertirse a la matriz 3D. Además, menciona que varias arquitecturas de CNN utilizan transformaciones de color RGB, HSV y HSB.

**Etapas de la arquitectura de una CNN**

La arquitectura básica de las redes neuronales convolucionales consta de tres etapas principales: entrada, extracción de características y clasificación [31].

En la etapa de entrada, se introduce el conjunto de datos que puede ser una imagen si el problema involucra su análisis, o cualquier otro tipo de datos que alimenten la red neuronal convolucional. En esta etapa, es crucial contar con un conjunto de datos sustancial.

La etapa de extracción de características tiene como objetivo extraer las características relevantes a través de dos operaciones esenciales: convoluciones y submuestreo. La convolución implica la aplicación de un conjunto de kernels u operadores que permiten resaltar las características propias de las imágenes. Se pueden aplicar los operadores necesarios para extraer las características que ayuden al modelo a tener un mejor desempeño, y después de cada convolución, se realiza un submuestreo o reducción de la matriz de características.

Por último, en la etapa de clasificación, se reciben los datos extraídos en la etapa anterior y son entrenados en una red neuronal multiconectada según el número de clases establecidas. Finalmente, se obtiene un modelo entrenado que puede utilizarse para clasificar las clases mencionadas.

En la figura 1 se muestra un diagrama que permite visualizar mejor las etapas básicas de la arquitectura de una CNN.

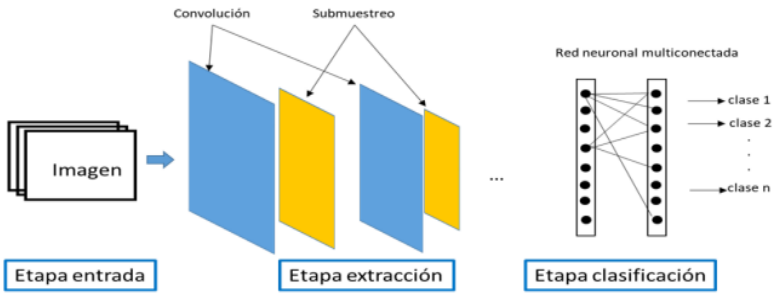


*Fig. 1. Etapas básicas de la red neuronal convolucional [31]*

**Principales componentes de una CNN**

Los principales componentes de la arquitectura de una red neuronal convolucional (CNN) son los siguientes:

**Capa convolucional:** Es la capa principal de una CNN, donde se aplican filtros entrenables sobre el volumen de entrada (imagen) para producir mapas de activación o características. Estos filtros se deslizan a través de la imagen, realizando operaciones de convolución para resaltar características específicas.

*Fig. 2. Ejemplo de un filtrado*

**Capa de agrupación (pooling):** Estas capas se colocan entre capas convolucionales sucesivas y su función es reducir la dimensionalidad de los mapas de características, disminuyendo la complejidad del modelo y evitando el sobreajuste. La operación más común es el max-pooling, que selecciona el valor máximo dentro de una región del mapa de características.

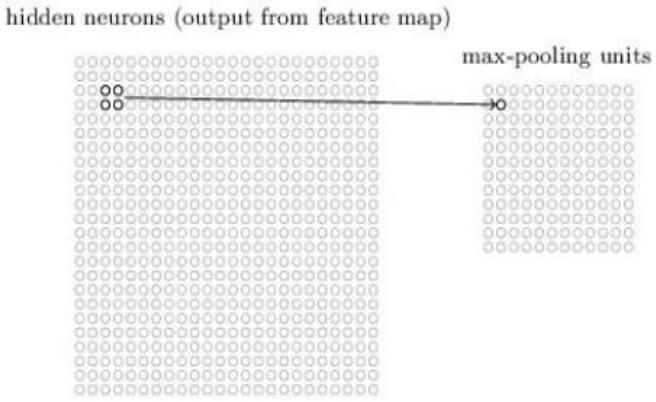


*Fig. 3. Max-pooling*

**Capa de unidades lineales rectificadas (ReLU):** Estas capas introducen no linealidad a las funciones de activación, aumentando la capacidad de aprendizaje de la red. Comúnmente se utiliza la función $f(x) = \max(0, x)$.

**Capa completamente conectada:** Similar a las capas de una red neuronal tradicional, donde todas las neuronas están conectadas a todas las neuronas de la capa anterior.

**Capa de pérdida:** Compara las predicciones del modelo con los valores reales de las imágenes, utilizando funciones como la pérdida softmax para clasificación o la pérdida euclídea para regresión [32].

**Identificación de Especies de Árboles**

El árbol se define como "una planta cuya información genética le faculta para desarrollarse, producir madera y crecer tanto como el ambiente se lo permita" [33]. Se menciona que los primeros árboles conocidos datan del período devónico, hace aproximadamente 380 millones de años, y pertenecían al género Wattieza. Estos árboles primitivos, que poblaban zonas de Norteamérica y Suramérica, probablemente enriquecieron la atmósfera con oxígeno producido mediante la fotosíntesis, favoreciendo el desarrollo de especies superiores de animales fuera de los mares.

**Importancia cultural y ambiental de los árboles**

Los árboles han jugado un papel importante en la religión, la filosofía y la cultura. Por ejemplo, se menciona el "árbol de la sabiduría" y el "árbol de Navidad". Además, los árboles tienen un gran protagonismo en relación al calentamiento global. Se calcula que un tercio de los bosques del mundo han desaparecido debido a la deforestación. El Programa de las Naciones Unidas para el Medio Ambiente ha iniciado una campaña mundial llamada "Plantemos Para el Planeta" con el objetivo de plantar 7.000 millones de árboles, es decir, un árbol por habitante de la Tierra [34].

**Partes de un árbol**

Las principales partes de un árbol: raíz, fuste (tronco), copa, ramas, hojas, flores y fruto. Cada una de estas partes cumple funciones específicas, como el anclaje al suelo, la absorción de agua y minerales, el transporte de líquidos, la fotosíntesis y la reproducción.

**Clasificación de árboles significativos**

Esta clasificación se puede dividir en tres categorías principales según su importancia y características particulares. Los árboles históricos adquieren su valor a través de razones históricas o culturales específicas que los vinculan con eventos, personajes o tradiciones relevantes para una comunidad. Por otro lado, los árboles naturales son aquellos que tienen su origen en una ciudad o espacio geográfico determinado, representando la flora autóctona del lugar. Finalmente, los árboles culturales se distinguen por ser considerados sobresalientes debido a características excepcionales como su tamaño imponente, edad avanzada, belleza particular o alguna singularidad que los hace únicos y dignos de reconocimiento especial dentro de su entorno.

**Claves para la identificación de un árbol**

Una de las metodologías sistemáticas utilizadas para la identificación de especies arbóreas es la que emplea las características morfológicas de las hojas como criterio principal. Este proceso

se estructura en tres fases consecutivas que permiten una aproximación gradual y precisa hacia la identificación correcta. La primera fase establece una clasificación general que distingue entre tres grandes grupos taxonómicos: coníferas, planifolios y palmeras, sentando las bases para una categorización inicial. Posteriormente, la segunda fase profundiza en la diferenciación al subdividir tanto las coníferas como los planifolios en grupos más específicos, tomando como referencia las características particulares del tipo de hoja que presentan. Finalmente, la tercera fase refina aún más esta clasificación al segmentar cada uno de los grupos previamente establecidos en subgrupos más reducidos y especializados, los cuales agrupan entre dos y varios géneros que comparten características foliares similares, facilitando así una identificación más precisa y detallada de las especies estudiadas [35].

## Materiales y métodos

### Tipo de investigación

La presente investigación es de tipo tecnológica aplicada, ya que se implementó una API basada en redes neuronales convolucionales (CNN) para la validación e identificación de especies de árboles en la ciudad de Chiclayo.

### Métodos de investigación

A continuación, se mencionan los métodos de investigación que fueron empleados:

Tabla 1. MÉTODOS DE INVESTIGACIÓN

| Método | Sustento por el cual será empleado en la investigación |
|---|---|
| Analítico | - Recopilación de imágenes de diversas escenas de páginas web con datasets existentes.<br>- Captura de imágenes de árboles de Chiclayo usando Google Street View.<br>- Investigación de registro de especies arbóreas de Chiclayo.<br>- Construcción manual del dataset de árboles nativos de Chiclayo. |
| Experimentos | - Revisión de documentación sobre arquitecturas de redes neuronales convolucionales.<br>- Implementación de los modelos de identificación y validación de árboles en imágenes usando Visual Studio Code.<br>- Entrenamiento y ajuste de los modelos con los datasets generados. |
| Investigación basada en el diseño | - Diseño de la estructura de la API utilizando Flask con Python en Visual Studio Code.<br>- Implementación de endpoints para la validación de presencia de árboles y la identificación de especies.<br>- Integración de los modelos de aprendizaje automático en la API. |
| Cualitativos y cuantitativos | - Desarrollo de una aplicación web para pruebas.<br>-Realización de pruebas de integración de los modelos de aprendizaje automático utilizando la aplicación web. |

En la siguiente tabla se describe las técnicas e instrumentos que nos ayudaran a la recolección de datos:

| Técnicas | Instrumentos |
|---|---|
| Observación | - Ficha de registros y características de árboles en Chiclayo (Ver Anexo 01)<br>- API para obtener imágenes de Google Street View |
| Revisión Documental | - Documentación técnica sobre arquitecturas de redes neuronales convolucionales (Ver Anexo 02) |

**Metodología de desarrollo**

La metodología que se empleó fue CRISP-DM (Cross-Industry Standard Process for Data Mining), una metodología estándar ampliamente utilizada para guiar proyectos de minería de datos y aprendizaje automático [36]. Fue desarrollada en 1996 por un consorcio liderado por SPSS (ahora parte de IBM) y Daimler AG, con el objetivo de estandarizar el proceso de minería de datos y facilitar su implementación en diferentes industrias y organizaciones. Consta de las siguientes fases:

**#1: Comprensión del negocio:** Esta fase inicial implica comprender los objetivos y requisitos del proyecto desde la perspectiva del negocio o la organización. Es fundamental definir claramente el problema a resolver, identificar las variables clave y los criterios de éxito, y determinar los recursos y el plan de proyecto necesarios.

**#2: Comprensión de los datos:** En esta fase, se recopilan y exploran los datos iniciales para familiarizarse con ellos. Implica identificar problemas de calidad de datos, como valores faltantes, inconsistencias o errores, y evaluar su impacto en el proyecto. También se analizan las relaciones entre las variables y se exploran patrones interesantes que puedan ser relevantes para los objetivos del proyecto.

**#3: Preparación de los datos:** Una vez que se comprenden los datos, es necesario prepararlos para el modelado. Esto implicó seleccionar los datos relevantes, realizar tareas de limpieza y transformación, como el manejo de valores faltantes, la normalización de datos y la codificación de variables categóricas. El objetivo es construir un conjunto de datos final listo para el modelado.

**#4: Modelado:** En esta fase, se seleccionan las técnicas de modelado adecuadas para las redes neuronales, según los objetivos del proyecto. Se entrenan y construyen los modelos utilizando los datos preparados, y se ajustan los parámetros del modelo para optimizar su rendimiento.

**#5: Evaluación:** Una vez construidos los modelos, se evalúa su rendimiento utilizando métricas apropiadas, como precisión. Se revisan los resultados y se determina si se cumplen los objetivos del negocio. Si es necesario, se pueden realizar ajustes o realizar más modelado.

**#6: Despliegue:** Si el modelo cumple con los requisitos, se planifica e implementa en un entorno de producción. Esto implica integrar el modelo en los sistemas existentes, capacitar al personal y establecer procesos de monitoreo y mantenimiento. Finalmente, se crean informes y documentación para comunicar los resultados a las partes interesadas.

**Mapeo de Objetivos**

| **Objetivo específico 01:** Generar datasets de imágenes, incluyendo un dataset con imágenes de diversas escenas y otro con imágenes y características de especies de árboles en Chiclayo. | | |
|---|---|---|
| **Resultados** | **Medio de verificación** | **Indicador objetivamente verificable** |
| Dataset validado con imágenes de diversas escenas generado. | Archivo digital del dataset con imágenes de diversas escenas. | - Índice Kappa de Cohen<br>- Número de imágenes por escena |
| Dataset con imágenes de árboles nativos de Chiclayo y sus características generado. | Archivo digital del dataset con imágenes de árboles nativos de Chiclayo y sus características. | - Índice Kappa de Cohen<br>- Número de especies incluidas<br>- Número de características registradas por especie |
| **Objetivo específico 02:** Implementar un modelo de aprendizaje automático para validar a presencia de árboles en una imagen. | | |

| **Resultados** | **Medio de verificación** | **Indicador objetivamente verificable** |
|---|---|---|
| Modelo entrenado capaz de validar la presencia o ausencia de árboles en imágenes. | - Código fuente del modelo | - Tiempo de entrenamiento<br>- Tiempo de ejecución<br>- Profundidad de la red |
| Modelo validado capaz de validar la presencia o ausencia de árboles en imágenes. | - Informe de desempeño del modelo con métricas de validación. | - Precisión<br>- Recall<br>- F1<br>- Exactitud |
| **Objetivo específico 03:** Implementar un modelo de aprendizaje automático para identificar diferentes de especies de árboles en Chiclayo a partir de imágenes. | | |
| **Resultados** | **Medio de verificación** | **Indicador objetivamente verificable** |
| Modelo entrenado capaz de identificar diferentes especies de árboles a partir de imágenes. | - Código fuente del modelo | - Tiempo de entrenamiento<br>- Tiempo de ejecución<br>Profundidad de la red |
| Modelo validado capaz de identificar diferentes especies de árboles a partir de imágenes. | - Informe de desempeño del modelo con métricas de validación. | - Precisión<br>- Recall<br>- F1<br>- Exactitud |
| **Objetivo específico 04:** Construir una API REST que integre los modelos de validación e identificación de especies de árboles en Chiclayo. | | |
| **Resultados** | **Medio de verificación** | **Indicador objetivamente verificable** |
| API REST desarrollada que integra los modelos de validación e identificación | - Código fuente de la API REST<br>- Documentación de la API | - Descripción de OpenAPI |

| **Objetivo específico 04:** Validar el funcionamiento de la API REST para asegurar el cumplimiento de la validación y la identificación de especies de árboles en Chiclayo. | | |
|---|---|---|
| **Resultados** | **Medio de verificación** | **Indicador objetivamente verificable** |
| API validado para la validación e identificación de especies de árboles nativos de Chiclayo. | - Registro de pruebas realizadas utilizando Postman.<br>- Aplicación web que utilice la API REST construida. | - Pruebas Fuzz<br>- Pruebas de Seguridad Dinámica<br>- Pruebas funcionales<br>- Tiempos de respuesta de la API [37] |

**Resultados y discusión**

**En base a la metodología utilizada**

**Iteración #1: Comprensión del negocio**

Al analizar la situación actual, se descubrió que la gestión del arbolado urbano en Chiclayo enfrenta desafíos significativos debido principalmente a la carencia de herramientas tecnológicas eficientes. Los métodos actuales, basados en procesos manuales, resultan lentos, costosos y propensos a errores. A pesar de contar con aproximadamente 1,229,760 m² de áreas verdes, el índice por habitante es significativamente bajo comparado con estándares internacionales. Un ejemplo claro de esta problemática fue la poda agresiva indiscriminada de 42 árboles en la Avenida Balta, situación que se produjo como consecuencia directa de la falta de un inventario sistemático y del desconocimiento sobre el valor ecológico de estos recursos por parte de las autoridades responsables.

En este contexto, se identificaron deficiencias específicas que incluyen la ausencia de un inventario exhaustivo y actualizado del arbolado, la falta de herramientas tecnológicas accesibles para validación e identificación, la dependencia excesiva de expertos para identificación manual, la carencia de datos precisos sobre distribución y estado de especies, la ausencia de evaluaciones técnicas previas a intervenciones urbanas, y la falta de procesos participativos que involucren a la ciudadanía en decisiones sobre el arbolado urbano.

Como respuesta a estas necesidades, se propuso el desarrollo de una API REST basada en redes neuronales convolucionales, una solución tecnológica capaz de realizar validación e identificación automática de árboles en imágenes, generación de datasets para entrenamiento,

integración de modelos en una API accesible, y la validación respectiva sobre el funcionamiento de la API. La arquitectura de esta solución se encuentra en el Anexo 1.

La planificación estableció una duración de 15 meses, con resultados esperados que contemplan una API REST completamente funcional, modelos CNN debidamente entrenados. Se seleccionó Python como lenguaje principal de desarrollo, TensorFlow como framework para el aprendizaje profundo, y Flask para implementar la interfaz de programación, a continuación. . Asimismo, el cronograma de actividades véase en el Anexo 2. Para el desarrollo de la investigación se tomó como presupuesto diferentes aspectos, véase en el Anexo 3.

**Iteración #2: Comprensión de los datos**

**Recopilación de datos:**

**Dataset de imágenes de diversas escenas:**

La selección del dataset de validación requirió una evaluación sistemática de cuatro alternativas principales del campo de visión por computadora. ImageNet, con 14 millones de imágenes distribuidas en 1,000 clases y resolución 256×256 píxeles, ofrece la máxima diversidad visual disponible; sin embargo, su tamaño de descarga de aproximadamente 150 GB y requisitos de procesamiento (clusters GPU) lo hacen inviable para entornos con recursos limitados como Google Colab (12 GB RAM). COCO, que contiene 330,000 imágenes en 80 clases con resoluciones variables y tamaño de aproximadamente 25 GB, presenta alta diversidad de escenas contextualizadas, pero demanda más de 16 GB de memoria RAM durante el entrenamiento, excediendo la capacidad disponible. Pascal VOC, aunque computacionalmente manejable con 20,000 imágenes en 20 clases y aproximadamente 2 GB de almacenamiento, carece de la diversidad necesaria para entrenar un clasificador binario robusto que generalice efectivamente entre escenas naturales y urbanas.

Tras este análisis comparativo, CIFAR-100 emergió como la opción óptima al cumplir simultáneamente tres criterios críticos: diversidad de escenas mediante 60,000 imágenes distribuidas en 100 clases que abarcan tanto objetos naturales (árboles: arce, roble, palma, pino, sauce; flores; bosques) como artificiales (vehículos, edificios, infraestructura urbana), esencial para validación árbol/no-árbol; viabilidad computacional con apenas 170 MB de descarga, imágenes de 32×32 píxeles procesables en Google Colab, y pipeline de carga optimizado en bibliotecas estándar; y documentación extensa con arquitecturas de referencia y benchmarks establecidos en la comunidad de transfer learning. Su estructura jerárquica en 20 superclases permite además un balance controlado entre categorías

relevantes e irrelevantes para el objetivo de detección, facilitando un entrenamiento eficiente del modelo de validación de presencia de árboles.

**Dataset de árboles de Chiclayo:**

Para la creación de este dataset, se evaluaron inicialmente fichas detalladas de algunos inventarios de las principales avenidad de la ciudad de Chiclayo, véase en el Anexo 4. Además, para el proceso de la obtención de las imágenes se tuvieron diferentes opciones:

Inicialmente, se consideró capturar imágenes directamente de Google Street View y redimensionarlas manualmente. Sin embargo, este proceso resultó ser extremadamente laborioso y poco eficiente. Tras una investigación adicional, se optó por utilizar la API de Google Street View. Esta solución permite automatizar en gran medida el proceso de recopilación de imágenes mediante un script en Python.

**Descripción de los datos**

**Dataset CIFAR-100:**

- Número total de imágenes: 60,000
- Distribución: 50,000 imágenes para entrenamiento y 10,000 para pruebas
- Resolución de imágenes: 32x32 píxeles
- Formato de color: RGB (3 canales)
- Número de clases: 100

**Dataset de árboles de Chiclayo**

Número de clases: 5 (algarrobo, delonix regia, ficus benjamina, palma canaria, pimentero falso)

Asimismo, para complementar el dataset de imágenes, se implementó una consulta sistemática a GBIF (Global Biodiversity Information Facility), infraestructura de investigación financiada por gobiernos que agrega más de 2.3 mil millones de registros de biodiversidad de 1,800 instituciones globales (museos, herbarios, universidades). Mediante un script en Python, se consultó la API de GBIF especificando claves taxonómicas por especie para descargar imágenes disponibles con licencias abiertas. Este proceso automatizado permitió obtener y validar las imágenes de cada especie de forma sistemática. A continuación, detallo el número de imágenes encontradas por cada especie, revisar Anexo 5.

**Identificación de problemas y desafíos:**

**Especies subrepresentadas:** Se ha detectado la necesidad de aumentar el número de especies arbóreas en el dataset. Actualmente solo se cuentan con 5 clases, lo cual es insuficiente para representar la diversidad arbórea de Chiclayo.

**Desafíos en la calidad y variabilidad de las imágenes:**

**Iluminación:** Las imágenes presentan variaciones significativas en la iluminación debido a las diferentes horas del día y condiciones climáticas en las que fueron capturadas.

**Distancia:** La distancia entre la cámara y los árboles varía considerablemente, afectando el nivel de detalle visible en las imágenes.

**Altura:** Los ángulos de captura no siempre son ideales, especialmente para árboles muy altos, lo que puede resultar en la pérdida de detalles de la copa.

**Sobreposición:** En muchas imágenes, los árboles están parcialmente sobrepuestos por otros objetos como edificios, vehículos o señales de tráfico.

**Estacionalidad:** Las imágenes no representan adecuadamente los cambios estacionales en los árboles, lo que puede afectar su apariencia y dificultar la identificación.

**Calidad de imagen:** Algunas imágenes pueden tener baja resolución o estar desenfocadas, especialmente después del redimensionamiento a 32x32 píxeles.

**Evaluación de la necesidad de técnicas de aumento de datos:**

Dado el número limitado de imágenes (2568 en total) y los desafíos identificados, se considera necesario implementar técnicas de aumento de datos para:

- Incrementar artificialmente el tamaño del dataset.
- Mejorar la robustez del modelo frente a variaciones en iluminación, ángulo y escala.
- Compensar la falta de diversidad en las especies representadas.

**Iteración #3: Preparación de los datos Selección de datos:**

Se seleccionaron las 60,000 imágenes del dataset CIFAR-100 como base para el modelo de validación de presencia de árboles.

Para el dataset de árboles de Chiclayo, se eligieron las imágenes más representativas y de mejor calidad obtenidas de Google Street View y de datasets externos, que en total fueron 2058 imágenes.

**Integración de datos:**

- Para el modelo de validación, se utilizó CIFAR-100 convirtiendo las etiquetas a binario (árbol/no árbol).
- Para el modelo de identificación, se usó exclusivamente el dataset de árboles de Chiclayo.

**Formateo de datos:**

- Se normalizaron todas las imágenes dividiendo cada valor de píxel por 255, llevando los valores al rango [0,1].
- Para CIFAR-100, se convirtieron las etiquetas a formato binario.
- Para el dataset de Chiclayo, se utilizó codificación categórica.

**División del dataset:**

Para CIFAR-100:

Se mantuvo la división original del dataset.

Para el dataset de Chiclayo:

80% para entrenamiento

20% para validación

Se realizó una división adicional para obtener un conjunto de prueba.

**Preparación para el entrenamiento:**

- Se configuraron generadores de datos con un tamaño de lote de 32 imágenes.
- Para el dataset de Chiclayo, se implementó un generador con aumento de datos para el conjunto de entrenamiento y un generador sin aumento para validación y prueba.

**Iteración 4#: Modelado Selección de la arquitectura:**

Se realizó una investigación exhaustiva de modelos de vanguardia para tareas de clasificación de imágenes, incluyendo EfficientNet, ResNet, VGG, y DenseNet, véase en el Anexo 6.

Tras un análisis comparativo basado en el estudio de Moreno Díaz- Alejo (2020) [37], se eligió ResNet50 como arquitectura base por las siguientes razones:

- Rendimiento probado: ResNet50 ha demostrado un excelente rendimiento en múltiples tareas de visión por computadora, incluyendo la clasificación de imágenes.

- Profundidad óptima: Con 50 capas, ofrece un buen equilibrio entre profundidad y eficiencia computacional, adecuado para el conjunto de datos y recursos disponibles.
- Manejo del problema de desvanecimiento del gradiente: La arquitectura de conexiones residuales de ResNet50 ayuda a mitigar el problema del desvanecimiento del gradiente, permitiendo entrenar redes más profundas de manera efectiva.
- Transferencia de aprendizaje: ResNet50 pre-entrenado en ImageNet proporciona una base sólida para la transferencia de aprendizaje, lo cual es crucial dado el conjunto de datos relativamente pequeño.
- Compatibilidad con recursos: La arquitectura se ajusta bien a los recursos computacionales disponibles, permitiendo un entrenamiento eficiente sin comprometer el rendimiento.
- Amplia adopción en la comunidad: Su popularidad asegura una amplia disponibilidad de recursos, documentación y soporte comunitario.

Esta elección se alinea con el objetivo de lograr una alta precisión en los modelos de validación e identificación de árboles de Chiclayo, mientras se mantiene una eficiencia computacional razonable.

**Preparación del modelo:**

**Modelo de validación de árboles:**

```
# Crear el modelo
base_model = ResNet50(weights='imagenet', include_top=False, input_shape=(32, 32, 3))
x = base_model.output
x = GlobalAveragePooling2D()(x)
x = Dense(1024, activation='relu')(x)
output = Dense(1, activation='sigmoid')(x)
model = Model(inputs=base_model.input, outputs=output)
```

```
Downloading data from https://storage.googleapis.com/tensorflow/keras-applications/resnet/resnet50_weights_tf_dim_ordering_tf_kernels_notop.h5
94765736/94765736 ━━━━━━━━━━━━━━━━━━━━ 6s 0us/step
```

Fig.4. Imagen del modelo de validación de datos

El modelo se basa en una arquitectura ResNet50 pre-entrenada, a la cual se le añaden capas adicionales. Específicamente, se carga el modelo base ResNet50 sin las capas superiores, se aplica un pooling global promedio, seguido de una capa densa con 1024 unidades y activación ReLU, y finalmente una capa de salida densa con activación sigmoide. El modelo se construye conectando estas capas.

```
# Crear el modelo ResNet50 con transfer learning
base_model = ResNet50(weights='imagenet', include_top=False, input_shape=(img_height, img_width, 3))
base_model.trainable = False  # Congelar las capas del modelo base
```

```
model = models.Sequential([
    base_model,
    layers.GlobalAveragePooling2D(),
    layers.Dense(256, activation='relu'),
    layers.Dropout(0.5),
    layers.Dense(len(especies), activation='softmax')
])
```

Fig.5. Capas del modelo de validación

**Modelo de identificación de árboles:**

Este modelo utiliza la arquitectura ResNet50 como base, aprovechando su capacidad para extraer características complejas de imágenes. Las capas adicionales permiten adaptar el modelo a la tarea específica de clasificación de especies de árboles. La capa de pooling global reduce la dimensionalidad, la capa densa con ReLU introduce no-linealidad, el dropout ayuda a prevenir el sobreajuste, y la capa de salida con softmax produce probabilidades para cada clase de árbol. Este enfoque de transfer learning es eficiente para entrenar un modelo robusto con un conjunto de datos relativamente pequeño.

**Configuración del entrenamiento:**

**Modelo de validación de árboles:**

```
# Entrenar el modelo
history = model.fit(
    x_train, y_train_bin,
    validation_data=(x_test, y_test_bin),
    epochs=10,
    batch_size=32
)
```

```
Epoch 1/10
1563/1563 ━━━━━━━━━━━━━━━━━━━━ 110s 35ms/step - accuracy: 0.9597 - loss: 0.1822 - val_accuracy: 0.9717 - val_loss: 0.0908
```

Fig.6. Configuración de entrenamiento de modelo de validación

Esta imagen muestra el entrenamiento del modelo de aprendizaje profundo usando el método `fit()`. Se especifican los datos de entrenamiento y validación, junto con parámetros como el

número de épocas (10) y el tamaño del lote (32). La salida muestra los resultados de la primera época, indicando un progreso completo (1563/1563), un tiempo de ejecución de 110 segundos, y métricas de rendimiento como la precisión de entrenamiento (95.97%), pérdida de entrenamiento (0.1822), precisión de validación (97.17%) y pérdida de validación (0.0908). Estos valores sugieren que el modelo está aprendiendo efectivamente y generalizando bien desde el inicio del entrenamiento.

**Modelo de identificación de árboles:**

```
# Recompilar con learning rate más bajo
optimizer_ft = tf.keras.optimizers.AdamW(
    learning_rate=1e-5,
    weight_decay=0.0001
)

model.compile(
    optimizer=optimizer_ft,
    loss='categorical_crossentropy',
    metrics=['accuracy', tf.keras.metrics.Precision(), tf.keras.metrics.Recall()]
)

# Continuar entrenamiento
history_fine = model.fit(
    train_generator,
    epochs=EPOCHS_FINE_TUNING,
    validation_data=val_generator,
    callbacks=callbacks,
    verbose=1
)
```

Fig.7. Modelo de identificación de árboles

En este código se está implementando un sistema de clasificación de árboles utilizando EfficientNetV2L como modelo base, una versión mejorada de la familia EfficientNet que es conocida por su eficiencia y capacidad para capturar detalles finos en imágenes. Se eligió este modelo específicamente porque ofrece un excelente balance entre precisión y eficiencia computacional, además de ser particularmente efectivo en la detección de patrones complejos como las texturas de corteza, formas de hojas y estructuras de ramas que son cruciales para identificar diferentes especies de árboles.La arquitectura del modelo se ha personalizado significativamente para la tarea específica de clasificación de árboles. Se implementa un enfoque de doble rama donde una rama captura características globales del árbol mientras que otra se especializa en detalles finos, utilizando técnicas avanzadas como BatchNormalization, Dropout progresivo y regularización L2 para prevenir el sobreajuste. El entrenamiento se realiza en dos fases: una fase inicial con el modelo base congelado y una fase de fine-tuning donde se ajustan gradualmente las últimas capas del modelo base. Además, se incorporan técnicas de aumentación de datos específicamente diseñadas para imágenes de árboles, como

rotaciones limitadas y variaciones sutiles de brillo, junto con un esquema de learning rate con warmup y decay coseno para optimizar el proceso de aprendizaje.

**Proceso de entrenamiento:**

**Modelo de validación de árboles:**

- Se entrenó el modelo durante 10 épocas.
- Se utilizó un tamaño de lote (batch size) de 32 imágenes.
- Se emplearon los generadores de datos previamente configurados para el entrenamiento y la validación.

**Modelo de identificación de árboles:**

- Se entrenó el modelo durante 20 épocas.
- Se emplearon los generadores de datos previamente configurados para el entrenamiento y la validación.

**Monitoreo y evaluación:**

**Modelo de validación de árboles:**

```
# Evaluar el modelo
perdida_prueba, precision_prueba = model.evaluate(x_test, y_test_bin, verbose=2)
print(f'\nPrecisión en el conjunto de prueba: {precision_prueba}')

313/313 - 2s - 5ms/step - accuracy: 0.9785 - loss: 0.0685

Precisión en el conjunto de prueba: 0.9785000085830688
```

Fig.8. Evaluación del modelo de validación

El código está evaluando el modelo en datos de prueba, y los resultados indican un rendimiento muy bueno. El modelo alcanza una precisión del 97.85% en el conjunto de prueba, lo que significa que identifica correctamente los casos positivos el 97.85% de las veces. La alta precisión y exactitud (también 97.85%) sugieren que el modelo es muy eficaz en su tarea de clasificación, cometiendo muy pocos errores en los datos de prueba. El entrenamiento tomó 2 segundos en total, con cada paso durando aproximadamente 5 milisegundos

**Modelo de identificación de árboles:**

El modelo alcanza una precisión general del 96%, con métricas consistentemente altas en todas las especies. La Palmera real muestra un rendimiento perfecto con 1.00 en precisión, recall y f1-score, mientras que las demás especies mantienen métricas superiores al 93. Esto indica que el modelo es altamente confiable para la identificación de estas especies de árboles.

**Iteración #5: Evaluación**

**Modelo de validación de árboles:**

**Métricas de Rendimiento:** Accuracy global: 0.9843 - Precisión por especie: 0.976

```
Matriz de confusión (con umbral ajustado):
[[8979  721]
 [  22  278]]

Informe de clasificación (con umbral ajustado):
              precision    recall  f1-score   support

           0       1.00      0.93      0.96      9700
           1       0.28      0.93      0.43       300

    accuracy                           0.93     10000
   macro avg       0.64      0.93      0.69     10000
weighted avg       0.98      0.93      0.94     10000
```

Fig.9. Matriz de confusión del modelo de validación

**Validación del Modelo:**

Comportamiento en conjunto de prueba

Fig.10. Muestras de las pruebas del modelo de validación

**Análisis de Casos**

Especies mejor clasificadas: Árbol y No árbol Principales errores de clasificación: Color de árboles

**Modelo de identificación de árboles:**

**Métricas de Rendimiento:**

Accuracy global: 0.96

Matriz de confusión:

Reporte de clasificación:

| | precision | recall | f1-score | support |
|---|---|---|---|---|
| Algarrobo | 0.97 | 0.98 | 0.97 | 95 |
| Ficus | 0.93 | 0.93 | 0.93 | 100 |
| Molle | 0.93 | 0.93 | 0.93 | 107 |
| Palmera real | 1.00 | 1.00 | 1.00 | 100 |
| Ponciano | 0.97 | 0.96 | 0.97 | 101 |
| accuracy | | | 0.96 | 503 |
| macro avg | 0.96 | 0.96 | 0.96 | 503 |
| weighted avg | 0.96 | 0.96 | 0.96 | 503 |

Fig.11. Matriz de confusión del modelo de identificación

Validación del Modelo:

Comportamiento en conjunto de prueba

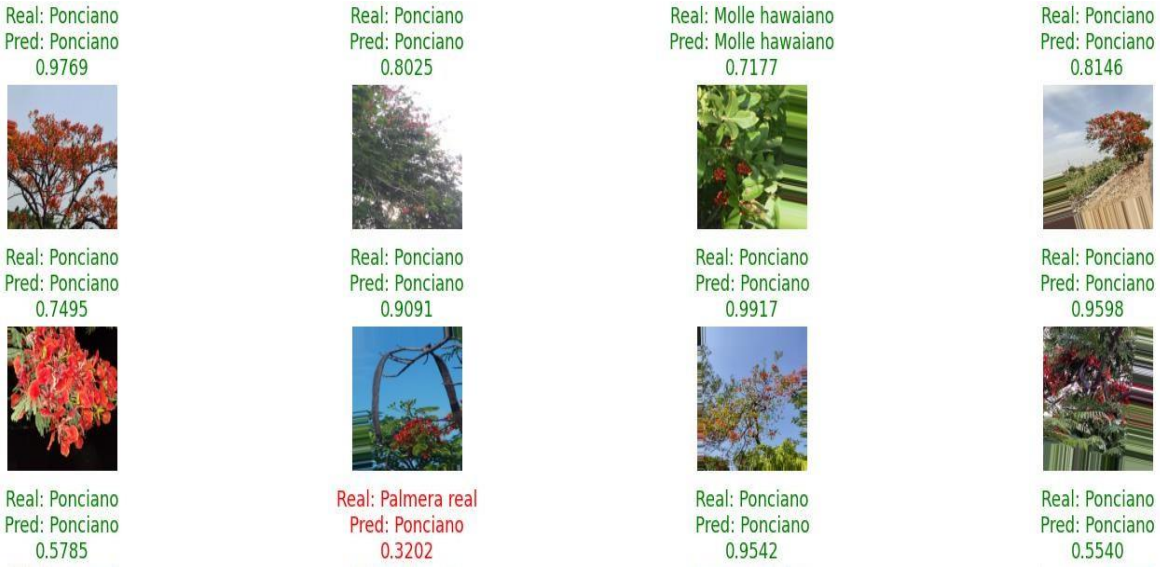


Fig.12. Muestras de las pruebas del modelo de identificación

**Iteración #6: Despliegue**

Se realizó la implementación de la API REST con base en redes neuronales convolucionales para la validación e identificación de especies de árboles en Chiclayo, considerando lo siguiente:

**Arquitectura del Sistema**

**Componentes Principales**

- API REST (Flask)
- Modelo de clasificación binaria (árbol/no árbol)

- Modelo de identificación de especies
- Base de datos de especies (Excel)

| id | nombre_cientifico | nombre_comun | descripcion |
|---|---|---|---|
| 1 | Ficus benjamina | Ficus | Árbol con fuste recto desde la base hasta 1.50m donde se bifurca, presenta copa globosa |
| 2 | Delonix regia | Ponciano | Árbol con fuste recto desde la base hasta 0.50m donde se bifurca, presenta copa globosa |
| 3 | Schinus terebinthifolius | Molle hawaiano | Árbol, fuste sinuoso, copa irregular |
| 4 | Roystonea regia | Palmera real | Árbol, fuste recto, copa palmiforme |
| 5 | Prosopis pallida | Algarrobo | Árbol de tronco tortuoso, copa amplia y extendida, ramas espinosas |

Fig.13. Referencia del archivo Excel que contiene la base de datos de las especies

**Requisitos Técnicos**

Para el correcto funcionamiento de la API desarrollada, se requiere un entorno con Python 3.8 o superior, junto con las librerías TensorFlow 2.x para el procesamiento de redes neuronales, Flask para el desarrollo del servicio REST, OpenCV para la manipulación de imágenes, Numpy y Pandas para el procesamiento de datos. Adicionalmente, el sistema debe contar con un mínimo de 4GB de memoria RAM y 500MB de espacio disponible en disco para el almacenamiento de los modelos entrenados y dependencias del proyecto.

**Configuración del Servidor:**

- Se está ejecutando en modo debug (desarrollo)
- Disponible en todas las direcciones (0.0.0.0)
- Accesible a través de:

**Respuesta en terminal cuando no es árbol:**

```
INFO:werkzeug:127.0.0.1 - - [28/Nov/2024 01:15:58] "OPTIONS /clasificar_arbol HTTP/1.1" 200 -
INFO:__main__:Iniciando clasificación de árbol
DEBUG:__main__:Imagen decodificada shape: (94, 80, 3)
DEBUG:__main__:Predicción binaria: 3.02711869153426 96e-05
INFO:werkzeug:127.0.0.1 - - [28/Nov/2024 01:15:59] "POST /clasificar_arbol HTTP/1.1" 200 -
INFO:werkzeug:127.0.0.1 - - [28/Nov/2024 01:16:58] "OPTIONS /clasificar_arbol HTTP/1.1" 200 -
INFO:__main__:Iniciando clasificación de árbol
DEBUG:__main__:Imagen decodificada shape: (80, 80, 3)
DEBUG:__main__:Predicción binaria: 0.06759808212518692
```

Fig.14. Terminal al realizar una prueba de validación

**Respuesta en terminal cuando si es árbol y lo clasifica:**

```
INFO:werkzeug:127.0.0.1 - - [28/Nov/2024 01:20:18] "OPTIONS /clasificar_arbol HTTP/1.1" 200 -
INFO:__main__:Iniciando clasificación de árbol
DEBUG:__main__:Imagen decodificada shape: (485, 800, 3)
DEBUG:__main__:Predicción binaria: 0.9988366961479187
DEBUG:__main__:Predicciones por especie:
DEBUG:__main__:Clase Algarrobo: 0.0000
DEBUG:__main__:Clase Ficus: 0.0000
DEBUG:__main__:Clase Molle hawaiano: 0.0000
DEBUG:__main__:Clase Palmera real: 0.0000
DEBUG:__main__:Clase Ponciano: 0.9999
INFO:werkzeug:127.0.0.1 - - [28/Nov/2024 01:20:21] "POST /clasificar_arbol HTTP/1.1" 200 -
```

Fig.15. Terminal al realizar una prueba de identificación

Para validar el funcionamiento de la API desarrollada, se implementó una aplicación web que sirve como interfaz de usuario para demostrar las funcionalidades del sistema. Las pruebas realizadas desde la aplicación web véase en el Anexo 7.

**Discusión**

- Los resultados obtenidos en esta investigación demuestran la efectividad de las redes neuronales convolucionales para la validación e identificación de especies arbóreas en entornos urbanos, alcanzando una precisión de 98.43% en el modelo de validación y 96% en el modelo de identificación de especies. Estos hallazgos presentan importantes similitudes con los resultados reportados por Vizcarra et al. [28], quienes lograron una precisión del 96.52% en pruebas utilizando la arquitectura VGG-19 para la identificación de especies arbóreas en la Amazonía peruana. En ambos casos, se evidencia que las arquitecturas basadas en redes neuronales profundas son altamente efectivas para capturar los patrones visuales complejos que distinguen a diferentes especies de árboles, incluso cuando existen variaciones en las condiciones de iluminación y ángulos de captura.
- Sin embargo, esta investigación se diferencia al implementar un enfoque de doble modelo, donde primero se valida la presencia de árboles antes de proceder a la identificación, lo que reduce significativamente los falsos positivos y optimiza el rendimiento general del sistema. Esta aproximación es complementaria con el trabajo de Homan y Preez [26], quienes también utilizaron un enfoque de dos fases, pero centrado en el reconocimiento de características específicas de árboles (hojas y corteza) antes de la clasificación de especies. La diferencia principal radica en que su sistema alcanzó una precisión de 94.04% para clasificación por hojas y 83.04% para clasificación por corteza, mientras que el enfoque generalista logró un 96% de precisión utilizando imágenes completas del árbol, demostrando mayor robustez ante diferentes tipos de input.
- Respecto a la metodología empleada, esta investigación coincide con Blanco et al. [27] en la utilización de redes neuronales convolucionales para la identificación de especies maderables peruanas. Sin embargo, mientras que ellos compararon las arquitecturas AlexNet, VGG-16 y MobileNet, optando finalmente por esta última con una precisión del 98.64%, esta investigación seleccionó ResNet50 tras un análisis comparativo, logrando resultados similares (98.43% y 96%). Esta similitud en resultados con diferentes arquitecturas sugiere que, para tareas de identificación de especies arbóreas, diversas

arquitecturas CNN pueden alcanzar rendimientos óptimos cuando son correctamente entrenadas y ajustadas.

**Conclusiones**

- Se generaron exitosamente dos datasets robustos para el entrenamiento de los modelos: uno basado en CIFAR-100 con 60,000 imágenes de diversas escenas y otro específico con 2,058 imágenes de cinco especies arbóreas nativas de Chiclayo. La diversidad y representatividad de estas imágenes, capturadas bajo distintas condiciones de iluminación, ángulos y distancias, proporcionaron una base sólida para el entrenamiento de los modelos, permitiendo alcanzar altos niveles de precisión en la identificación.
- Se implementó un modelo de aprendizaje automático basado en la arquitectura ResNet50 para la validación de presencia de árboles en imágenes, que logró una precisión excepcional del 98.43%, con una precisión por especie de 97.61%. Este modelo demostró alta robustez frente a variaciones en condiciones de iluminación y ángulos de captura, manteniendo tiempos de inferencia optimizados menores a 0.5 segundos por imagen, lo que garantiza su eficiencia en aplicaciones prácticas.
- Se implementó un modelo de clasificación multiclase basado también en ResNet50 que alcanzó una precisión global del 96% en la identificación de cinco especies arbóreas nativas de Chiclayo, con un rendimiento destacado en la identificación de especies como la Palmera Real (precisión 1.00) y el Ponciano. El modelo demostró alta capacidad para distinguir entre especies similares y mantener una clasificación precisa incluso ante imágenes con diferentes calidades y condiciones ambientales.
- Se construyó una API REST completa y robusta que integra ambos modelos de manera eficiente, incluyendo endpoints bien definidos para login, validación e identificación, y manejo eficiente de errores y excepciones. La API demostró tiempos de respuesta óptimos entre 2-5 segundos por consulta, lo que la hace viable para implementaciones en tiempo real en aplicaciones municipales o móviles.
- Se validó exhaustivamente el funcionamiento del sistema completo mediante una interfaz web especialmente diseñada, que permitió probar todos los casos de uso relevantes: validación de tipos de archivo, identificación correcta de imágenes sin árboles, y clasificación precisa de las cinco especies seleccionadas, cumpliendo con todos los requisitos funcionales y no funcionales establecidos al inicio del proyecto.

**Recomendaciones**

- Ampliar el dataset de especies arbóreas de Chiclayo para incluir más allá de las cinco especies actualmente contempladas, incorporando otras nativas e introducidas comunes en la zona urbana. Esto permitiría una caracterización más completa del patrimonio arbóreo local y mejoraría la utilidad práctica del sistema para inventarios municipales completos.
- Implementar técnicas avanzadas de aumento de datos que consideren variaciones estacionales y diferentes estados fenológicos de los árboles (floración, fructificación, pérdida de hojas), lo que mejoraría la robustez del modelo ante cambios temporales y permitiría identificar especies en diferentes épocas del año con mayor precisión.
- Incorporar imágenes captadas con drones para obtener perspectivas desde la copa de los árboles, lo que facilitaría la identificación en áreas de difícil acceso y complementaría la visión lateral actualmente utilizada, generando un sistema más versátil y aplicable a diferentes contextos urbanos.
- Integrar el sistema desarrollado con plataformas municipales existentes de gestión de espacios verdes, añadiendo capacidades como geolocalización de ejemplares, seguimiento de intervenciones (podas, tratamientos fitosanitarios), y alertas automáticas sobre riesgos potenciales basados en la identificación de especies y su estado, lo que potenciaría su impacto práctico en la gestión urbana sostenible.

**Referencias**

[1] N. Röbbel, «Los espacios verdes: un recurso indispensable para lograr una salud sostenible en las zonas urbanas», 30 de diciembre de 2016. [En línea]. Disponible en: https://www.un.org/es/chronicle/article/los-espacios-verdes-un-recurso-indispensable-para-lograr-una-salud-sostenible-en-las-zonas-urbanas

[2] UNECE, «Desafío de los árboles en las ciudades», 2019. [En línea]. Disponible en: https://land.unece.org/treesincities/

[3] L. Picek, M. Šulc, Y. Patel, y J. Matas, «Plant recognition by AI: Deep neural nets, transformers, and kNN in deep embeddings», *Front. Plant Sci.*, vol. 13, p. 787527, sep. 2022, doi: 10.3389/fpls.2022.787527.

[4] B. Liu *et al.*, «Tree Species Classification Using Ground-Based LiDAR Data by Various Point Cloud Deep Learning Methods», *Remote Sens.*, vol. 14, n.º 22, p. 5733, nov. 2022, doi: 10.3390/rs14225733.

[5] Organización de las Naciones Unidas, «Se proyecta que el 68% de la población mundial vivirá en zonas urbanas en 2050, según la ONU.», 2018. [En línea]. Disponible en: https://www.un.org/uk/desa/68-world-population-projected-live-urban-areas-2050-says-un

[6] Organización de las Naciones Unidas (ONU), «Las ciudades seguirán creciendo, sobre todo en los países en desarrollo». [En línea]. Disponible en:

https://www.un.org/es/desa/2018-world-urbanization-prospects#:~:text=Actualmente%2C%20las%20%C3%A1reas%20m%C3%A1s%20urbanizadas,Europa%3A%2074%20%25.

[7] INEI, «POBLACIÓN PERUANA ALCANZÓ LOS 33 MILLONES 726 MIL PERSONAS EN EL AÑO 2023», *Oficina Técnica de Difusión*, 10 de julio de 2023. [En línea]. Disponible en: https://m.inei.gob.pe/media/MenuRecursivo/noticias/nota-de-prensa-no-104-2023-inei.pdf

[8] M. L. Ortiz-Moreno y C. I. Caro-Caro, «Áreas verdes y vivienda de interés social: histórico déficit de bienestar ambiental», *Rev. UDCA Actual. Divulg. Científica*, vol. 28, n.º 1, feb. 2025, doi: 10.31910/rudca.v28.n1.2025.2595.

[9] Programa de las Naciones Unidas para el Medio Ambiente (PNUMA), «Proyecto GEO Ciudades 10 años». [En línea]. Disponible en: https://sinia.minam.gob.pe/sites/default/files/sinia/archivos/public/docs/2997.pdf

[10] Ministerio del Ambiente (MINAM), «Lazamiento Iniciativa Reconocimiento Árboles Patrimoniales», 2021. [En línea]. Disponible en: https://www.gob.pe/institucion/minam/campa%C3%B1as/4102-arboles-patrimoniales

[11] P. Bonnet *et al.*, «Plant Identification: Experts vs. Machines in the Era of Deep Learning», en *Multimedia Tools and Applications for Environmental & Biodiversity Informatics*, A. Joly, S. Vrochidis, K. Karatzas, A. Karppinen, y P. Bonnet, Eds., Cham: Springer International Publishing, 2018, pp. 131-149. doi: 10.1007/978-3-319-76445-0_8.

[12] A. Abdollahnejad y D. Panagiotidis, «Tree Species Classification and Health Status Assessment for a Mixed Broadleaf-Conifer Forest with UAS Multispectral Imaging», *Remote Sens.*, vol. 12, n.º 22, p. 3722, nov. 2020, doi: 10.3390/rs12223722.

[13] K. Alpan y B. Sekeroglu, «TREE INVENTORY REGISTRATION SYSTEM», *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.*, vol. XLIV-4/W3-2020, pp. 29-32, nov. 2020, doi: 10.5194/isprs-archives-XLIV-4-W3-2020-29-2020.

[14] S. Lukacs de Pereny, «ÁRBOLES Y CALIDAD DE VIDA: ANALIZANDO SU "PODER VERDE" EN ÁREAS URBANAS», *Cámara de Comercio de La Libertad*, 13 de marzo de 2024. [En línea]. Disponible en: https://camaralalibertad.org.pe/arboles-y-calidad-de-vida-analizando-su-poder-verde-en-areas-urbanas/

[15] K. Choi *et al.*, «An automatic approach for tree species detection and profile estimation of urban street trees using deep learning and Google street view images», *ISPRS J. Photogramm. Remote Sens.*, vol. 190, pp. 165-180, ago. 2022, doi: 10.1016/j.isprsjprs.2022.06.004.

[16] O. Martínez Gaitán, «Plan De Gestión Del Arbolado Urbano», *Universidad de Jaén*, 2020. [En línea]. Disponible en: https://www.ujaen.es/servicios/utecnica/sites/servicio_utecnica/files/uploads/node_seccion_de_micrositio/2020-03/PLAN%20DIRECTOR.pdf

[17] X. Mejía, «Chiclayo: remoción de 42 árboles en avenida principal sería inviable y afectaría salud de ciudadanos», 20 de junio de 2022. [En línea]. Disponible en: https://www.actualidadambiental.pe/chiclayo-remocion-de-42-arboles-en-avenida-principal-seria-inviable-y-afectaria-salud-de-ciudadanos/

[18] D. S. Jodas, S. Brazolin, G. D. N. Velasco, R. A. De Lima, T. Yojo, y J. P. Papa, «Urban tree failure probability prediction based on dendrometric aspects and machine learning models», *Comput. Environ. Urban Syst.*, vol. 108, p. 102074, mar. 2024, doi: 10.1016/j.compenvurbsys.2024.102074.

[19] D. Baldivia Blume, «Inician tala de árboles contra el segundo parque más grande de Piura, a pesar de denuncias y protestas de vecinos», 7 de mayo de 2024. [En línea]. Disponible en: https://www.infobae.com/peru/2024/05/07/inician-tala-de-arboles-

contra-el-segundo-parque-mas-grande-de-piura-a-pesar-de-denuncias-y-protestas-de-vecinos/

[20] Ministerio del Ambiente - MINAM, «Visor de Árboles Patrimoniales del Minam permite observar ejemplares reconocidos en el marco del bicentenario», 21 de abril de 2022. [En línea]. Disponible en: https://sinia.minam.gob.pe/novedades/visor-arboles-patrimoniales-minam-permite-observar-ejemplares

[21] D. L. H. Rabadán, J. P. S. Hernández, E. L. Sosa, J. F. Solis, y J. J. G. Barbosa, «ANÁLISIS DE ARQUITECTURAS DE REDES NEURONALES CONVOLUCIONALES APLICADAS A LA DETECCIÓN DE CENICILLA POLVORIENTA EN CULTIVOS DE JITOMATE».

[22] I. Capecchi, T. Borghini, y I. Bernetti, «Automated urban tree survey using remote sensing data, Google street view images, and plant species recognition apps», *Eur. J. Remote Sens.*, vol. 56, n.º 1, p. 2162441, dic. 2023, doi: 10.1080/22797254.2022.2162441.

[23] J. Ringland, M. Bohm, y S.-R. Baek, «Characterization of food cultivation along roadside transects with Google Street View imagery and deep learning», *Comput. Electron. Agric.*, vol. 158, pp. 36-50, mar. 2019, doi: 10.1016/j.compag.2019.01.014.

[24] D. Homan y J. A. Du Preez, «Automated feature-specific tree species identification from natural images using deep semi-supervised learning», *Ecol. Inform.*, vol. 66, p. 101475, dic. 2021, doi: 10.1016/j.ecoinf.2021.101475.

[25] A. Blanco, J. Sánchez, C. Del Carpio, E. Dianderas, y G. Kemper, «Identification of Peruvian timber species based on image processing and convolutional neural networks», *Int. J. Appl. Sci. Eng.*, vol. 21, n.º 1, pp. 1-17, 2023, doi: 10.6703/IJASE.202403_21(1).001.

[26] S. Arragokula y M. Y. Ratnam, «Architectural Styles and the Design of Network- based Software Architectures», *Manag. Educ.*, vol. 3, n.º 1, 2016.

[27] M. Lanthaler y C. Gütl, «Seamless Integration of RESTful Services into the Web of Data», *Adv. Multimed.*, vol. 2012, pp. 1-14, 2012, doi: 10.1155/2012/586542.

[28] E. Gómez Cobos, «Visibilidad en la Web de los Colegios Oficiales de Aparejadores, Arquitectos Técnicos e Ingenieros de Edificación de Andalucía», *Rev. Gen. Inf. Doc.*, vol. 25, n.º 2, pp. 313-339, dic. 2015, doi: 10.5209/rev_RGID.2015.v25.n2.51239.

[29] S. Han Lee, C. Seng Chan, y P. Remagnino, «Clasificación de plantas multiorgánicas basada en redes neuronales convolucionales y recurrentes», *IEEE Trans. Image Process.*, vol. 27, n.º 9, pp. 4287-4301, may 2018, doi: 10.1109/TIP.2018.2836321.

[30] M. U. Ahmad, S. Ashiq, G. Badshah, A. H. Khan, y M. Hussain, «Feature Extraction of Plant Leaf Using Deep Learning», *Complexity*, vol. 2022, n.º 1, p. 6976112, ene. 2022, doi: 10.1155/2022/6976112.

[31] D. L. H. Rabadán, J. P. S. Hernández, E. L. Sosa, J. F. Solis, y J. J. G. Barbosa, «ANÁLISIS DE ARQUITECTURAS DE REDES NEURONALES CONVOLUCIONALES APLICADAS A LA DETECCIÓN DE CENICILLA POLVORIENTA EN CULTIVOS DE JITOMATE».

[32] C. Bonilla Carrión, «Redes Convolucionales», TRABAJO FIN DE GRADO, Universidad de Sevilla, Sevilla, 2020. [En línea]. Disponible en: https://idus.us.es/server/api/core/bitstreams/aa10b7ce-d576-4a9b-9e6b-a2ddd5dfa881/content

[33] D. Aguilar Sandí, «¿Qué es un árbol?», *Rev. Biol. Trop.*, p. Blog, jun. 2019, doi: 10.15517/rbt.v0i3.37682.

[34] ONU, «Campaña del PNUMA supera marca de 4.000 millones de árboles sembrados», *Mirada global Historias humanas*. [En línea]. Disponible en: https://news.un.org/es/story/2009/06/1166201

[35] A. J. COOMBES, *Manuales de identificación de árboles*, OMEGA, S.A. Barcelona: Kyodo Printing Co., Singapore. [En línea]. Disponible en: https://revistaecociencias.cl/wp-content/uploads/2020/07/Atlas-Manual-de-Identificaci%C3%B3n-de-%C3%81rboles-Allen-J-Coombes.pdf

[36] International Business Machines Corporation (IBM), «Guía de CRISP-DM de IBM SPSS Modeler», p. 46.

[37] A. L. Moreno Díaz, «Análisis comparativo de arquitecturas de redes neuronales para la clasificación de imágenes», Trabajo Fin de Máster, Universidad Internacional de La Rioja (UNIR), 2020. [En línea]. Disponible en: https://reunir.unir.net/bitstream/handle/123456789/10008/Moreno%20D%c3%adaz-Alejo%2c%20Lara.pdf?sequence=1&isAllowed=y

## Anexos

### Anexo 1

### Arquitectura del proyecto

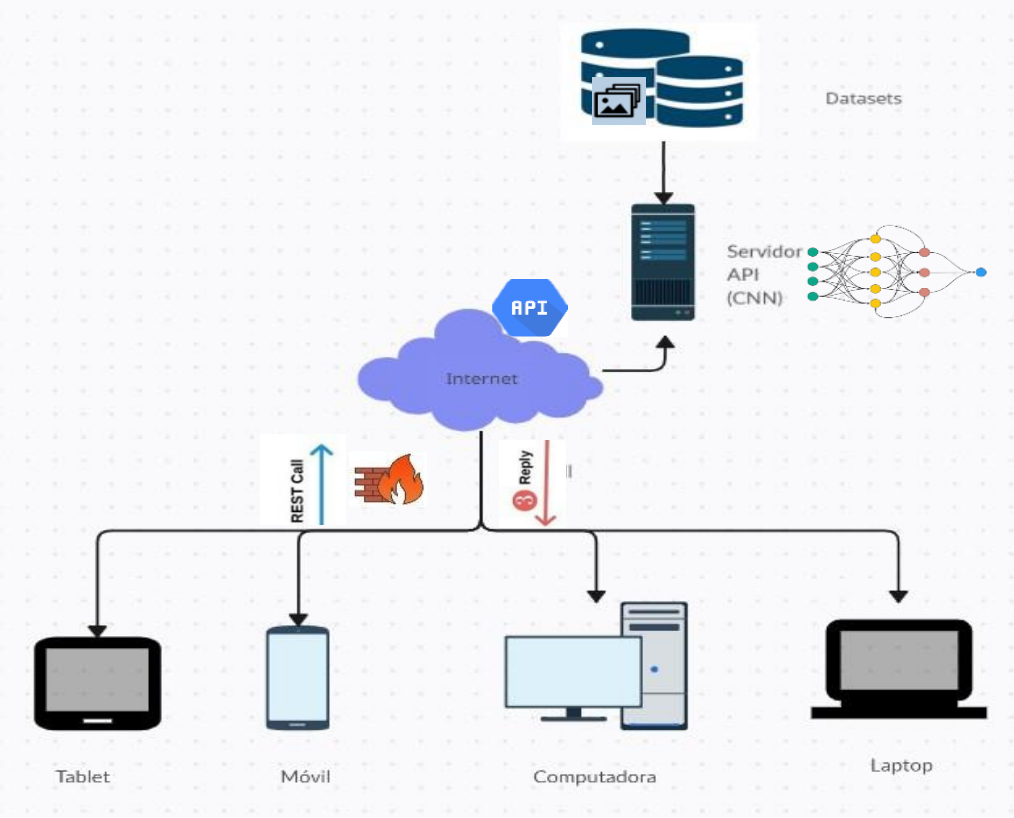


*Fig.16. Arquitectura del proyecto*

La arquitectura estará conformada por:

- Dispositivos Clientes (Tablet, Móvil, Computadora, Laptop): Son los dispositivos desde los cuales los usuarios interactúan con el sistema. Pueden ser dispositivos móviles (tabletas, teléfonos inteligentes) o dispositivos de escritorio (computadoras de escritorio, laptops). Estos dispositivos envían solicitudes a través de Internet para acceder a los servicios del sistema.
- Internet: Es la red global que permite la comunicación entre los dispositivos clientes y el servidor. Proporciona la conectividad necesaria para que los dispositivos clientes puedan enviar solicitudes y recibir respuestas del servidor.
- Firewall: Es un componente de seguridad que actúa como barrera de protección entre la red interna y la red externa (Internet). Filtra el tráfico entrante y saliente según las reglas de seguridad establecidas, permitiendo o bloqueando conexiones según sea necesario. Ayuda a proteger el sistema de amenazas externas, como ataques cibernéticos o accesos no autorizados.

- Servidor API (CNN): Es el servidor que aloja la implementación de las Redes Neuronales Convolucionales (CNN). Recibe las solicitudes de los dispositivos clientes a través de Internet y el Firewall. Utiliza los modelos de CNN entrenados para procesar las imágenes recibidas y realizar la identificación de especies de árboles. Proporciona una interfaz de programación de aplicaciones (API) para que los dispositivos clientes puedan interactuar con el sistema.
- Datasets: Son los conjuntos de datos utilizados para entrenar los modelos de CNN. Contienen imágenes de diferentes especies de árboles, etiquetadas con sus respectivas clasificaciones. Los Datasets son utilizados durante la fase de entrenamiento de los modelos de CNN para ajustar sus pesos y parámetros. Asimismo, están almacenados en servicio de almacenamiento en la nube.

## Anexo 2

## Cronograma de actividades

*Tabla 2. Cronograma de investigación*

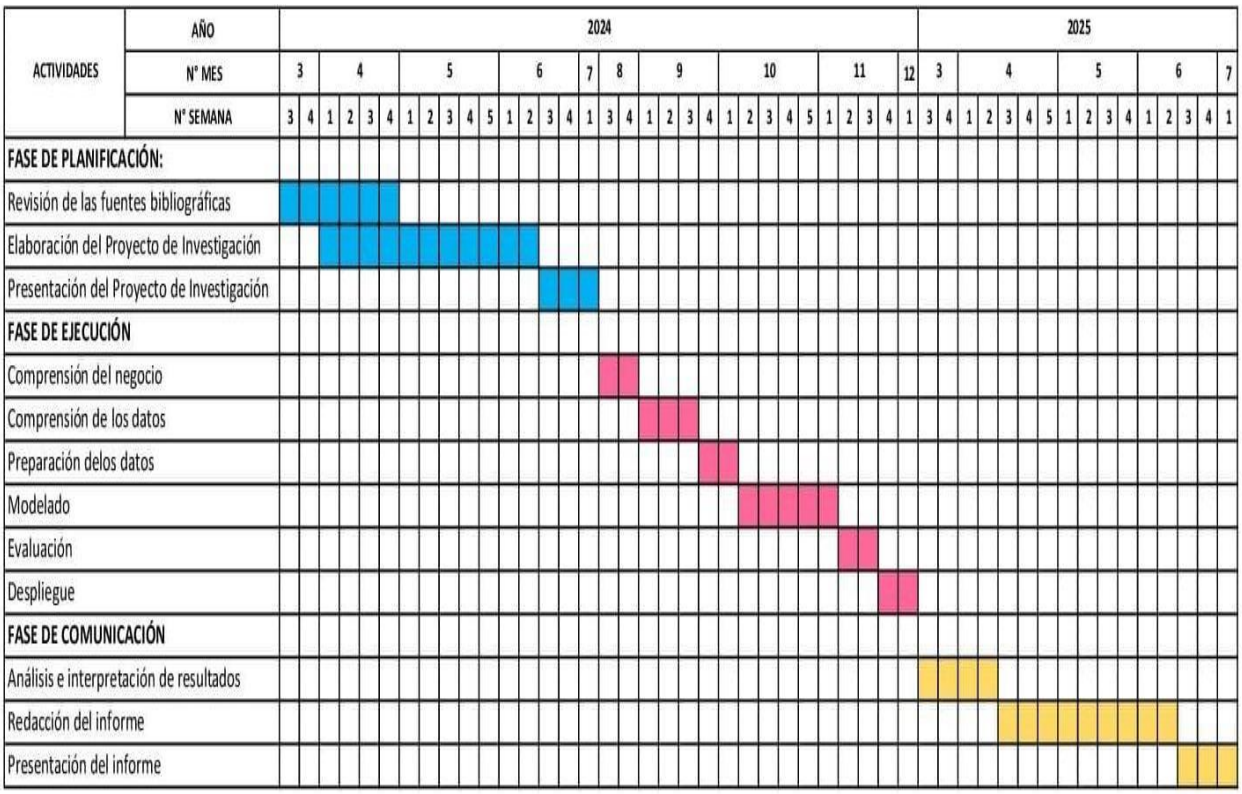


## Anexo 3

## PRESUPUESTO

## Presupuesto del producto acreditable

TABLA III
PRESUPUESTO DEL PRODUCTO ACREDITABLE

| PARTE PRESUP. | DESCRIPCIÓN | CANT. | UNIDAD DE MEDIDA | PRECIO UNITARIO (S/.) | PRECIO TOTAL (S/.) | SUBTOTAL (S/.) |
|---|---|---|---|---|---|---|
| 2.3.1.5.1 | Materiales y útiles de oficina | | | | | 50.00 |
| 2.3.1.5.1.2 | Papelería en general, útiles y materiales de Oficina | 1 | GLOBAL | 50.00 | 50.00 | |
| 2.3.21.2 | Viajes domésticos | | | | | 100.00 |
| 2.3.21.2.1 | Pasajes y gasto de transporte | 1 | GLOBAL | 100.00 | 100.00 | |
| | TOTAL, PRESUPUESTO DEL PROUCTO ACREDITABLE | | | | | 150.00 |

## Presupuesto tecnológico

TABLA IV
PRESUPUESTO TECNOLÓGICO

| PARTE PRESUP. | DESCRIPCIÓN | CANT. | UNIDAD DE MEDIDA | PRECIO UNITARIO (S/.) | PRECIO TOTAL (S/.) | SUBTOTAL (S/.) |
|---|---|---|---|---|---|---|
| 2.6.32.31 | Equipos computaciones y periféricos | | | | | 3,952.00 |
| | Laptop Core I5 | 1 | UNIDAD | 3,352.00 | 3,352.00 | |
| | Teléfono Android | 1 | UNIDAD | 600.00 | 600.00 | |
| 2.3.22.2 | Servicios de telefonía e internet | | | | | 90.00 |
| 2.3.22.2.3 | Servicio de internet | 1 | GLOBAL | 90.00 | 79.00 | |
| 2.6.61.3 | Activos intangibles | | | | | 438.00 |
| 2.6.61.3.2 | Softwares<br>- Visual Studio Code<br>- Android Studio<br>- Postman | 1<br>1<br>1 | UNIDAD<br>UNIDAD<br>UNIDAD | 00.00<br>00.00<br>00.00 | 000.00 | |
| 2.6.62.3.3 | Otros activos intangibles | | | | | |
| | - VPS<br>- Google Colab<br>- Google Drive | 1<br>1<br>1 | GLOBAL<br>GLOBAL<br>GLOBAL | 285.00<br>153.00<br>000.00 | 438.00 | |
| | TOTA, PRESUPUESTO TECNOLÓGICO | | | | | 4480.00 |

## Resumen presupuestal

TABLA V
RESUMEN PRESUPUESTAL

| ITEM | DESCRIPCIÓN PRESUPUESTO | SUBTOTAL (S/.) |
|---|---|---|
| 1 | TOTAL PRESUPUESTO DEL PRODUCTO ACREDITABLE | 150.00 |
| 2 | TOTAL PRESUPUESTO TECNOLÓGICO | 4,480.00 |
| | TOTAL, PRESUPUESTO | S/. 4,630.00 |

# Anexo 4

## Fichas detalladas de árboles de Chiclayo

*SUB GERENCIA DE LIMPIEZA PÚBLICA Y AREAS VERDES*

**CÓDIGO DE ÁRBOL:** 000/000/0027

EMPLAZAMIENTO: Árbol ubicado dentro del Parque 7 de Junio.

CLASIFICACIÓN TAXONÓMICA

| | |
|---|---|
| NOMBRE COMÚN | Ficus |
| NOMBRE CIENTÍFICO | *Ficus benjamina* |
| COMPORTAMIENTO FISIOLÓGICO | Siempreverde |
| DESCRIPCIÓN: Árbol de pequeño porte, perennifolio. Desarrolla raíces aéreas. Hojas pequeñas y con un color verde brillante y forma oval. Flores pequeñas, en inflorescencias a modo de siconos, de color blanquecino-amarillento. Fruto pequeño, y esférico. | |

CARACTERÍSTICAS DASOMÉTRICAS

| ***EDAD ESTIMADA (años)*** | ***ALTURA TOTAL (m)*** | ***COPA*** | | ***FUSTE*** | | | | ***RAICES*** |
|---|---|---|---|---|---|---|---|---|
| | | Ø ECUATORIAL (m) | FORMA | DAP (cm) | FORMA | ALTURA (m) | INCLINACION (°) | RAICES EXPUESTAS |
| | | | | | | | | |
| 25 - 30 | 7 | 7 | Redondo | 50 | Monopodial | 3 | 45 – 90 | No |

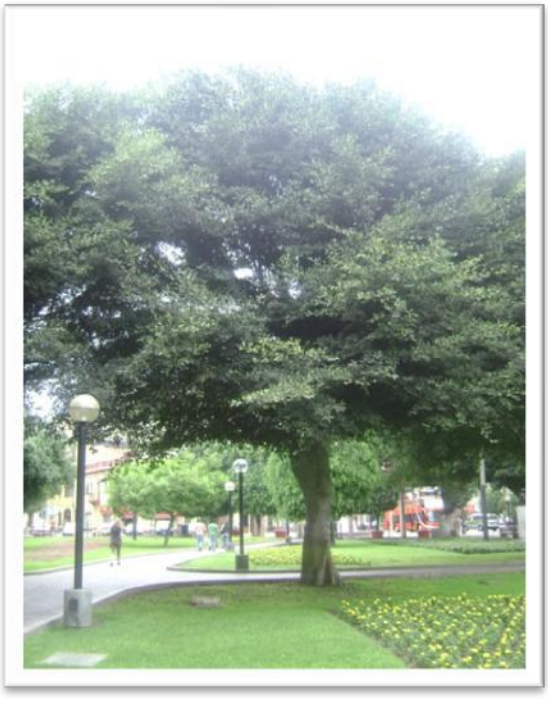

ESTADO FENOLÓGICO: Vegetativo con hojas.

ESTADO FITOSANITARIO

Árbol con presencia de nudos y sin presencia de agentes patógenos.

INTERFERENCIA CON LOS SERVICIOS PÚBLICOS

No existe interferencia alguna de la copa con los servicios públicos.

INTERVENCIÓN ANTROPOGÉNICA

Poda formativa de la copa.

ESTADO DE CONSERVACIÓN

Buena. Recibe riego y mantenimiento adecuado. Requierepoda de formación.

CALENDARIO DE

Última fecha de poda: julio - 2011

MANTENIMIENTO

RECOMENDACIONES

Requiere poda de formación de la copa. Necesita de un lavado del follaje del árbol.

*SUB GERENCIA DE LIMPIEZA PÚBLICA Y AREAS VERDES*

**CÓDIGO DE ÁRBOL:** 000/000/0062

EMPLAZAMIENTO: Árbol ubicado dentro del Parque 7 de Junio.

CLASIFICACION TAXONÓMICA

| | |
|---|---|
| NOMBRE COMÚN | Molle Costeño |
| NOMBRE CIENTÍFICO | *Schinus terebinthifolius* |
| COMPORTAMIENTO FISIOLÓGICO | Siempreverde |
| DESCRIPCION: Árbol con la copa densa de color verde oscuro; Tronco corto, a veces algo torcido, con la corteza oscura y fisurada; Hojas imparipinnadas, elípticos u obovados; Flores dioicas dispuestas en racimos axilares o terminales; Frutos rojizos dispuestos en racimos. | |

CARACTERÍSTICAS DASOMÉTRICAS

| ***EDAD ESTIMADA (años)*** | ***ALTURA TOTAL (m)*** | ***COPA*** | | ***FUSTE*** | | | | ***RAICES*** |
|---|---|---|---|---|---|---|---|---|
| | | Ø ECUATORIAL (m) | FORMA | DAP (cm) | FORMA | ALTURA (m) | INCLINACION (˚) | RAICES EXPUESTAS |
| 15 -20 | 5 | 7 | Aparasolada | 35 | Simpodial | 3 | 45 – 90 | Si |

ESTADO FENOLÓGICO Vegetativo con hojas.

ESTADO FITOSANITARIO

Bueno. Árbol con buena densidad de follaje. No presentasignos externos de agentes patógenos.

INTERFERENCIA CON LOS SERVICIOS PÚBLICOS

No existe interferencia de la copa con los servicios públicos.

INTERVENCION ANTROPOGÉNICA

Poda de formación de la copa.

ESTADO DE CONSERVACIÓN

Recibe riego adecuado. Requiere poda de formación.

CALENDARIO DE

Última fecha de poda: julio - 2011

MANTENIMIENTO

Requiere poda de formación de la copa, con la finalidad de evitar interferencias con la copa del árbol aledaño.

*SUB GERENCIA DE LIMPIEZA PÚBLICA Y AREAS VERDES*

**CÓDIGO DE ÁRBOL:** 000/000/0069

EMPLAZAMIENTO:

Palmera ubicada dentro del Parque 7 de Junio.

CLASIFICACIÓN TAXONÓMICA

| | |
|---|---|
| NOMBRE COMÚN | Palmera real |
| NOMBRE CIENTÍFICO | *Oreodoxa regia* |
| COMPORTAMIENTO FISIOLÓGICO | Siempreverde |
| DESCRIPCIÓN: Copa en forma de parasol. Tallo columnar limpio y liso de color gris en laparte inferior y verde claro en el extremo donde nacen las hojas. Hojas pinnadas de 2 a 3 metros de largo. Raíz ramificada y profunda. | |

CARACTERÍSTICAS DASOMÉTRICAS

| ***EDAD*** | ***ALTUR*** | ***COPA*** | ***FUSTE*** | ***RAICES*** |
|---|---|---|---|---|

| ***ESTIMADA (años)*** | ***A TOTAL (m)*** | Ø ECUATORIAL (m) | FORMA | DAP (cm) | FORMA | ALTURA (m) | INCLINACION (˚) | RAICES EXPUESTAS |
|---|---|---|---|---|---|---|---|---|
| 20 - 25 | 5.5 | 3 | Pendular | 35 | Monopodial | 4 | 45 – 90 | No |

ESTADO

Vegetativo con hojas.

FENOLÓGIC

No presenta signos externos de agentes patógenos en el fuste.

O ESTADO

FITOSANITA

RIO

INTERFERENCIA CON LOS SERVICIOS PÚBLICOS

No Existe interferencia de la copa con los servicios públicos.

INTERVENCIÓN ANTROPOGÉNICA

Poda de limpieza de las hojas de la palmera.

ESTADO DE CONSERVACIÓN

Bueno. Recibe riego adecuado.

CALENDARIO DE

Última fecha de poda: julio - 2011

MANTENIMIENTO

RECOMENDACIONE

Requiere poda continua de las hojas secas de la palmera, con la finalidad de evitar la caída de hojas por encontrase secas.

| |
|---|
| **Jefe de brigada**: Ing. James Alexander Chamaya Gonzáles |
| **Asistente:** Sr. Jaime Alberca Barboza |
| **Fecha de Inicio:** 02/04/19 |
| **Fecha de Término:** 06/04/19 |

| |
|---|
| **Región:** Lambayeque |
| **Provincia:** Chiclayo |
| **Distrito:** Chiclayo |
| **Ciudad:** Chiclayo |

| **Formulario para Inventario de Avenidas** | | | | | | | |
|---|---|---|---|---|---|---|---|
| **Nombre de Av: Jose Balta** | | | | | | | |
| **Código** | **Nombre Cientific** | **Nombre común** | **DAP (m)** | **Altura Total (m)** | **Ubicación (Dirección)** | **Edad aproxi mada** | **Descripción** |
| B0-01 | Schinus molle | Molle | 0,45 | 6,50 | Referencia: Esquina de balta y garcilazo | 20 | Árbol con fuste sinuoso, copa pendular. |
| B0-02 | Schinus molle | Molle | 0,50 | 6,50 | Referencia: Esquina de balta y garcilazo | 20 | Árbol con fuste sinuoso, copa pendular. |
| B0-03 | Ficus benjamina | Ficus | 0,38 | 5,00 | Frente al domicilio N° 015 | 11 | Árbol con fuste recto desde la base hasta 1.50m donde se bifurca, presenta copa globosa. |
| B0-04 | Ficus benjamina | Ficus | 0,20 | 3,50 | Frente al domicilio N° 025 | 11 | Árbol con fuste recto desde la base hasta 1.50m donde se bifurca, presenta copa globosa. |
| B0-05 | Ficus benjamina | Ficus | 0,23 | 3,00 | Frente al domicilio N° 035 | 11 | Árbol con fuste recto y copa globosa. |
| B0-06 | Ficus benjamina | Ficus | 0,22 | 3,00 | Frente al domicilio N° 039 | 11 | Árbol con fuste recto y copa globosa. |
| B0-07 | Spathodea campan | Tulipan africano | 0,22 | 4,50 | Frente al domicilio N° 057 | 10 | Árbol con fustte sinuoso,copa irregular. |
| B0-08 | Ficus benjamina | Ficus | 24,00 | 4,50 | Frente al domicilio N° 040 | 10 | Árbol con fuste recto desde la base hasta 1.50m donde se bifurca, presenta copa globosa. |
| B0-09 | Ficus benjamina | Ficus | 0,08<br>0,07 | 3,00 | Frente al domicilio N° 040 | 6 | Árbol que presenta dos brotes desde la base, fuste recto presenta copa globosa. |
| B0-10 | Delonix regia | Ponciano | 0,45 | 6,00 | Frente al domicilio N° 052 | 18 | Árbol con fuste recto desde la base hasta 0.50m donde se bifurca, presenta copa globosa |
| B0-11 | Ficus benjamina | Ficus | 0,03<br>0,02 | 2,50 | Frente al domicilio N° 054 | 2 | Árbol que presenta dos brotes desde la base, fuste recto presenta copa globosa |
| B0-12 | Ficus benjamina | Ficus | 0,12 | 4,50 | Referencia: Comisaria de familia (080) | 5 | Árbol con fuste recto desde la base hasta 1.50m donde se bifurca, presenta copa globosa. |
| B0-13 | Ficus benjamina | Ficus | 0,13 | 4,50 | Referencia: Comisaria de familia (080) | 5 | Árbol con fuste recto desde la base hasta 1.00m donde se bifurca, presenta copa globosa. |
| B0-14 | Ficus benjamina | Ficus | 0,11 | 4,50 | Referencia: Comisaria de familia (080) | 5 | Árbol con fuste recto desde la base hasta 0.50m donde se bifurca, presenta copa globosa. |
| B0-15 | Ficus benjamina | Ficus | 0,13 | 4,00 | Referencia: Comisaria de familia (080) | 5 | Árbol con fuste recto desde la base hasta 0.50m donde se bifurca, presenta copa globosa. |
| B0-16 | Ficus benjamina | Ficus | 0,22 | 4,00 | Referencia: Comisaria de familia (080) | 5 | Árbol con fuste recto desde la base hasta 0.50m donde se bifurca, presenta copa globosa. |
| B0-17 | Ficus benjamina | Ficus | 0,14 | 4,00 | Referencia: Comisaria de familia (080) | 5 | Árbol con fuste recto desde la base hasta 0.50m donde se bifurca, presenta copa globosa. |
| B0-18 | Ficus benjamina | Ficus | 0,14 | 4,00 | Referencia: Comisaria de familia (080) | 5 | Árbol con fuste recto desde la base hasta 0.50m donde se bifurca, presenta copa globosa. |
| B1-19 | Araucaria heteroph | Araucaria | 0,18 | 3,40 | Referencia: Frontis Universidad San Martin | 6 | Árbol con fuste recto, presenta copa irregular podado al tercio superior. |
| B1-20 | Spathodea campan | Tulipan africano | 0,28 | 5,00 | Referencia: Frontis Universidad San Martin | 10 | Árbol con fuste recto, la copa no presenta hojas por indicios de sequedad. |

| | | | | | | | |
|---|---|---|---|---|---|---|---|
| B1-21 | Spathodea campan | Tulipan africano | 0,30 | 6,50 | Referencia: Frontis Universidad San Martin | 10 | Árbol con fuste acanaldado, presenta copa irregular podado |
| B1-22 | Araucaria heteroph | Araucaria | 0,22 | 18,00 | Referencia: Frontis Universidad San Martin | 8 | Árbol con fuste recto, presenta copa conica |
| B1-23 | Ficus benjamina | Ficus | 0,17 | 1,80 | Referencia: Frente a Premium | 8 | Árbol con fuste recto desde la base hasta 0.40m donde se bifurca, presenta copa globosa |
| B1-24 | Ficus benjamina | Ficus | 0,16 | 1,80 | Referencia: Frente a Premium | 8 | Árbol con fuste recto desde la base hasta 0.50m donde se bifurca, presenta copa globosa |
| B1-25 | Ficus benjamina | Ficus | 0,13 | 1,80 | Referencia: Frontis Metro | 8 | Árbol con fuste recto desde la base hasta 0.50m donde se bifurca, presenta copa globosa |
| B1-26 | Ficus benjamina | Ficus | 0,11 | 1,80 | Referencia: Frontis Metro | 8 | Árbol con fuste recto desde la base hasta 0.30m donde se bifurca, presenta copa globosa |
| B1-27 | Ficus benjamina | Ficus | 0,16 | 1,80 | Referencia: Frontis Metro | 8 | Árbol con fuste recto desde la base hasta 0.50m donde se bifurca, presenta copa globosa |
| B1-28 | Ficus benjamina | Ficus | 0,12 | 1,80 | Referencia: Frontis Metro | 8 | Árbol con fuste recto desde la base hasta 0.40m donde se bifurca, presenta copa globosa |
| B1-29 | Ficus benjamina | Ficus | 0,18 | 2,00 | Referencia: Frontis Metro | 8 | Árbol con fuste recto desde la base hasta 0.50m donde se bifurca, presenta copa globosa |
| B1-30 | Ficus benjamina | Ficus | 0,20 | 2,00 | Referencia: Frontis Metro | 8 | Árbol con fuste recto desde la base hasta 0.50m donde se bifurca, presenta copa globosa |
| B1-31 | Ficus benjamina | Ficus | 0,09<br>0,07 | 1,60 | Referencia: Frontis Metro | 8 | Árbol que presenta dos brotes desde la base, fuste recto presenta copa irregular |
| B1-32 | Ficus benjamina | Ficus | 0,12<br>0,10<br>0,90 | 2,00 | Referencia: Frontis Metro | 6 | Árbol trifurcado desde la base, fustes rectos, copa globosa |
| B1-33 | Ficus benjamina | Ficus | 0,14 | 2,30 | Referencia: Grifo Petro Perú | 6 | Árbol con fuste recto desde la base hasta 0.50m donde se bifurca, presenta copa globosa |
| B1-34 | Hibiscus rosa-sinensis | Cucarda | 0,10 | 2,40 | Referencia: Grifo Petro Perú | 4 | Árbol, presenta fuste sinuoso, presencia de rebrotes, copa globosa |
| B1-35 | Citrus × sinensis | Naranja | 0,50 | 2,00 | Referencia: Grifo Petro Perú | 4 | Árbol, fuste sinuoso, copa irregular |
| B1-36 | Ficus benjamina | Ficus | 0,08<br>0,06 | 2,00 | Referencia: Grifo Petro Perú | 5 | Árbol bifurcado desde la base, fustes rectos, copa irregular |
| B1-37 | Ficus benjamina | Ficus | 0,08<br>0,09 | 2,00 | Referencia: Grifo Petro Perú | 5 | Árbol que presenta dos brotes desde la base, fuste recto presenta copa irregular |
| B1-38 | Ficus elastica | Gomero | 0,60 | 18,00 | Referencia: Frente Entrafesa | 22 | Árbol, fuste recto acanalado, copa columnar |
| B1-39 | Schinus terebinthifolius | Molle hawaiano | 0,44 | 12,00 | Referencia: Frente a Telesup | 15 | Árbol, fuste sinuoso, copa irregular |
| B1-40 | Ficus benjamina | Ficus | 0,13 | 6,50 | Referencia: Frente a Elektra | 10 | Árbol, fuste recto acanalado, copa globosa |
| B1-41 | Spathodea campan | Tulipan africano | 0,15 | 6,00 | Referencia: Frente a Elektra | 8 | Ärbol, fuste acanalado sinuoso, copa irregular |
| B2-42 | Spathodea campan | Tulipan africano | 0,36 | 2,50 | Referencia: Esquina de Balta y Bolognesi | 15 | Árbol, fuste recto acanalado, mo presenta copa por poda agresiva |

| | | | | | | | |
|---|---|---|---|---|---|---|---|
| B2-44 | Ficus benjamina | Ficus | 0,17<br>0,09 | 4,50 | Frente al domicilio N° 219 | 10 | Árbol, presenta dos brotes desde la base, fuste recto presenta copa globosa |
| B2-45 | Ficus benjamina | Ficus | 0,14 | 11,00 | Frente al domicilio N° 233 | 10 | Árbol con fuste recto desde la base hasta 0.50m donde se bifurca, presenta copa globosa |
| B2-46 | Ficus benjamina | Ficus | 0,21 | 5,50 | Frente al domicilio N° 249 | 10 | Árbol con fuste recto, presenta copa globosa |
| B2-47 | Spathodea campan | ulipan african | 0,36 | 6,00 | Frente al domicilio N° 259 | 25 | Árbol con fuste recto, presenta copa irregular |
| B2-48 | Spathodea campan | ulipan african | 0,40 | 8,00 | Frente al domicilio N° 275 | 25 | Árbol con fuste recto, presenta copa irregular |
| B2-49 | Spathodea campan | ulipan african | 0,11 | 4,50 | Frente al domicilio N° 292 | 10 | Árbol con fuste recto, presenta copa irregular |
| B2-50 | Spathodea campan | ulipán african | 0,40 | 8,00 | Frente al domicilio N° 292 | 20 | Árbol con fuste recto, presenta copa irregular |
| B2-51 | Ficus benjamina | Ficus | 0,15 | 4,50 | Referencia: Centro de idiomas UNPRG | 8 | Ärbol, fuste recto, copa globosa |
| B2-52 | Ficus benjamina | Ficus | 0,30 | 4,50 | Referencia: Centro de idiomas UNPRG | 8 | Árbol con fuste recto desde la base hasta 0.50m donde se bifurca, presenta copa globosa |
| B2-53 | Ficus benjamina | Ficus | 0,18 | 4,50 | Referencia: Centro de idiomas UNPRG | 8 | Árbol, fuste recto, copa globosa |
| B2-54 | Spathodea campan | ulipán african | 0,15 | 13,00 | Referencia: Centro de idiomas UNPRG | 15 | Árbol, fuste sinuoso, copa irregular |
| B2-55 | Ficus benjamina | Ficus | 0,12 | 4,50 | Referencia: Centro de idiomas UNPRG | 8 | Árbol, fuste recto, copa globosa |
| B2-56 | Spathodea campan | ulipán african | 0,32 | 15,00 | Referencia: Centro de idiomas UNPRG | 12 | Árbol, fuste sinuoso, copa irregular |
| B2-57 | Spathodea campan | ulipán african | 0,30 | 15,00 | Referencia: Caja Sipan | 12 | Árbol, fuste sinuoso, copa irregular |
| B2-58 | Ficus benjamina | Ficus | 0,15 | 4,50 | Referencia: Caja Sipan | 8 | Árbol, fuste recto, copa globosa |
| B2-59 | Spathodea campan | ulipán african | 0,29 | 12,00 | Referencia: Caja Sipan | 8 | Árbol, fuste recto, copa globosa |
| B2-60 | Spathodea campan | ulipán african | 0,33 | 14,00 | Referencia: Caja Sipan | 18 | Árbol, fuste recto,acanalado, copa irregular |
| B2-61 | Ficus benjamina | Ficus | 0,24 | 5,00 | Referencia: Caja Sipan | 18 | Árbol, fuste recto, copa globosa |
| B3-62 | Spathodea campan | ulipán african | 0,10<br>0,09<br>0,05 | 3,00 | Frente al domicilio N° 307 | 1 | Árbol, presenta tres rebrotes con fuste recto, copa irregular |
| B3-63 | Spathodea campan | ulipán african | 0,04<br>0,04<br>0,03<br>0,02 | 1,70 | Frente al domicilio N° 319 | 1 | Árbol, presenta cuatro rebrotes con fuste recto, copa irregular |
| B3-64 | Ficus benjamina | Ficus | 0,15 | 4,50 | Referencia: Frente a garaje de h | 10 | Árbol, fuste recto, copa globosa |

## Anexo 5

## Imágenes referenciales del dataset de árboles de Chiclayo

- Algarrobo: 507 imágenes

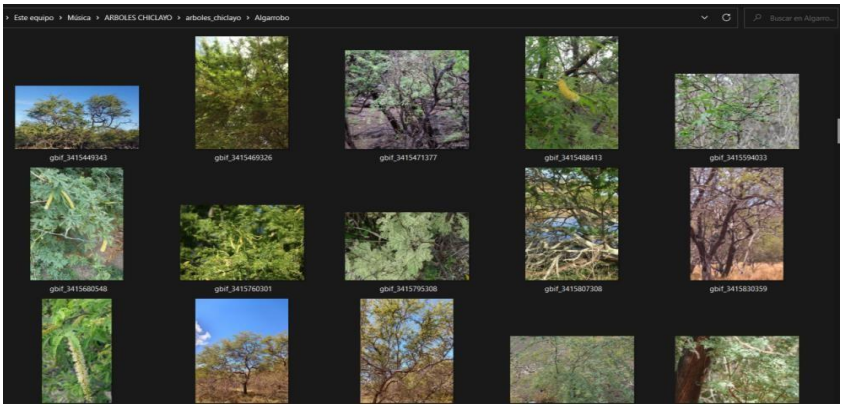

Fig.14. Imágenes Especie Algarrobo

- Ficus: 505 imágenes

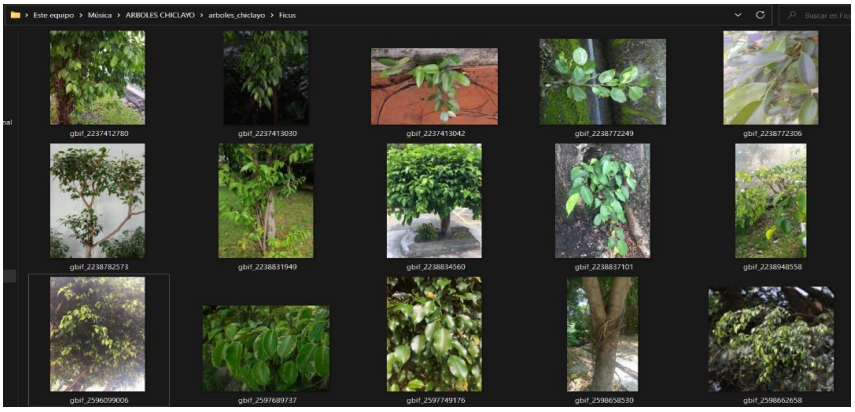

Fig. 15. Imágenes Especie Ficus

- Molle Hawaiano: 535 imágenes

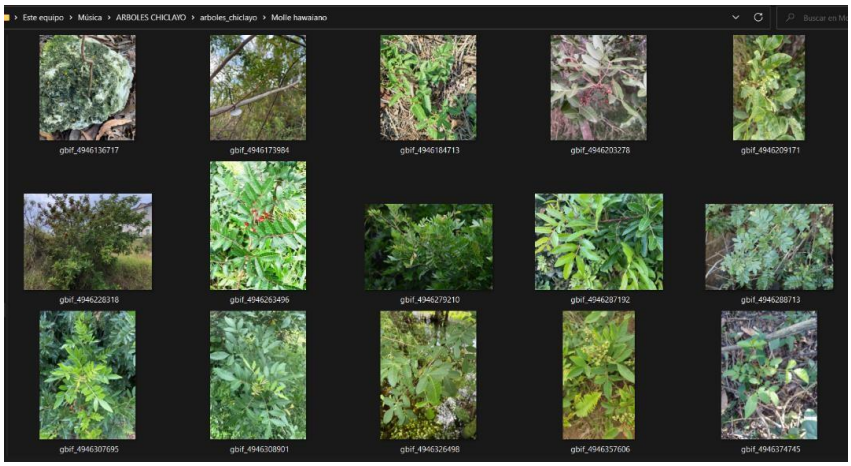

Fig. 16. Imágenes Especie Molle Hawaiano

- Palmera Real: 511 imágenes

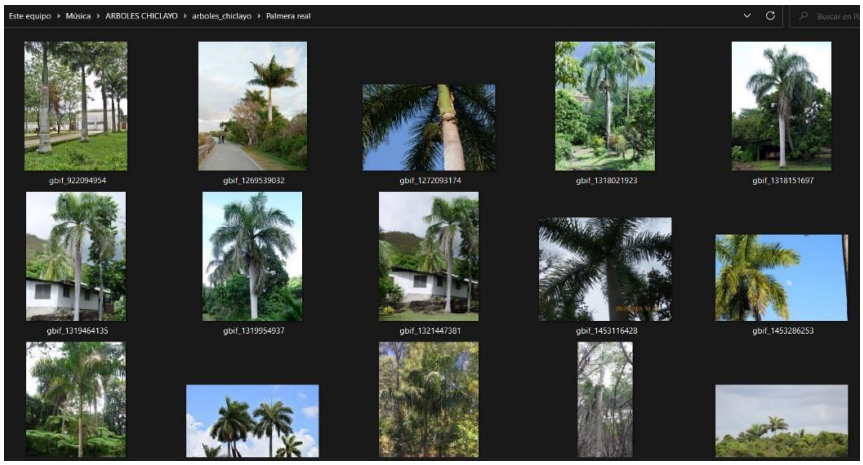


Fig. 7. Imágenes Especie Palmera Real

- Ponciano: 510 imágenes

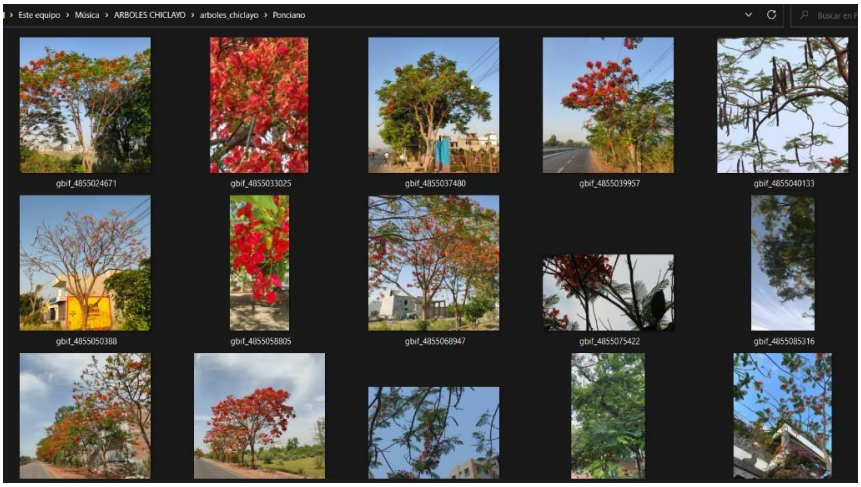


Fig. 8. Imágenes Especie Ponciano

O aquí también podemos observas imágenes de árboles obtenidos mediante la API de Google Street View:

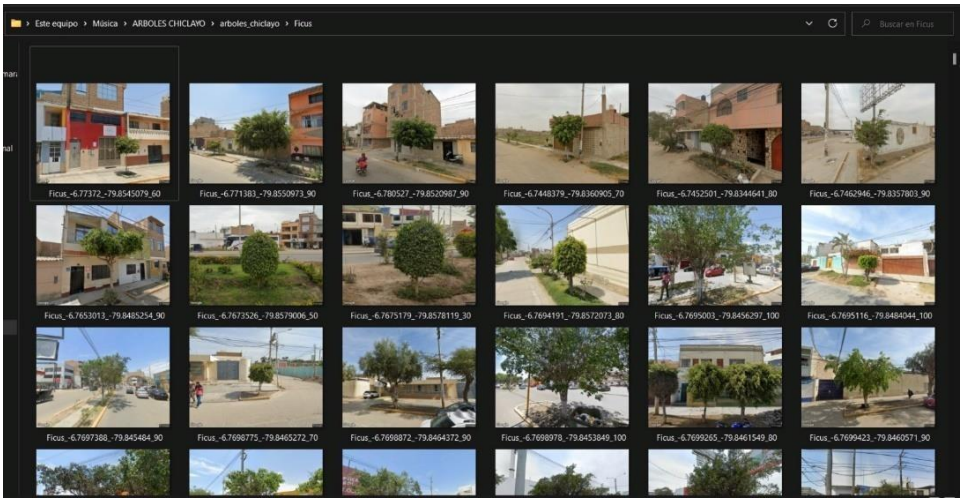


Fig. 9. Imágenes Especies obtenidas por Google Steet View

**Anexo 6**

**Arquitecturas de redes neuronales convolucionales**

**Tabla Comparativa de Arquitecturas CNN**

| Aspecto | EfficientNet | ResNet | VGG | DenseNet |
|---|---|---|---|---|
| **Año de Introducción** | 2019 | 2015 | 2014 | 2016 |
| **Autores/Organización** | Google Research | Microsoft Research | Oxford University | Facebook AI Research |
| **Principio Fundamental** | Escalado compuesto balanceado | Conexiones residuales | Simplicidad y profundidad | Conexiones densas |

**Características Arquitectónicas**

| Característica | EfficientNet | ResNet | VGG | DenseNet |
|---|---|---|---|---|
| **Profundidad Típica** | B0: 224 capas, B7: 813 capas | 18, 34, 50, 101, 152 capas | 11, 13, 16, 19 capas | 121, 169, 201, 264 capas |
| **Tamaño de Filtros** | Optimizado por NAS (3x3, 5x5, 7x7) | Principalmente 3x3 | Exclusivamente 3x3 | Principalmente 3x3 |
| **Conexiones Especiales** | Squeeze-and-Excitation | Skip connections (residuales) | Secuenciales tradicionales | Dense connections |
| **Función de Activación** | Swish | ReLU | ReLU | ReLU |
| **Normalización** | Batch Normalization | Batch Normalization | Sin normalización | Batch Normalization |

## Rendimiento y Eficiencia

| Métrica | EfficientNet | ResNet | VGG | DenseNet |
|---|---|---|---|---|
| **Accuracy ImageNet (Top-1)** | B0: 77.3%, B7: 84.3% | ResNet-50: 76.0%, | VGG-16: 71.5%, VGG-19: 72.4% | DenseNet-121: 74.4%, DenseNet-201: 77.3% |

| | | | | |
|---|---|---|---|---|
| | | ResNet-152: 78.3% | | |
| **Parámetros** | B0: 5.3M, B7: 66M | ResNet-50: 25.6M, ResNet-152: 60.2M | VGG-16: 138M, VGG-19: 144M | DenseNet-121: 8.0M, DenseNet-201: 20M |
| **FLOPs** | B0: 0.39B, B7: 37B | ResNet-50: 4.1B, ResNet-152: 11.6B | VGG-16: 15.5B, VGG-19: 19.6B | DenseNet-121: 2.9B, DenseNet-201: 4.3B |
| **Eficiencia Computacional** | Excelente | Buena | Regular | Buena |

**Ventajas y Desventajas**

| Arquitectura | Ventajas | Desventajas |
|---|---|---|
| **EfficientNet** | Máxima eficiencia parámetro/precisión, Escalado compuesto sistemático, Estado del arte en muchos benchmarks, Optimización automática (NAS) | Complejidad de implementación, Requiere más memoria en entrenamiento, Dependiente de hardware moderno |
| **ResNet** | Soluciona problema del gradiente que desaparece, Fácil de implementar, Escalabilidad probada, Amplia adopción en la industria | Alto consumo de memoria, Redundancia en características, No optimizado para eficiencia |
| **VGG** | Arquitectura simple y comprensible, Filtros pequeños uniformes, Fácil de implementar, Buena base para transfer learning | Excesivo número de parámetros, Alto costo computacional, Problemas de overfitting, Obsoleta para aplicaciones modernas |
| **DenseNet** | Eficiente en parámetros, Reutilización de características, Mejor propagación del gradiente, Menor tendencia al overfitting | Alto consumo de memoria durante entrenamiento, Complejidad de implementación, Menor velocidad de inferencia |

Esta docuemntación fue realizada bajo las siguientes investigaciones:

- **Tan & Le** (2019): EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks
- **He, Zhang, Ren & Sun** (2016): Deep Residual Learning for Image Recognition
- **Simonyan & Zisserman** (2014): Very Deep Convolutional Networks for Large-Scale Image Recognition
- **Huang, Liu, Van Der Maaten & Weinberger** (2017): Densely Connected Convolutional Networks

## Anexo 7

## Pruebas realizadas desde la aplicación web

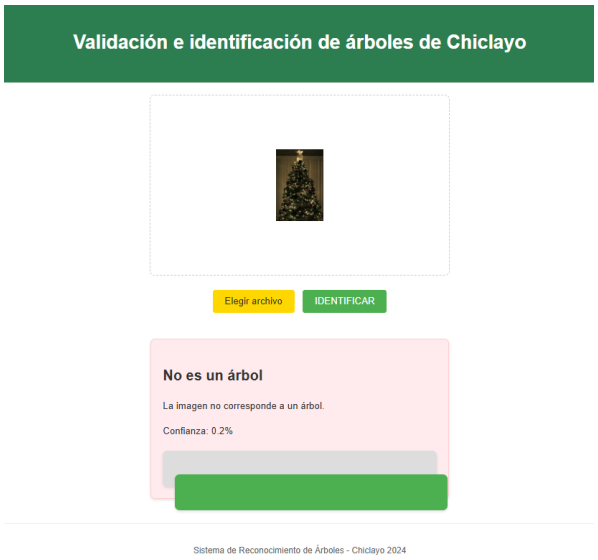


Fig. 23. Prueba de validación de árbol desde la aplicación web

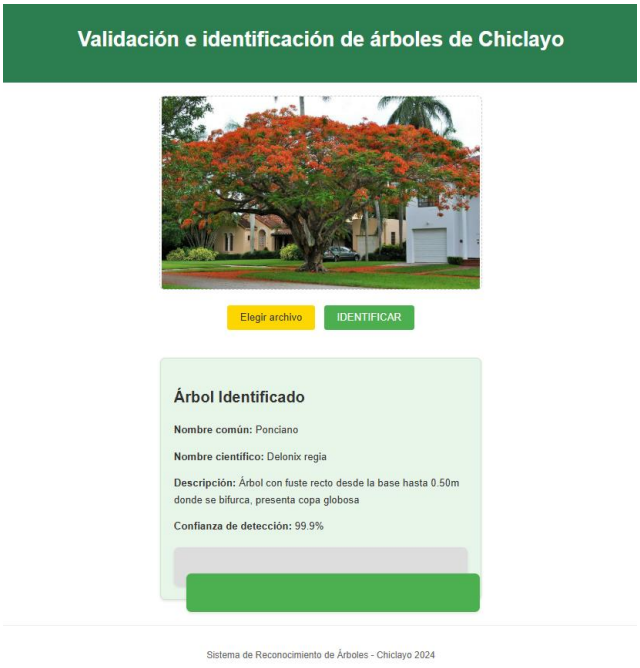


Fig.24. Prueba de identificación de árbol Ponciano desde la aplicación web

Fig. 25. Prueba de identificación de árbol Molle desde la aplicación web

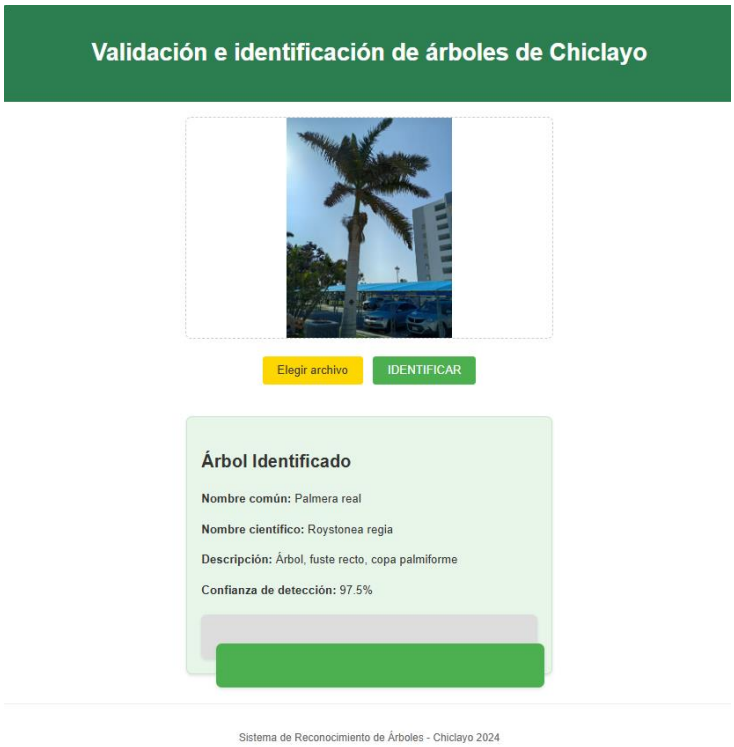


Fig.26. Prueba de identificación de árbol Palmera desde la aplicación web

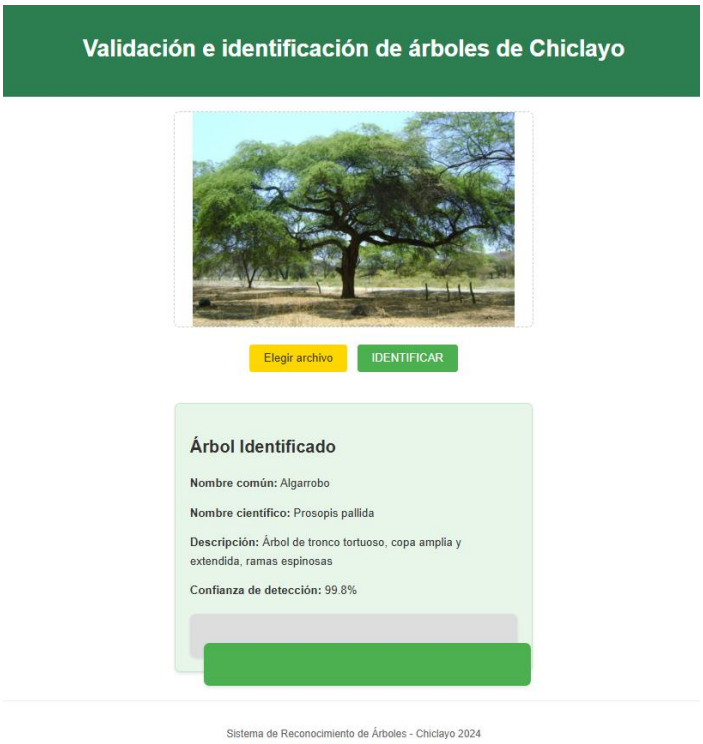


Fig. 27. Prueba de identificación de árbol Algarrobo desde la aplicación web

También se añadió a que cuando el modelo detecte que es un árbol, pero no tenga alta precisión de la especie, la respuesta sea, especie no registrada:

Fig.28. Prueba de identificación de árbol desconocido de la base de datos desde la aplicación web