

UNIVERSIDAD TÉCNICA DEL NORTE

Faculta de Ingeniería en Ciencias Aplicadas

Carrera de Software



**DESARROLLO DE UN APLICATIVO MÓVIL PARA EL RECONOCIMIENTO
DE CINCO ESPECIES MADERABLES MEDIANTE LA UTILIZACIÓN DE
UNA RED NEURONAL CONVOLUCIONAL**

Trabajo de grado previo a la obtención del título de Ingeniero de Software
presentado ante la Universidad Técnica del Norte.

AUTOR:

Edwin Paco Herrera Gómez

DIRECTOR:

PhD. Irving Marlon Reascos Paredes

Ibarra – Ecuador

2025



UNIVERSIDAD TÉCNICA DEL NORTE

BIBLIOTECA UNIVERSITARIA

AUTORIZACIÓN DE USO Y PUBLICACIÓN A FAVOR DE

LA UNIVERSIDAD TÉCNICA DEL NORTE

1. IDENTIFICACIÓN DE LA OBRA

En cumplimiento del Art. 144 de la Ley de Educación Superior, hago la entrega del presente trabajo a la Universidad Técnica del Norte para que sea publicado en el Repositorio Digital Institucional, para lo cual pongo a disposición la siguiente información:

DATOS DE CONTACTO			
CÉDULA DE IDENTIDAD	DE	171894172-5	
APELLIDOS Y NOMBRES	Y	EDWIN PACO HERRERA GÓMEZ	
DIRECCIÓN		QUITO – ATAHUALPA (HABASPAMBA)	
EMAIL		epherrerag@utn.edu.ec	
TELÉFONO FIJO:	022304-337	TELÉFONO MÓVIL:	0960815129

DATOS DE LA OBRA	
TÍTULO	DESARROLLO DE UN APLICATIVO MÓVIL PARA EL RECONOCIMIENTO DE CINCO ESPECIES MADERABLES MEDIANTE LA UTILIZACIÓN DE UNA RED NEURONAL CONVOLUCIONAL.
AUTOR(ES):	EDWIN PACO HERRERA GÓMEZ
FECHA:	06/02/2025
PROGRAMA	PREGRADO
TÍTULO POR EL QUE OPTA:	INGENIERO EN SOFTWARE
DIRECTOR:	PhD. IRVING MARLON REASCOS PAREDES
ASESOR 1:	MSc. HUGO ORLANDO PAREDES RODRÍGUEZ

2. CONSTANCIAS

El autor manifiesta que la obra objeto de la presente autorización es original y fue desarrollada sin violar derechos de autor de terceros. Por lo tanto, la obra es original y el autor es titular de los derechos patrimoniales, por lo que asume la responsabilidad sobre el contenido de la misma y saldrá en defensa de la Universidad en caso de reclamación por parte de terceros.

Ibarra, a los 6 días del mes de febrero de 2025

EL AUTOR:



ESTUDIANTE
Edwin Paco Herrera Gómez

CI: 1718941725

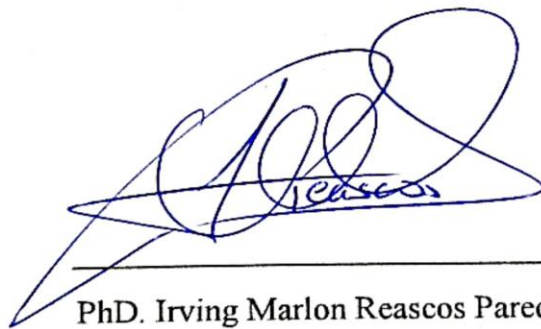
CERTIFICACIÓN DIRECTOR

Ibarra 6 de febrero del 2025

CERTIFICACIÓN DIRECTOR DEL TRABAJO DE TITULACIÓN

Por medio del presente yo PhD. Irving Marlon Reascos Paredes, certifico que el Sr. Herrera Gómez Edwin Paco portador de la cédula de ciudadanía número 171894172-5, ha trabajado en el desarrollo del proyecto de grado **“Desarrollo de un aplicativo móvil para el reconocimiento de cinco especies maderables mediante la utilización de una red neuronal convolucional”**, previo a la obtención del Título de Ingeniero en Software. Este trabajo se ha realizado con responsabilidad, lo cual certifico con honor a la verdad.

Atentamente



PhD. Irving Marlon Reascos Paredes
DIRECTOR DE TRABAJO DE GRADO

DEDICATORIA

Este trabajo de titulación está dedicado a las personas más importantes en mi vida, mi madre María Gómez, mi padre Washington Herrera, por su amor incondicional, su incansable apoyo y su fe en mis capacidades han sido mi mayor motivación. Gracias por los sacrificios que hicieron para brindarme oportunidades, por enseñarme el valor del esfuerzo y la perseverancia, y por estar siempre presentes en cada paso que he dado. Este logro es un reflejo de sus enseñanzas y sacrificios.

A Dios, por darme la fuerza, la sabiduría y las oportunidades necesarias para alcanzar este logro.

A mis hermanos, hermanas y sobrino, quienes siempre han sido mi ejemplo y mi refugio. Su cariño, apoyo que me ha acompañado en cada momento de este recorrido. Gracias por su confianza en mí y por ser un motor constante para seguir adelante. Cada uno de ustedes ocupa un lugar especial en este logro.

A mi familia en general, por su amor y su presencia, que han sido mi fortaleza en los momentos más difíciles.

A mis amigos, quienes, con su compañerismo, palabras de aliento y consejos fueron parte esencial de este recorrido académico. Su amistad es algo que valoro profundamente y que ha sido fundamental en este camino.

Y finalmente, a todos aquellos que de una u otra forma contribuyeron a este proyecto, en especial a mi tutor y asesor de tesis, por su guía, paciencia y enseñanzas. Su apoyo fue clave para convertir esta idea en una realidad.

EDWIN PACO HERRERA GÓMEZ

AGRADECIMIENTOS

En primer lugar, agradezco a Dios por salud y la fortaleza necesaria para superar los retos de este proceso académico y mis padres, quienes han sido mi mayor fuente de inspiración. Su amor incondicional, sacrificios y constante apoyo han sido la base para alcanzar este logro. Gracias por enseñarme a ser perseverante y a nunca rendirme ante las dificultades. Este triunfo también es suyo.

Agradezco a Joseline Portilla por aportar con su tiempo y dedicación para la toma de imágenes macroscópicas utilizadas en este trabajo de titulación.

A mi tutor PhD. Irving Reascos y asesor de tesis Msc. Hugo Paredes, por su paciencia, orientación y por compartir su conocimiento conmigo. Su guía fue fundamental para llevar este proyecto a buen término.

A mis profesores y compañeros de la carrera, quienes contribuyeron significativamente a mi formación académica y personal. Gracias por compartir su sabiduría, experiencias y apoyo durante esta etapa.

Finalmente, a todas aquellas personas que, de una u otra forma, estuvieron presentes en este camino, brindándome ánimo, confianza y ayuda. Cada uno de ustedes ha dejado una huella importante en mi vida, y por ello, les estaré eternamente agradecido.

EDWIN PACO HERRERA GÓMEZ

TABLA DE CONTENIDOS

DEDICATORIA	IV
AGRADECIMIENTOS.....	V
ÍNDICE DE FIGURAS	X
ÍNDICE DE TABLAS	XIII
RESUMEN	XIV
ABSTRACT.....	XV
INTRODUCCIÓN.....	XVI
Tema.....	XVI
Problema.....	XVI
Situación Actual.....	XVI
Prospectiva.....	XVII
Planteamiento del Problema	XVII
Objetivos	XIX
Objetivo General	XIX
Objetivos específicos.....	XIX
Alcance	XIX
Metodología.....	XX
Justificación.....	XXI
CAPÍTULO 1	23
1. Marco Teórico	23
1.1. Introducción a la IA y las Redes Neuronales Convolucionales (CNN).....	23
1.1.1. Redes neuronales convolucionales para reconocimiento visual.....	24
1.1.2. Aplicaciones de Redes Neuronales para el Reconocimiento de imágenes.....	25
1.1.3. Redes neuronales relevantes en el reconocimiento de maderas.....	26

1.2.	Aplicaciones de Reconocimiento de Especies Maderables	32
1.2.1.	Importancia del Reconocimiento de Especies Maderables	32
1.2.2.	Aplicaciones actuales y necesidades en el campo forestal.....	32
1.2.3.	Avances tecnológicos para la identificación maderable	33
1.2.4.	Beneficios y desafíos del reconocimiento de especies maderables	34
1.2.5.	Tipos de entrenamiento.....	35
1.2.6.	Preparación del dataset para el entrenamiento de una red neuronal	35
1.3.	Anotación de imágenes	36
1.3.1.	Importancia de la anotación de imágenes entrenamiento de modelos.....	37
1.3.2.	Tipos de anotación de imágenes.....	37
1.3.3.	Herramientas y plataformas de anotación de imágenes	41
1.4.	Herramientas y plataformas de desarrollo de aplicativos móviles	43
1.4.1.	Entorno de desarrollo integrado (IDE) para aplicativos móviles	44
1.4.2.	Lenguajes de programación y frameworks móviles Kotlin	44
1.4.3.	Herramienta de diseño UI/UX.....	46
1.5.	Modelo de éxito de sistemas de información de Delone y McLean.....	46
1.5.1.	Calidad del sistema	47
1.5.2.	Calidad de la información	48
1.5.3.	Calidad del servicio.....	48
1.5.4.	Intención de uso/uso	48
1.5.5.	Satisfacción del usuario.....	49
1.5.6.	Impactos netos.....	49
1.5.7.	Relevancia en el aplicativo de reconocimiento de madera	49
CAPÍTULO 2		50
2. Desarrollo		50
2.1.	Visión general	50

2.1.1.	Planificación	50
2.1.2.	Entregables.....	51
2.1.3.	Materiales y herramientas	52
2.2.	Especies maderables.....	53
2.3.	Proceso de anotación de imágenes	57
2.4.	Definición de la Red Neuronal Convolutiva	59
2.5.	Desarrollo y entrenamiento del modelo	60
2.6.	Matriz de confusión y métricas	69
2.7.1.	Matriz de confusión.....	70
2.7.2.	Métricas.....	72
2.8.	Prototipado.....	73
2.8.1.	Prototipo de pantalla de inicio.....	73
2.8.2.	Prototipo de pantalla de información.....	74
2.8.3.	Prototipo de pantalla de funcionamiento.....	75
2.9.	Desarrollo de la aplicación móvil	75
2.9.1.	Preparación de entorno de desarrollo.....	77
2.9.2.	Codificación de la aplicación móvil	79
2.10.	Instalación y generación de APK.....	83
2.10.1.	Instalación directa vía USB.....	83
2.10.2.	Generación de APK e instalación	83
2.11.	Funcionalidad de la aplicación instalada	85
2.11.1.	Pantalla de inicio instalada.....	85
2.11.2.	Pantalla de información instalada.....	85
2.11.3.	Pantalla funcionamiento e identificación de especies.....	86
2.11.4.	Herramientas para el uso de la aplicación	87
2.11.5.	Capturas con cámara del celular y lupa 10x.....	89

2.11.6.	Capturas con Microscopio USB y uso de la galería	90
2.12.	Precisión menor a 90%	92
CAPÍTULO 3		93
3.	Evaluación y validación de resultados.....	93
3.1.	Diseño del instrumento de medición	93
3.1.1.	Planificación	94
3.2.	Interpretación de resultados	96
3.2.1.	Análisis de datos.....	97
3.3.	Presentación de resultados	102
3.3.1.	Variables del modelo de éxito de S.I de Delone & McLean	102
3.3.2.	Calidad del sistema	103
3.3.3.	Calidad de la información	105
3.3.4.	Calidad del servicio.....	107
3.3.5.	Intensión de uso/uso	108
3.3.6.	Satisfacción del usuario.....	110
3.3.7.	Impactos Netos	111
3.4.	Análisis de favorabilidad y desfavorabilidad	113
CONCLUSIONES		116
RECOMENDACIONES		117
BIBLIOGRAFÍA.....		118
ANEXOS		125

ÍNDICE DE FIGURAS

Figura 1 Planteamiento del Problema (Causa/Efecto)	XVIII
Figura 2 Red Neuronal Convolutacional	25
Figura 3 Tipos de redes neuronales convolucionales.....	31
Figura 4 Detección de objetos.....	38
Figura 5 Detección de puntos de referencia	39
Figura 6 Segmentación.....	40
Figura 7 Clasificación de imagen.....	41
Figura 8 Plataformas para anotación de imágenes	43
Figura 9 Modelo DeLone y McLean 2016.....	47
Figura 10 Chonta Caspi.....	54
Figura 11 Sande o Lechoso	54
Figura 12 Cedro	55
Figura 13 Nogal	56
Figura 14 Chalviande	56
Figura 15 Tablero Kanban para anotación de imágenes	57
Figura 16 Anotación de imágenes en roboflow de la especie cedro	58
Figura 17 Clasificación por carpetas.....	58
Figura 18 Arquitectura EfficientNetB7.....	59
Figura 19 Arquitectura de Compound Scaling.....	60
Figura 20 Tablero Kanban para entrenamiento del modelo	61
Figura 21 Cuaderno de desarrollo Google colab.....	62
Figura 22 Ajustes de entorno de desarrollo Google Colab	62
Figura 23 Conexión de Google drive con el entorno de desarrollo.....	63
Figura 24 Librerías, Módulos y Biblioteca Efficientnet	63
Figura 25 Conversión de Imágenes a Formato JPG.....	64
Figura 26 Carga y División de Imágenes	65
Figura 27 Definición de Funciones Cargar, Procesar y Etiquetar Imágenes.....	66
Figura 28 Uso de EfficientNetB7.....	66
Figura 29 Preprocesamiento y Aumento de Datos.....	67
Figura 30 Visualización de un Lote de Imágenes de Entrenamiento	68

Figura 31 Entrenamiento del Modelo	68
Figura 32 Obtención del Archivo Tensorflow Lite del Modelo.....	69
Figura 33 Matriz de Confusión	70
Figura 34 Prototipo de Inicio	74
Figura 35 Prototipo de Pantalla de Información	74
Figura 36 Prototipo de Funcionamiento.....	75
Figura 37 Tablero Kanban Para el Desarrollo de la Aplicación.....	76
Figura 38 Arquitectura de la Aplicación Móvil	77
Figura 39 Abrir Proyecto en Android Studio	78
Figura 40 Carga de Archivo .tflite al Aplicativo.....	79
Figura 41 Pantalla de Inicio en Android Studio.....	80
Figura 42 Pantalla de Información en Android Studio	80
Figura 43 Pantalla de Funcionamiento en Android Studio	81
Figura 44 Codificación del Botón Cámara.....	82
Figura 45 Codificación del botón galería.....	82
Figura 46 Run App Para la Instalación	83
Figura 47 Generación de APK	84
Figura 48 APK Generado.....	84
Figura 49 Pantalla de Inicio de la App Funcionando	85
Figura 50 Pantalla de Información Funcionando	86
Figura 51 Pantalla de Información de Chonta Caspi.....	86
Figura 52 Pantalla de Identificación de Especies Maderables	87
Figura 53 Cuchilla para Corte	87
Figura 54 Lupa 10x.....	88
Figura 55 Microscopio USB	88
Figura 56 Captura de Imagen con Lupa 10x	89
Figura 57 Pantalla de Recorte de Imagen.....	89
Figura 58 Pantalla de Resultado.....	90
Figura 59 Captura de Imagen con Microscopio USB	91
Figura 60 Resultado con Imagen de Microscopio USB	91
Figura 61 Resultado de Confianza de Precisión Menor a 90%	92
Figura 62 Resultado de Dimensión Calidad del Sistema	104

Figura 63 Resultado de Dimensión Calidad de la Información	106
Figura 64 Resultado de Dimensión Calidad del Servicio	107
Figura 65 Resultado de Dimensión Intensión de Uso	109
Figura 66 Resultado de Dimensión Satisfacción del Usuario	110
Figura 67 Resultado de la Dimensión Impactos Netos	112
Figura 68 Diagrama de Favorabilidad y Desfavorabilidad	115

ÍNDICE DE TABLAS

Tabla 1 Planificación Para el Desarrollo.....	50
Tabla 2 Entregables del Proyecto.....	51
Tabla 3 Materiales y Herramientas Utilizadas en el Desarrollo.....	52
Tabla 4 Especies Maderables	53
Tabla 5 Análisis de Resultados	71
Tabla 6 Análisis de Resultados	94
Tabla 7 Entregables del Proyecto.....	98
Tabla 8 Resultados de la Encuesta por Usuario	99
Tabla 9 Interpretación de Resultado del Alfa de Cronbach.....	100
Tabla 10 Valores Estadísticos por Dimensión	101
Tabla 11 Análisis de Favorabilidad.....	113

RESUMEN

Este trabajo de tesis aborda el desarrollo de un aplicativo móvil para el reconocimiento de cinco especies maderables utilizando una red neuronal convolucional (CNN). La investigación se estructura en varios objetivos específicos que incluyen la revisión del estado del arte sobre técnicas de reconocimiento de especies y redes neuronales, el desarrollo e implementación del modelo de clasificación, y la evaluación del rendimiento del sistema.

En el primer capítulo, se realiza una exhaustiva revisión del estado del arte, identificando los avances en el uso de redes neuronales convolucionales en la clasificación de imágenes, así como las aplicaciones en el ámbito de la gestión forestal y el reconocimiento de especies maderables. Este análisis establece la base teórica para el diseño del modelo.

En el segundo capítulo, se presenta el desarrollo del aplicativo móvil, detallando la integración de la red neuronal, el proceso de entrenamiento utilizando un conjunto de datos de imágenes de las especies seleccionadas y la creación de una interfaz de usuario amigable, accesible tanto para investigadores como para profesionales del sector forestal. Además, este capítulo está dedicado al análisis de los resultados obtenidos a partir de la evaluación del modelo mediante una matriz de confusión, destacando una precisión superior al 90% y métricas clave como precisión, recall y F1 score. Los resultados validan la efectividad del sistema para clasificar correctamente las especies maderables, incluso en condiciones variables de las imágenes.

En el tercer capítulo, se presenta la evaluación del aplicativo móvil utilizando el modelo de éxito de sistemas de información de DeLone y McLean, que resalta la aceptación del sistema por parte de los usuarios y su impacto positivo en términos de calidad del sistema, la información y el servicio.

Finalmente, la investigación concluye con una propuesta para futuras mejoras, como la inclusión de más especies maderables y la actualización constante del sistema, además de los anexos del trabajo realizado

ABSTRACT

This thesis addresses the development of a mobile application for the recognition of five timber species using a convolutional neural network (CNN). The research is structured around several specific objectives, including a review of the state of the art on species recognition techniques and neural networks, the development and implementation of the classification model, and the evaluation of the system's performance.

In the first chapter, an exhaustive review of the state of the art is conducted, identifying advancements in the use of convolutional neural networks for image classification, as well as applications in forest management and timber species recognition. This analysis establishes the theoretical foundation for model design.

In the second chapter, the development of the mobile application is presented, detailing the integration of the neural network, the training process using a dataset of images of the selected species, and the creation of a user-friendly interface accessible to researchers and forestry professionals. Additionally, this chapter is dedicated to analyzing the results obtained from the model evaluation through a confusion matrix, highlighting an accuracy exceeding 90% and key metrics such as precision, recall, and F1 score. The results validate the effectiveness of the system in accurately classifying timber species, even under variable image conditions.

In the third chapter, the mobile application is evaluated using the DeLone and McLean success model, which emphasizes user acceptance of the system and its positive impact in terms of system quality, information quality, and service quality.

Finally, the research concludes with a proposal for future improvements, such as the inclusion of additional timber species and the constant updating of the system, along with the annexes of the work performed.

INTRODUCCIÓN

Tema

DESARROLLO DE UN APLICATIVO MÓVIL PARA EL RECONOCIMIENTO DE CINCO ESPECIES MADERABLES MEDIANTE LA UTILIZACIÓN DE UNA RED NEURONAL CONVOLUCIONAL.

Problema

Situación Actual

La identificación precisa de especies maderables sigue siendo un desafío crítico, especialmente en el contexto de la tala ilegal. A pesar de los avances tecnológicos, este proceso continúa siendo lento, costoso y dependiente de la experiencia de profesionales especializados. Esta dependencia limita la efectividad y objetividad del proceso de identificación, aumentando el riesgo de errores humanos, lo que facilita actividades ilegales y poco controladas, como la tala clandestina (Mantilla et al., 2021).

Según (Montero et al., 2020) la ausencia de herramientas tecnológicas accesibles y confiables para la identificación de especies maderables contribuye a problemáticas como:

1. Facilitación de la tala ilegal: Esto tiene un impacto directo en la degradación de los bosques, la pérdida de biodiversidad y el incumplimiento de normativas ambientales.
2. Impacto económico y productivo: La identificación incorrecta de la madera puede resultar en un mal uso de los recursos, afectando la calidad de los productos y generando pérdidas económicas para las industrias.
3. Subjetividad en la identificación: La formación limitada o la falta de experiencia de algunos profesionales provoca inconsistencias y errores en la clasificación de las especies.

Prospectiva

El desarrollo de un aplicativo móvil para el reconocimiento de especies maderables mediante redes neuronales convolucionales promete transformar la identificación de maderas, haciéndola más accesible, precisa y eficiente. Esto contribuirá a combatir la tala ilegal, proteger los bosques y mejorar la sostenibilidad en la industria maderera.

Además, con la mejora continua de los algoritmos y la expansión de bases de datos que incluyan características más detalladas de especies maderables, estas aplicaciones podrían ampliarse para reconocer un mayor número de especies, contribuir al monitoreo del estado de los bosques y generar información valiosa para la investigación científica.

En el futuro, estas tecnologías podrían ser ampliamente adoptadas, facilitando el control aduanero, optimizando el uso de maderas en la cadena productiva y democratizando el acceso a herramientas avanzadas para usuarios con diferentes niveles de experiencia.

Para maximizar su impacto, será crucial promover la colaboración entre instituciones académicas, gubernamentales y tecnológicas, garantizando así su implementación efectiva y sostenible. Este proyecto no solo aborda un problema actual, sino que también sienta las bases para un manejo más responsable de los recursos naturales.

Planteamiento del Problema

El proceso de identificación de especies maderables enfrenta múltiples limitaciones, a pesar de los avances tecnológicos. La falta de herramientas accesibles y efectivas facilita actividades como la tala ilegal, contribuyendo a la pérdida de biodiversidad y la degradación forestal.

A demás (Izko & Burneo, 2018) mencionan lo que genera la identificación inexacta de especies:

- Errores en el uso adecuado de las maderas, afectando la calidad de los productos.
- Pérdidas económicas en sectores productivos.

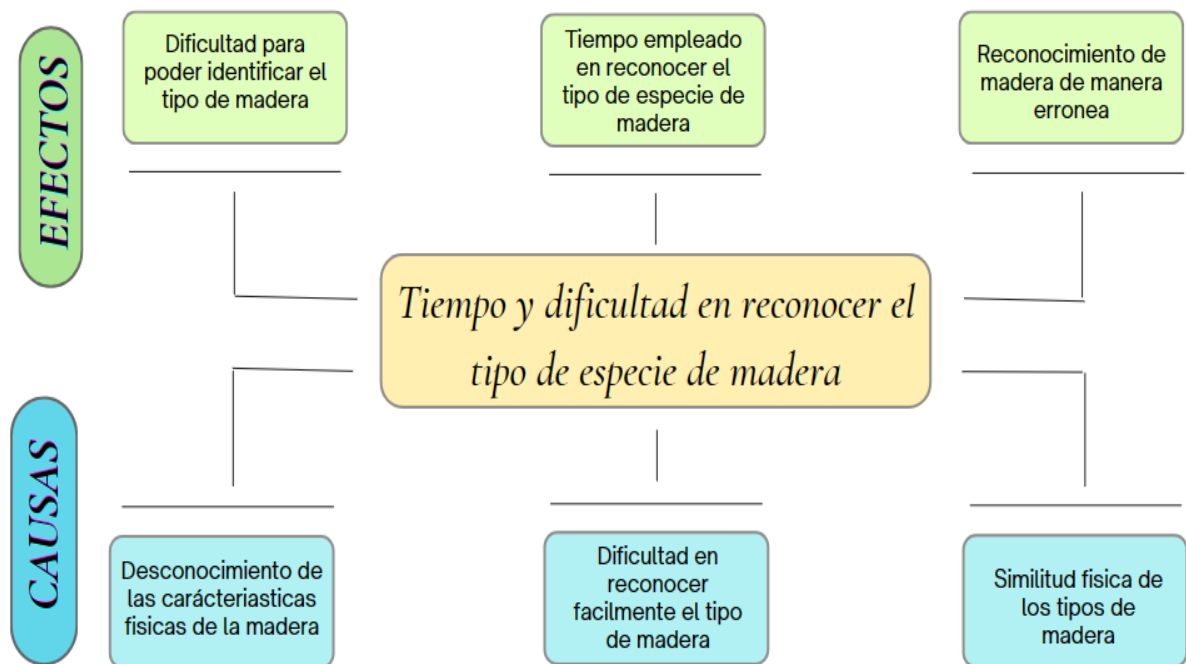
- Dependencia de la experiencia subjetiva de los profesionales, lo que disminuye la fiabilidad del proceso.

Para abordar esta problemática, se propone el diseño y desarrollo de un aplicativo móvil basado en redes neuronales convolucionales, que permita una identificación precisa, rápida y accesible de cinco especies maderables. Esto no solo solucionará los problemas actuales, sino que también proporcionará una herramienta sostenible para mejorar el manejo responsable de los recursos forestales y fomentar prácticas industriales más eficientes.

La Figura 1 muestra las principales causas y efectos de la problemática planteada.

Figura 1

Planteamiento del Problema (Causa/Efecto)



Nota: Elaboración Propia.

Objetivos

Objetivo General

Desarrollar una aplicación móvil para el reconocimiento de cinco especies maderables a partir de imágenes de muestra macroscópicas de madera.

Objetivos específicos

- Elaborar un estado del arte respecto al reconocimiento de especies maderables.
- Desarrollar un aplicativo móvil para la identificación de 5 especies maderables.
- Evaluar los resultados y verificar el funcionamiento de la aplicación móvil mediante el uso del Modelo de éxito de sistemas de información de Delone y McLean.

Alcance

El alcance de esta investigación se centra en el desarrollo de una aplicación móvil para dispositivos Android destinada a la identificación de cinco especies específicas de madera mediante técnicas de visión por computadora y aprendizaje automático. La aplicación se diseñará para reconocer visualmente las características macroscópicas de estas especies, utilizando un conjunto de datos de imágenes de referencia.

El algoritmo de aprendizaje profundo empleado será una red neuronal convolucional, programada en Python con las librerías TensorFlow y Keras. Este algoritmo será entrenado utilizando un repositorio de imágenes macroscópicas compuesto por al menos 2,000 imágenes (400 por especie), las cuales serán proporcionadas por una estudiante de la carrera de Ingeniería Forestal.

Las pruebas y evaluaciones se enfocarán en medir la precisión, eficiencia y practicidad de la aplicación en la identificación de madera. Para la validación de la aplicación, se empleará el modelo de éxito de sistemas de información de Delone y McLean, analizando factores como la calidad del sistema, la satisfacción del usuario y los impactos netos.

Además, se formularán recomendaciones para su implementación efectiva en la industria de la madera, sectores académicos y otros campos relacionados. La

investigación también contempla aspectos éticos y legales asociados con la identificación de madera, el manejo responsable de datos e imágenes, y las implicaciones del uso de tecnologías basadas en inteligencia artificial.

Este proyecto se limitará a las cinco especies seleccionadas y a la plataforma móvil Android, estableciendo las bases para posibles ampliaciones futuras. Su éxito contribuirá a la protección de los recursos forestales, mejorando la precisión y accesibilidad de herramientas tecnológicas aplicadas al sector forestal.

Metodología

Para el desarrollo de esta investigación se empleará un enfoque metodológico basado en etapas estructuradas, que permiten cumplir con los objetivos planteados:

Para cumplir el primer objetivo se realizará una búsqueda exhaustiva de información sobre el reconocimiento de especies maderables en fuentes académicas como artículos científicos, libros, trabajos de grado, y documentos técnicos disponibles en las bases bibliográficas ofrecidas por la Universidad Técnica del Norte. Esta revisión permitirá fundamentar teóricamente el proyecto y garantizar el rigor científico en las decisiones metodológicas.

Para cumplir el segundo objetivo se realizará algunas etapas para cumplirlo de manera satisfactoria

1. Se etiquetarán las imágenes del conjunto de datos, asegurando que cada una esté correctamente clasificada según las características de las cinco especies seleccionadas.

2. Con el uso de librerías especializadas como TensorFlow y Keras, se llevará a cabo el entrenamiento del modelo basado en una red neuronal convolucional (CNN), ajustando los parámetros para maximizar la precisión y minimizar el error.

3. La parte gráfica de la aplicación móvil será desarrollada utilizando el framework TensorFlow Lite (TFLite), combinado con lenguajes de programación como Java y Python para integrar el modelo entrenado a la interfaz del usuario.

4. Se aplicarán métricas de evaluación propias de la inteligencia artificial, como precisión, sensibilidad, especificidad y la matriz de confusión, para medir el desempeño del modelo y garantizar su fiabilidad.

Para cumplir el tercer objetivo se procederá a evaluar el impacto y la usabilidad de la aplicación, se empleará el modelo de éxito de Sistemas de Información de Delone y McLean. Este modelo permitirá medir aspectos clave como la calidad del sistema, la satisfacción del usuario, y el beneficio percibido por parte de los usuarios finales en términos de eficiencia y utilidad práctica.

Justificación

El presente trabajo busca contribuir activamente a la prevención de la deforestación y la extracción desordenada de madera que amenazan a especies maderables vulnerables (Mio & Mejia, 2022). Al emplear tecnología avanzada, este proyecto aborda problemas ambientales, económicos y sociales asociados con el manejo ineficiente de los recursos forestales, promoviendo una gestión más sostenible y responsable.

Justificación Tecnológica. - El desarrollo de un aplicativo móvil basado en una red neuronal convolucional para el reconocimiento automático de especies maderables representa una solución tecnológica innovadora y eficiente. Esta herramienta no solo facilita la identificación precisa de especies, sino que también optimiza procesos en la gestión forestal y contribuye a la sostenibilidad ambiental (Alpuente et al., 2014). Además, su accesibilidad en dispositivos móviles garantiza un impacto significativo en sectores clave como la industria maderera, la conservación de recursos y el control gubernamental.

Justificación Teórica. - La iniciativa se fundamenta en la urgente necesidad de preservar la biodiversidad forestal y combatir la tala ilegal, que son factores críticos en la degradación de los ecosistemas naturales. Este trabajo también busca promover prácticas sostenibles en la explotación de recursos forestales y contribuir a los esfuerzos globales para mitigar el cambio climático. La aplicación no solo representa un avance en la

investigación científica, sino que también se posiciona como una herramienta esencial para la conservación de los recursos forestales.

Justificación Ambiental. - Los bosques desempeñan un papel crucial en la regulación del clima, la protección del suelo y el mantenimiento de la biodiversidad. Esta aplicación apoya la conservación de los bosques al facilitar la identificación de especies vulnerables, lo que ayuda a prevenir la tala ilegal y la explotación insostenible. Su implementación puede contribuir significativamente a la mitigación del cambio climático y a la protección de los ecosistemas, alineándose con los Objetivos de Desarrollo Sostenible (ODS) relacionados con el medio ambiente.

Justificación Económica. - En el ámbito económico, la aplicación tiene el potencial de optimizar la eficiencia operativa en la industria maderera, reducir errores en la clasificación de madera, asegurar el cumplimiento de normativas ambientales y facilitar el acceso a mercados responsables. Además, al mejorar la precisión en la identificación de especies, se agrega valor a los productos madereros procesados, lo que beneficia tanto a las empresas como a los consumidores finales. Esta tecnología también puede generar ahorros en costos operativos y abrir nuevas oportunidades en mercados de comercio sostenible.

En conjunto, este trabajo no solo busca resolver un problema técnico, sino también aportar un impacto positivo en la gestión ambiental, la investigación científica y el desarrollo económico sostenible, fortaleciendo los esfuerzos globales para proteger nuestros recursos naturales.

CAPÍTULO 1

1. Marco Teórico

El objetivo de este capítulo es familiarizar al lector con términos técnicos y al mismo tiempo brindarle una comprensión profunda del tema principal: Desarrollo de un aplicativo móvil para el reconocimiento de cinco especies maderables mediante la utilización de una red neuronal convolucional. Se ha determinado que los principios pertinentes que ayudarán a este proyecto deben introducirse y explicarse en detalle para garantizar su validez. A lo largo del capítulo, se desarrollarán los siguientes temas:

- **Introducción a la IA y las Redes Neuronales Convolucionales (CNN):** Introducción a los principios generales de la IA y las CNN.
- **Aplicaciones de Reconocimiento de Especies Maderables:** Casos de aplicación específicos y beneficios.
- **Entrenamientos de modelos de redes neuronales convolucionales:** Tipos de entrenamiento y preparación de datos.
- **Anotación de imágenes:** Proceso de anotación de imágenes, tipos de anotación y herramientas.
- **Herramientas y plataformas de desarrollo de aplicativos móviles:** Librerías, Lenguajes y Herramientas de desarrollo.
- **Modelo de éxito de sistemas de información de Delone y McLean:** Conceptos y uso para evaluación de sistemas.

1.1. Introducción a la IA y las Redes Neuronales Convolucionales (CNN)

La Inteligencia Artificial (IA) se ha consolidado como una herramienta clave para abordar problemas complejos en múltiples disciplinas. Su aplicación abarca el reconocimiento de imágenes, la traducción automática y la detección de patrones. Dentro de este ámbito, las Redes Neuronales Convolucionales (CNN) sobresalen como una técnica especializada en el procesamiento de datos estructurados en cuadrículas, como es el caso de las imágenes.

1.1.1. Redes neuronales convolucionales para reconocimiento visual

Las Redes Neuronales Convolucionales representan un enfoque avanzado dentro de los algoritmos de aprendizaje profundo, diseñados específicamente para tareas de visión por computadora. Inspiradas en la organización del sistema visual humano, estas redes han sido fundamentales en el análisis y reconocimiento de patrones en imágenes. Gracias a su evolución, han logrado avances significativos en áreas como la identificación de objetos, la segmentación de imágenes y la categorización visual. Estas innovaciones han transformado la visión artificial, permitiendo el desarrollo de métodos más sofisticados para que las máquinas interpreten y comprendan contenido visual (Romero & Caicedo, 2022).

Arquitectura y Funcionamiento

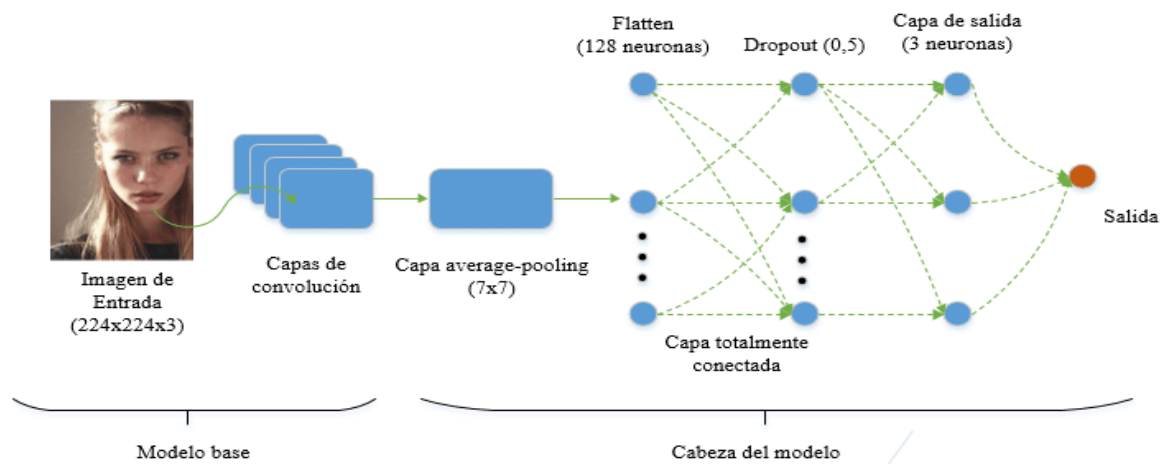
Según (Neena & Geetha, 2017) mencionan que las capas de una red neuronal convolucional son:

- **Capas convolucionales:** Detectan patrones locales en la imagen mediante filtros que se aplican en regiones específicas, extrayendo características como bordes, texturas o patrones complejos.
- **Capas de agrupamiento (pooling):** Minimizan la dimensionalidad de las representaciones obtenidas en las capas convolucionales, preservando los detalles más relevantes.
- **Capas completamente conectadas:** Procesan la información de las capas anteriores para realizar la clasificación final basándose en los detalles aprendidos.

En la figura 2 se observa la arquitectura de una red neuronal convolucional.

Figura 2

Red Neuronal Convolutonal



Nota: Se describe el funcionamiento de la arquitectura de una red neuronal convolutonal. Tomado de (Andrade et al., 2021).

1.1.2. Aplicaciones de Redes Neuronales para el Reconocimiento de imágenes

Las redes CNN han revolucionado la capacidad de las computadoras para comprender el contenido visual de las imágenes. Su versatilidad y precisión las han convertido en una herramienta fundamental, desempeñan un papel integral en diversas aplicaciones, destacando su capacidad en el reconocimiento de escenas, donde pueden comprender y clasificar el contexto general de una imagen, abarcando paisajes, entornos urbanos e interiores (Yuan et al., 2015). Esta habilidad resulta fundamental en sistemas de navegación y realidad aumentada. Además, en el ámbito del diagnóstico médico, las CNN ofrecen una potente herramienta para identificar patrones sutiles en imágenes médicas, permitiendo la detección temprana y precisa de condiciones como fracturas, cánceres y anomalías óseas mediante resonancias magnéticas y tomografías computarizadas (Bhavsar et al., 2021).

En el sector de la automatización industrial, las CNN son indispensables para la inspección de productos manufacturados al identificar con precisión defectos o anomalías en componentes individuales, garantizando así la calidad del producto final (Rafique & Velasco, 2018). Asimismo, en el ámbito de la conducción autónoma, estas redes posibilitan la identificación en tiempo real de diversos objetos, como señales de tráfico, peatones y

obstáculos, contribuyendo a tomar decisiones más seguras y precisas en vehículos autónomos al evaluar la información visual de múltiples sensores (Bhavsar et al., 2021).

En el campo agrícola y medioambiental, las CNN son esenciales para mejorar la producción y gestionar de manera efectiva el entorno. Analizando imágenes de campos, estas redes pueden detectar plagas, enfermedades y déficits en los cultivos, permitiendo intervenciones tempranas y precisas para minimizar daños y maximizar la salud de las cosechas. En conjunto, las aplicaciones de las CNN abarcan una amplia gama de sectores, demostrando su versatilidad y contribución significativa a través del análisis y procesamiento de imágenes (Liakos et al., 2018).

1.1.3. Redes neuronales relevantes en el reconocimiento de maderas

Las redes neuronales convolucionales (CNN) se pueden utilizar también en el campo del reconocimiento de especies maderables. Se han desarrollado arquitecturas especializadas para satisfacer las demandas y complejidades que abarcan este campo. Dentro de las arquitecturas relevantes para este fin, destacan las siguientes:

ResNet (Residual Networks)

Es una innovadora arquitectura de red neuronal que ha transformado las redes neuronales convolucionales profundas al introducir conexiones residuales. Esta característica única posibilita el entrenamiento de redes más profundas sin perder rendimiento, permitiendo la captura de representaciones generales y detalladas. Su impacto se extiende a diversas aplicaciones, desde el reconocimiento de objetos hasta la identificación precisa de especies de madera. Esta versatilidad facilita su integración en aplicativos móviles, especialmente en tareas de identificación en entornos naturales, donde su capacidad para aprender características sutiles y diferencias visuales destaca (Lu et al., 2020).

En el ámbito del reconocimiento de especies maderables, la aplicación de ResNet ha sido significativa. Su capacidad para manejar redes profundas y aprender representaciones detalladas ha mejorado la precisión en la identificación de especies, capturando características sutiles y permitiendo una adaptabilidad efectiva a conjuntos de datos diversos. Esta versatilidad

ha facilitado su implementación en aplicativos móviles, posibilitando el reconocimiento rápido y preciso de especies maderables en entornos naturales (Zhang et al., 2021).

ResNet se presenta en varias versiones, como ResNet-18, ResNet-34, ResNet-50 hasta ResNet-101 y ResNet-152, cada una nombrada según el número de capas que contiene. Cada versión utiliza bloques residuales para permitir redes más profundas y precisas en la identificación de imágenes. Además, variantes especializadas, como ResNeXt, emplean la técnica de bloque cardinal para mejorar la representación, satisfaciendo diversas necesidades en trabajos de visión por computadora al proporcionar distintos niveles de precisión y efectividad. En cuanto a los resultados significativos, ResNet ha marcado un hito en el aprendizaje profundo, especialmente en la identificación de imágenes (Sarwinda et al., 2021). Antes de su introducción, las redes neuronales más profundas a menudo experimentaban estancamiento o deterioro en su rendimiento debido a la dificultad para adquirir representaciones precisas con un aumento en el número de capas. ResNet superó este desafío al introducir conexiones residuales, permitiendo el entrenamiento de redes mucho más profundas y logrando mejoras sustanciales en la precisión en comparación con arquitecturas anteriores, especialmente en tareas que implican la detección y categorización de objetos (Li & He, 2018).

VGG (Visual Geometry Group)

Una red neuronal desarrollada por el equipo de Geometría Visual de la Universidad de Oxford, destaca por su estructura simple y enfoque profundo. Utilizando capas de agrupación y convolucionales de tamaño pequeño (3x3), esta red ha sido clave para entender aspectos complicados en imágenes, estableciendo un referente en identificación visual y clasificación de objetos (Dey et al., 2021). En el ámbito del reconocimiento de especies maderables, aunque no diseñada específicamente para este propósito, VGG ha demostrado eficacia en la captura y distinción de características visuales complejas en hojas, cortezas y estructuras de madera. Destaca su aplicabilidad en el reconocimiento y clasificación de especies de árboles en contextos naturales cuando se entrena con conjuntos de datos de especies maderables, gracias a su capacidad para diferenciar entre diversas especies en función de texturas, formas y detalles visuales.

Las variantes de VGG, como VGG16 y VGG19, difieren principalmente en la profundidad y número de capas. Estas versiones, compuestas principalmente por capas convolucionales y de agrupación, permiten adaptar la complejidad de la red según las necesidades de la tarea. Las iteraciones más recientes de VGG han ajustado su diseño fundamental, manteniendo eficiencia y simplicidad en la representación de datos visuales (Vedaldi & Zisserman, 2016). En términos de resultados significativos, la eficacia de VGG para extraer características visuales se ha evidenciado en pruebas de clasificación de objetos y reconocimiento visual. La arquitectura ha destacado en competiciones de reconocimiento visual, demostrando excelentes tasas de precisión y la capacidad para aprender características complejas en conjuntos de datos desafiantes (Guan et al., 2019).

Inception (GoogLeNet)

Una innovadora creación de Google en el diseño de redes neuronales convolucionales destaca por su enfoque único en la utilización de módulos Inception. Estos módulos consisten en capas convolucionales paralelas con diferentes tamaños, permitiendo la extracción simultánea de características a diversas escalas. Este enfoque singular facilita la captura eficiente de detalles minuciosos y contextos más amplios en imágenes, estableciendo un estándar de construcción de redes neuronales convolucionales precisa y eficiente (Si et al., 2022). En el ámbito del reconocimiento de especies maderables, Inception ha demostrado capacidad para identificar características contextuales y detalladas de imágenes de especies de árboles. Sus módulos de convolución paralelos de diferentes tamaños resultan útiles para detectar detalles minuciosos y estructuras visuales únicas en madera, corteza y hojas, a pesar de no haber sido originalmente diseñada con este propósito (Ahmed et al., 2023).

Inception se destaca como una técnica valiosa para aplicaciones de identificación y clasificación de especies en entornos naturales, al poder identificar patrones específicos de cada especie cuando se entrena con conjuntos de datos de especies de madera. Las variantes y versiones de Inception, como InceptionV2, InceptionV3 e InceptionV4, se han desarrollado para aumentar su precisión y eficiencia. Estas versiones refinan la arquitectura original, modifican la disposición y cantidad de módulos Inception, y aplican técnicas de regularización y optimización para mejorar la capacidad de aprendizaje y precisión en tareas de

reconocimiento visual. Además, han demostrado una mayor eficiencia computacional, reduciendo la complejidad y el gasto computacional sin comprometer la precisión, lo que las hace atractivas para aplicaciones del mundo real en el reconocimiento de patrones y objetos (Niso et al., 2022). En términos de resultados significativos, comparada con otras arquitecturas, ha mostrado su precisión y capacidad para capturar información a diversas escalas, consolidándose como una opción viable para aplicaciones que involucran clasificación de objetos e identificación visual (Jahandad et al., 2019).

EfficientNet

Una innovadora familia de diseños de redes neuronales convolucionales introducida por Google, se destaca por su enfoque en el rendimiento y la eficiencia computacional. Su arquitectura se basa en un mecanismo de escalado revolucionario que equilibra la profundidad, el ancho y la resolución de la red para maximizar el rendimiento con recursos computacionales limitados. En aplicaciones de visión por computadora ha superado a otros diseños conocidos, logrando altos niveles de precisión en la clasificación de imágenes en dataset de referencia. En el ámbito del reconocimiento de especies maderables (Atila et al., 2021), Además destaca por su eficiencia en el procesamiento de imágenes y su capacidad para capturar información a diversas escalas. Aunque no fue creado específicamente para este propósito, su énfasis en maximizar recursos computacionales lo hace apropiado para identificar patrones visuales únicos en imágenes de cortezas, hojas o estructuras de madera, EfficientNet ha demostrado la capacidad de distinguir entre especies basándose en rasgos visuales importantes al ser entrenado con conjuntos de datos de especies maderables, convirtiéndolo en una herramienta valiosa para y clasificación y la identificación de especies de árboles en entornos naturales. También consta de varias variantes, desde B0 hasta B7, cada una diferenciándose en tamaño y complejidad (Simonyan & Zisserman, 2015). Estas variaciones mantienen un equilibrio que maximiza el rendimiento en relación con la eficiencia informática, escalando uniformemente en tres dimensiones: ancho, profundidad y resolución de la red. Además, han surgido iteraciones mejoradas y modificadas, como EfficientNet-Lite y EfficientNet-EdgeTPU, diseñadas específicamente para funcionar en dispositivos con recursos limitados. En términos de resultados significativos, EfficientNet ha demostrado ser excepcionalmente preciso en tareas de visión por computadora, logrando un compromiso efectivo entre economía

computacional y precisión. Su escalado en ancho, profundidad y resolución proporciona ganancias notables en precisión sin sobrecargar excesivamente la computadora, convirtiéndolo en la elección preferida en aplicaciones de visión por computadora y reconocimiento visual (Liu et al., 2022).

MobileNet

Es un modelo de red neuronal convolucional diseñada específicamente para aplicaciones móviles y entornos computacionalmente de bajos recursos, destaca por su eficiencia y diseño liviano. Este modelo divide la convolución ordinaria en dos pasos, realizando una convolución en profundidad y otra puntual, utilizando operaciones de convolución separables para reducir los costos computacionales. Su enfoque eficiente minimiza el consumo de recursos mientras mantiene un rendimiento sólido en tareas de visión computacional como la identificación de objetos y la categorización de imágenes (Chakrabarti et al., 2019). MobileNet se ha demostrado especialmente útil en dispositivos móviles, facilitando implementaciones de aprendizaje automático de baja latencia y en tiempo real en contextos con recursos limitados.

En el ámbito del reconocimiento de especies maderables, MobileNet destaca por su efectividad y adaptabilidad en dispositivos de baja potencia, como dispositivos móviles. Aunque no fue creado específicamente para esta aplicación, su arquitectura optimizada y diseño liviano lo hacen apto para su uso en la identificación de especies maderables. MobileNet ha demostrado eficiencia en la clasificación de imágenes cuando se entrena con conjuntos de datos de especies de madera, convirtiéndolo en una opción potencial para aplicaciones de reconocimiento de especies en entornos naturales, donde la eficiencia computacional y la movilidad del sistema son fundamentales (Khasoggi et al., 2019).

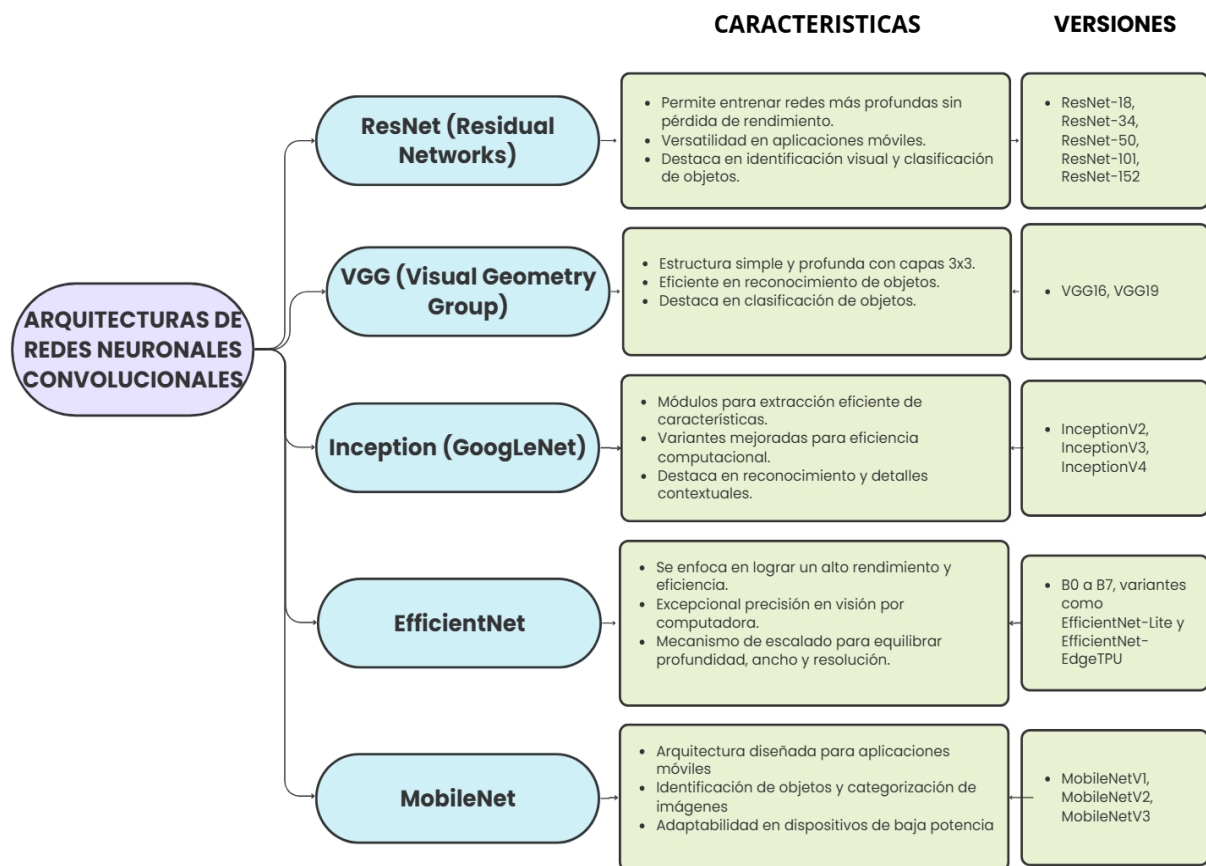
Existen varias variantes de MobileNet, como MobileNetV1, MobileNetV2 y MobileNetV3, cada una adaptada para diferentes requisitos y restricciones computacionales. La investigación de sus funciones ha resaltado su efectividad y rendimiento en tareas de visión por computadora, especialmente en dispositivos móviles con recursos limitados. Comparado con diseños más pesados (Rybczak & Kozakiewicz, 2023), A pesar de su estructura liviana se mantiene una precisión comparable en la clasificación de imágenes y detección de objetos.

La contribución de MobileNet se evidencia en su capacidad para simplificar la implementación de algoritmos de aprendizaje automático en dispositivos móviles, permitiendo una detección eficiente de objetos y clasificación de imágenes con baja latencia y uso eficiente de recursos. Estos hallazgos respaldan la aplicabilidad y el valor de la visión computacional, especialmente en entornos móviles y con recursos limitados (Kaya & Gürsoy, 2023).

Un breve resumen de las redes neuronales se puede ver en la figura 3.

Figura 3

Tipos de redes neuronales convolucionales



Nota: Elaboración propia.

1.2. Aplicaciones de Reconocimiento de Especies Maderables

La aplicación de tecnologías avanzadas, especialmente el reconocimiento de especies mediante redes neuronales convolucionales (CNN), trata de cómo la inteligencia artificial ha revolucionado la identificación precisa de especies maderables, crucial para la silvicultura, la preservación y administración sostenible de los recursos forestales. Abordando desafíos en la preservación de ecosistemas y la prevención de la tala ilegal, el marco teórico destaca cómo estas herramientas permiten una identificación eficiente y automatizada a partir de imágenes macroscópicas de madera (Khalid et al., 2008).

1.2.1. Importancia del Reconocimiento de Especies Maderables

Es fundamental identificar las especies de madera para preservar el medio ambiente y gestionar de manera sostenible los recursos forestales. Este método posibilita la valoración de la diversidad y la salud de los bosques, lo que simplifica la puesta en marcha de planes de administración forestal sustentable. Además, como cada tipo de árbol tiene un efecto diferente en la ecología, ayuda a conservar la biodiversidad (Muellner et al., 2011). Desde una perspectiva económica, la identificación de especies es fundamental para combatir la tala ilícita y promover un sector forestal sostenible. También dirige la investigación científica, ofreciendo información vital para una comprensión más profunda de los ecosistemas forestales. Además, las ventajas tecnológicas, como el seguimiento remoto y la gestión eficaz de los recursos forestales, se obtienen gracias a la identificación automática de especies maderables mediante el uso de tecnologías como el reconocimiento de patrones y las redes neuronales convolucionales. Por lo tanto, el reconocimiento de especies maderables es esencial para el manejo ético de los bosques y también contribuye a la preservación de la biodiversidad y al crecimiento a largo plazo del sector forestal (Machado et al., 2019).

1.2.2. Aplicaciones actuales y necesidades en el campo forestal

El uso sustentable de los recursos naturales en el área forestal tiene una variedad de aplicaciones y propósitos. Planificar y supervisar las operaciones forestales ahora es más sencillo gracias a tecnologías como la vigilancia satelital y los sistemas de información geográfica (SIG), que se utilizan para evaluar el tamaño y la salud de los bosques. Cada vez es

más necesaria una tecnología más avanzada, incluida la inteligencia artificial empleada en la identificación de especies maderables, para mejorar la precisión y eficiencia de la identificación de especies concretas (Fassnacht et al., 2023). Al potenciar la batalla contra la tala ilícita y mejorar la gestión forestal, esta aplicación podría garantizar la sostenibilidad y la preservación de los bosques. Además, las crecientes demandas de la industria forestal se pueden satisfacer mediante la implementación de procesos automatizados y sistemas de información. lo que mejorará la toma de decisiones y garantizará una utilización más ética de los recursos. Para abordar estos requisitos, se podrían crear aplicaciones móviles con funciones avanzadas de detección de especies de madera, brindando a los especialistas forestales una herramienta práctica y conveniente (Wang et al., 2021).

1.2.3. Avances tecnológicos para la identificación maderable

Los avances tecnológicos y el uso de métodos de visión computacional a través de la computadora han tenido un impacto significativo en la evolución de la identificación de especies maderables en la región forestal. En los últimos años se ha visto un cambio significativo en esta metodología debido al desarrollo de algoritmos significativos, la disponibilidad de diversos conjuntos de datos y una mayor potencia de procesamiento (Figueroa et al., 2018). Las redes neuronales convolucionales (CNN) y las arquitecturas de aprendizaje profundo son dos ejemplos de modelos basados en inteligencia artificial que han sido posibles gracias al uso generalizado de la visión por computadora. Al examinar características visuales complejas de sus fotografías, estos algoritmos pueden identificar de forma rápida y precisa los tipos de madera en sus fotografías. (Booth et al., 2017).

La creación de aplicaciones móviles especializadas es un ejemplo de cómo se utilizan estos avances en la práctica. Estas herramientas basadas en algoritmos de visión por computadora permiten al personal forestal identificar rápidamente diferentes tipos de madera mientras están en el campo. Este cambio revolucionario en la clasificación de las especies maderables beneficia objetivos más amplios como la conservación de la biodiversidad y el

avance de métodos sostenibles para la recolección de recursos forestales, además de aumentar la eficacia de la gestión forestal (Kumar et al., 2022).

1.2.4. Beneficios y desafíos del reconocimiento de especies maderables

Existen muchas ventajas y dificultades asociadas con la identificación automática de diferentes tipos de madera mediante tecnologías de visión por computadora y aprendizaje automático, que tienen una relación directa con la gestión forestal. El beneficio más destacable es el notable aumento de la eficiencia operativa, que permite identificar especies de forma rápida y precisa ahorrando tiempo y dinero. Una gestión forestal más informada y sostenible se ve facilitada por resultados consistentes y la capacidad de monitorear continuamente la salud y distribución de las especies. Sin embargo, la variedad de rasgos visuales de las especies, los factores ambientales cambiantes que pueden alterar la calidad de la imagen afectando el requisito crucial de conjuntos de datos representativos para un entrenamiento eficiente del modelo son obstáculos (Dassot et al., 2021).

Para utilizar plenamente las nuevas tecnologías, los métodos forestales actuales deben integrarse eficazmente con ellas. Como resultado, una evaluación justa de estas ventajas y desventajas ofrece importantes conocimientos para la implementación exitosa y moral de especies maderables automatizadas en el manejo forestal, así como una comprensión más profunda de la posible función de esta tecnología (Schmitt et al., 2023).

El entrenamiento de un modelo de CNN es un proceso esencial para que el sistema pueda realizar predicciones precisas. Este proceso consiste en ajustar los pesos de la red neuronal para reducir el error entre las predicciones y los valores reales.

1.2.5. Tipos de entrenamiento

Según (Lecun et al., 2015) el entrenamiento de modelos puede clasificarse en diferentes tipos según la disponibilidad de datos y la tarea específica:

1. **Entrenamiento supervisado:** En este tipo de entrenamiento, el modelo aprende a partir de un set de datos etiquetados, donde cada entrada está asociada con una salida esperada. En el caso de las especies maderables, cada imagen de madera estaría etiquetada con el nombre de la especie correspondiente.
2. **Entrenamiento no supervisado:** Este método se utiliza cuando los datos no tienen etiquetas. El modelo intenta identificar patrones o agrupaciones en los datos. Aunque menos común en el reconocimiento de especies maderables, podría ser útil para categorizar nuevas especies.
3. **Aprendizaje semi-supervisado:** Relaciona datos etiquetados y no etiquetados para mejorar el entrenamiento. Es particularmente útil cuando el etiquetado de datos es costoso o difícil de realizar.
4. **Aprendizaje por transferencia:** El aprendizaje por transferencia consiste en utilizar un modelo preentrenado en una tarea similar y ajustarlo a una tarea específica. Esto permite disminuir el tiempo de entrenamiento y mejorar el rendimiento, especialmente cuando el conjunto de datos es limitado.

1.2.6. Preparación del dataset para el entrenamiento de una red neuronal

Según (Kaya & Gürsoy, 2023) mencionan los pasos a realizar en la preparación de datos las cuales son las siguientes:

- **Adquisición de Datos:** Detalla el proceso de recolección de imágenes de las especies maderables, incluyendo fuentes, métodos de adquisición y aspectos a considerar en la calidad de las imágenes.
- **Etiquetado y Anotación:** Describe cómo se lleva a cabo la etiquetación de las imágenes, identificando cada especie maderable en el conjunto de datos. Discute las técnicas de anotación utilizadas y su importancia para el entrenamiento de la CNN.

- **Preprocesamiento de Imágenes:** Detalla las técnicas de preprocesamiento aplicadas a las imágenes, como la normalización, redimensionamiento, eliminación de ruido o ajuste de iluminación, para mejorar la calidad y homogeneidad del conjunto de datos.
- **División del Conjunto de Datos:** Describe la división del conjunto de datos en grupos de prueba, validación y entrenamiento para que el rendimiento del modelo pueda evaluarse con precisión.
- **Aumento de Datos (Data Augmentation):** Garantiza la mejora de la generalización del modelo, describe las estrategias de aumento de datos (como rotación, reescalado y recorte aleatorio) que se utilizaron para aumentar la diversidad y la cantidad de muestras.
- **Balanceo de Clases (Class Balancing):** Si es necesario, comenta sobre estrategias para abordar desequilibrios en el número de muestras entre las diferentes especies maderables, asegurando que el modelo no esté sesgado hacia una clase particular.
- **Verificación y Validación de Datos:** Detalla los procedimientos utilizados para verificar la precisión y coherencia de las etiquetas, así como para validar la calidad general del conjunto de datos preparado.

1.3. Anotación de imágenes

El etiquetado de imágenes es una parte clave del procesamiento de datos, implica la labor humana de asignar metadatos y atributos a las imágenes para mejorar la capacidad de las máquinas de reconocer objetos. Por ejemplo, en el campo del aprendizaje automático, los especialistas dedican tiempo a detallar imágenes de árboles, diferenciando entre una palmera y otras variedades. Esta labor no se limita a señalar lo que es una palmera, sino también a enseñar a las máquinas a reconocer qué no es una palmera, como cualquier otro árbol, completando así su comprensión (Ojha et al., 2017).

A pesar de los avances, el proceso no es definitivo. Aunque las máquinas puedan identificar palmeras con precisión, solo al mostrarles un sauce u otro árbol se evidencia que aún necesitan más instrucción. Por lo tanto, los expertos deben continuar etiquetando imágenes para ampliar el repertorio de lo que las máquinas reconocen como no palmeras. Este

entrenamiento continuo, que se extiende durante años, permite a las máquinas aprender a detectar y distinguir objetos según su contexto, propósito y los datos a los que han sido expuestas (Zhang et al., 2022).

1.3.1. Importancia de la anotación de imágenes entrenamiento de modelos

Un elemento principal para el desarrollo de los sistemas de visión por computadora es la recolección y el uso de imágenes anotadas que abarcan nuestro mundo visual. La anotación de imágenes puede considerarse como un problema de asignación de un conjunto de etiquetas relevantes a una imagen de acuerdo con el contenido donde se contengan múltiples características como bordes, contorno de objetos, forma y textura, en el aprendizaje de buenas características es muy importante y mejorará de forma significativa el sistema. También hace que las máquinas obtengan más detalles sobre los tipos de objetos que hay en el conjunto de datos y así ayuda a los modelos a diferenciar con precisión un objeto de otro ya sean especies de animales, plantas o tipos de madera (Sun et al., 2015).

1.3.2. Tipos de anotación de imágenes

Detección de objetos

La finalidad de la detección de objetos, como su nombre indica, consiste en asistir a las computadoras y a los modelos de inteligencia artificial en la identificación de varios objetos presentes en imágenes.

Según (Saavedra et al., 2020) para definir con precisión qué objetos específicos se encuentran en una imagen, los profesionales especializados en la anotación de datos aplican tres técnicas destacadas.


- **Cuadros delimitadores 2D:** En este proceso, se trazan y etiquetan recuadros rectangulares alrededor de distintos objetos presentes en las imágenes.
- **Cuadros delimitadores 3D:** se crean cajas tridimensionales que envuelven los objetos para destacar tanto su presencia como su profundidad dentro de la escena capturada en las imágenes.

- **Polígonos:** En lugar de cajas rectangulares, se utilizan polígonos para definir la forma precisa de los objetos en una imagen.

La forma de detección de objetos se puede ver a continuación en la figura 4.

Figura 4

Detección de objetos



Nota: La detección de objetos asiste a los modelos de inteligencia artificial en la identificación de varios objetos presentes en imágenes. Tomado de (Irigaray, 2021).

Detección de puntos de referencia

Los puntos de referencia en la anotación de datos no son simplemente ubicaciones destacadas o relevantes, sino áreas específicas o características esenciales dentro de una imagen que requieren ser identificadas. Estos puntos representan ubicaciones importantes o elementos distintivos de la imagen, como esquinas, bordes, puntos focales o estructuras significativas. La identificación de puntos de referencia se centra en descubrir e identificar puntos clave que pueden ser esenciales para comprender la estructura, forma o características distintivas de un objeto o escena en una imagen, en lugar de delinear cosas completas (Wu & Ji, 2019).

La forma en cómo actúan los puntos de referencia como se observa en la figura 5.

Figura 5

Detección de puntos de referencia



Nota: La detección de puntos de referencia identifica áreas específicas o características esenciales dentro de una imagen que requieren ser identificadas. Tomado de (Fuentes & Zacarías, 2023)

Segmentación

Es un procedimiento detallado que divide una imagen en múltiples secciones para identificar distintos elementos dentro de ellas. Esto implica reconocer límites, ubicar objetos y otras acciones similares. La meta es atribuir una categoría o clase determinada a cada píxel de la imagen, de manera que puedan distinguirse y reconocerse diferentes objetos o áreas o regiones. Para ilustrarlo de manera más clara (Durkee et al., 2021) detallan las siguientes técnicas de segmentación:

- **Segmentación semántica:** En este método, cada punto individual de una imagen se etiqueta con información específica y detallada. Esta técnica es fundamental para los modelos que necesitan comprender el entorno y contexto de la imagen.
- **Segmentación de instancias:** En este enfoque, se etiquetan minuciosamente todas y cada una de las apariciones de un elemento específico en una imagen, lo que proporciona una información detallada y específica de cada instancia del objeto.

- **Segmentación panóptica:** En este método se incorporan y etiquetan minuciosamente los detalles tanto de la segmentación semántica como de las instancias individuales en las imágenes.

La segmentación en una imagen se observa en la Figura 6

Figura 6

Segmentación



Nota: La segmentación tiene como objetivo es asignar una clase o categoría específica a cada píxel de la imagen para que puedan identificarse y diferenciarse distintos objetos o regiones. Tomado de (Gajewski, 2023).

Clasificación de imagen

La clasificación de imágenes consiste en reconocer y agrupar los elementos presentes en un objeto en categorías específicas. Este enfoque hace que la clasificación considere la imagen en su totalidad y se le asigne a una categoría. Esta técnica difiere notablemente de la detección de objetos, donde se identifican los objetos. Por ejemplo, una imagen que muestra un gato podría ser etiquetada simplemente como un "animal". La imagen se categoriza específicamente como un gato. En el caso de imágenes con múltiples animales, cada uno se detecta y clasifica individualmente según corresponda (Izko & Burneo, 2018), esto se puede observar en la figura 7.

Figura 7

Clasificación de imagen



Nota: La clasificación de imágenes se enfoca en que la clasificación considere la imagen en su totalidad y se le asigne a una categoría. Tomado de (Romo, 2021).

1.3.3. Herramientas y plataformas de anotación de imágenes

Labelbox

Ofrece herramientas de etiquetado para datos de entrenamiento, permitiendo la colaboración entre equipos para etiquetar imágenes de manera eficiente y precisa. Facilita la gestión de proyectos, la asignación de tareas y la integración con herramientas de aprendizaje automático, siendo fundamental para entrenar modelos de inteligencia artificial con conjuntos de datos etiquetados de alta calidad (Aljabri et al., 2022).

Supervisely

Es una plataforma para anotar datos con énfasis en el aprendizaje automático que ofrece herramientas que permiten la generación de conjuntos de datos con etiquetas, incluyendo capacidades de etiquetado semiautomático y la posibilidad de colaboración entre usuarios en este proceso, además nos puede proporcionar integraciones con plataformas de aprendizaje automático, lo que simplifica el flujo de trabajo desde la anotación hasta el despliegue del modelo entrenado (Voeikov et al., 2020).

CVAT (Computer Vision Annotation Tool)

Es una plataforma de código abierto que etiqueta datos de imágenes y videos para aplicaciones en visión por computadora y aprendizaje automático. Los usuarios pueden trabajar juntos para anotar conjuntos de datos utilizando una variedad de herramientas de etiquetado, incluidas etiquetas temporales para videos, polígonos, cuadros delimitadores y segmentación semántica. Es de código abierto y compatible con varios formatos de anotación, lo que le permite personalizar la plataforma para satisfacer sus necesidades específicas (Hansen et al., 2021).

Scale AI

Una plataforma de anotación de imágenes que se centra en proporcionar conjuntos de datos de alta calidad para aplicaciones de visión por computadora y aprendizaje automático. Proporciona amplios servicios de etiquetado de datos para aplicaciones de inteligencia artificial, incluido el procesamiento de datos de texto mediante visión por computadora. Se destaca por su énfasis en la precisión y el calibre de las anotaciones, empleando revisión humana y métodos de control de calidad para garantizar la exactitud de los conjuntos de datos (Sjödín et al., 2021).

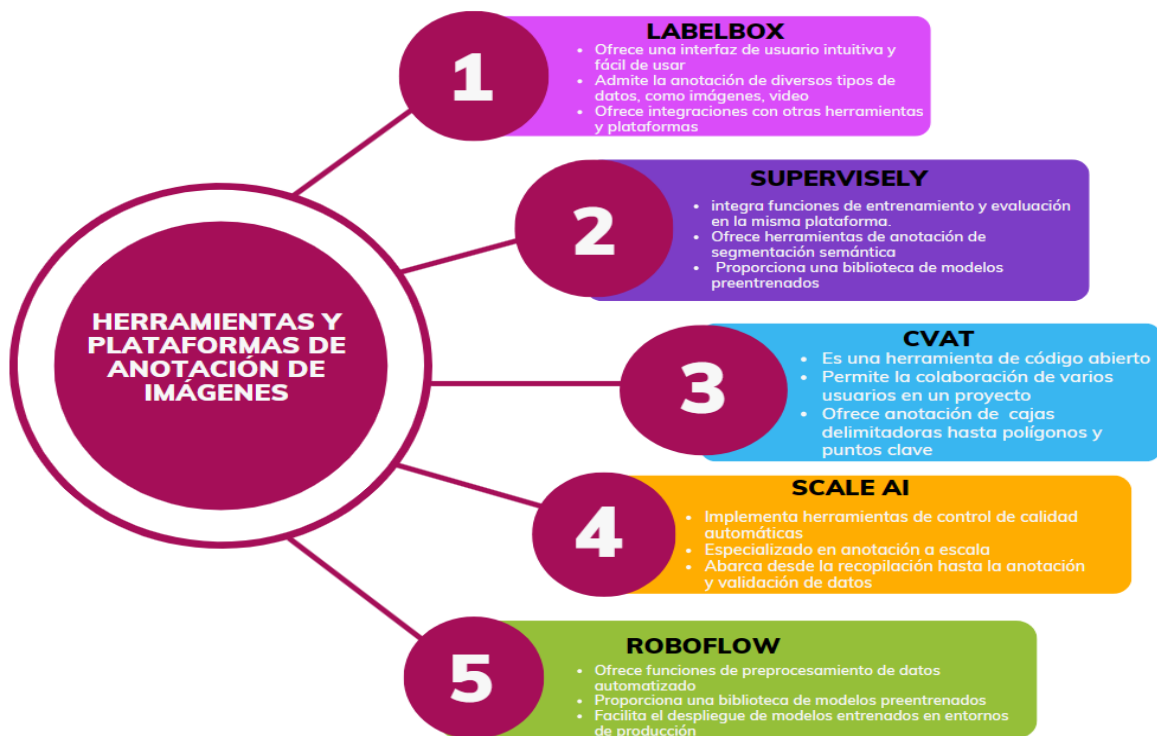
Roboflow

Es una plataforma que facilita la preparación de datos de proyectos de visión por computadora y aprendizaje automático. El entrenamiento de modelos se simplifica gracias a la facilidad con la que se pueden organizar, anotar y optimizar grupos de datos de imágenes. Para acelerar el aprendizaje del modelo, proporciona herramientas para refinar y transformar conjuntos de datos, así como integraciones con varios marcos de aprendizaje automático (Sonya et al., 2015).

Un resumen de estas herramientas se puede observar en la figura 8.

Figura 8

Plataformas para anotación de imágenes



Nota: Elaboración Propia.

1.4. Herramientas y plataformas de desarrollo de aplicativos móviles

El desarrollo de aplicativos móviles se ha vuelto esencial en la era digital, y contar con las herramientas y plataformas adecuadas es crucial para garantizar el éxito de estos proyectos. Diversas opciones se encuentran disponibles, abarcando desde entornos de desarrollo nativos hasta frameworks multiplataforma. Herramientas populares como Android Studio para aplicaciones Android y Xcode para iOS proporcionan entornos integrados robustos y específicos para cada plataforma, permitiendo a los desarrolladores aprovechar al máximo las características exclusivas de cada sistema operativo. Asimismo, frameworks como Flutter y React Native ofrecen soluciones multiplataforma, permitiendo el desarrollo de aplicativos que funcionen tanto en Android como en iOS con un solo código base, también el framework Tensorflowlite para el desarrollo móvil utilizando aprendizaje automático. La elección entre estas herramientas depende de factores como la naturaleza del proyecto, los recursos disponibles en este caso el reconocimiento de especies maderables. En conjunto, estas

herramientas y plataformas facilitan la creación de aplicativos móviles eficientes, atractivos y funcionales para satisfacer las crecientes demandas de la audiencia móvil (Dalmasso et al., 2022).

1.4.1. Entorno de desarrollo integrado (IDE) para aplicativos móviles

Android Studio

El principal entorno de desarrollo para la creación de aplicaciones móviles en Android es Android Studio, una herramienta diseñada por Google. Este IDE proporciona un conjunto de funcionalidades avanzadas, como un editor gráfico intuitivo, un emulador para probar aplicaciones en distintos dispositivos Android, herramientas de depuración y compatibilidad total con el lenguaje Kotlin. Además, permite una integración fluida con los servicios de Google, facilita la gestión de dependencias mediante Gradle y ofrece actualizaciones constantes que garantizan su compatibilidad con las últimas versiones del sistema operativo. Gracias a su interfaz amigable y su amplio conjunto de características, Android Studio se ha consolidado como una herramienta esencial para los desarrolladores, abarcando todo el proceso de desarrollo, desde el diseño hasta la implementación. (Hagos, 2018).

1.4.2. Lenguajes de programación y frameworks móviles Kotlin

En el desarrollo de aplicaciones para Android, Kotlin ha ganado protagonismo como uno de los lenguajes más utilizados. Su compatibilidad con Java, su tipado seguro y su sintaxis concisa han contribuido a su adopción por parte de la comunidad de desarrolladores. Al estar respaldado por Google, Kotlin se ha convertido en una opción preferida para la creación de aplicaciones modernas, ofreciendo características de programación funcional y soporte multiplataforma a través de Kotlin Multiplatform (KMP). Estas capacidades mejoran la flexibilidad del lenguaje, haciendo que Kotlin sea una alternativa confiable para desarrollar aplicaciones móviles con altos estándares de seguridad y eficiencia.

Por último, pero no menos importante, la creciente popularidad de Kotlin dentro de la comunidad de desarrolladores de Android se evidencia en sus funciones actualizadas y en la mejora general del entorno de desarrollo por lo cual se ha convertido en una opción confiable y adaptable para la creación de aplicaciones móviles, particularmente por sus características,

diseño actual y capacidad para elevar la productividad del desarrollo de aplicaciones (Acero & Linares, 2020).

Java

Particularmente para Android, Java ha sido una base crucial en la creación de aplicaciones móviles. Java es el lenguaje de programación más conocido para desarrollar aplicaciones de Android y es conocido por su portabilidad, orientación a objetos y seguridad. También cuenta con el apoyo de una comunidad considerable y una gran cantidad de recursos. Sigue siendo una buena opción a pesar de que tiene problemas con la longitud del código y con la atención a algunas características contemporáneas, particularmente para aplicaciones empresariales que necesitan integrarse con los sistemas actuales. Aunque Kotlin se está volviendo cada vez más popular, Java todavía se considera un lenguaje confiable y bien establecido para el desarrollo móvil (Jambe & Yogyakarta, 2020).

Python

Python juega un papel fundamental en el entrenamiento de modelos de aprendizaje profundo, como las redes neuronales convolucionales (CNN), para la clasificación de distintos tipos de madera en aplicaciones móviles su amplio ecosistema de herramientas, incluyendo bibliotecas como PyTorch y TensorFlow, facilita este proceso. Gracias a su sintaxis clara, Python simplifica el desarrollo y la comprensión del código, mientras que sus bibliotecas especializadas en ciencia de datos optimizan el manejo y procesamiento de la información para mejorar el entrenamiento de modelos. Además, proporciona herramientas de visualización y una comunidad activa que favorece la integración de modelos de inteligencia artificial en aplicaciones móviles, ofreciendo una solución eficiente y adaptable a este tipo de requerimientos. (Raschka et al., 2020).

TensorflowLite

El desarrollo móvil para microprocesadores se beneficia de soluciones que permiten la integración eficiente con modelos de aprendizaje automático en entornos con recursos limitados. TensorFlow Lite, derivado de TensorFlow, facilita la conversión de modelos originales para proporcionar inferencias en tiempo real sin necesitar de conexión a Internet. Esta tecnología prioriza la latencia y la privacidad en aplicaciones de inteligencia artificial.

Además, TensorFlow Lite es compatible con Unidades de Procesamiento de Tensor (TPU) y ofrece librerías especializadas para el desarrollo en Android e iOS, lo que lo convierte en una opción versátil para la implementación de diversas arquitecturas de aprendizaje automático, incluyendo Redes Neuronales Convolucionales (CNN), en una amplia gama de plataformas y dispositivos (Fadlilah et al., 2021).

1.4.3. Herramienta de diseño UI/UX

Figma

Debido a que ofrece un entorno de diseño para la creación de prototipos interactivos y la colaboración en tiempo real. Los equipos de diseño utilizan Figma para crear interfaces útiles y visualmente atractivas; con prototipos interactivos, también agiliza las evaluaciones y las opiniones de los usuarios. Su capacidad de colaboración remota mejora la productividad al permitir que equipos dispersos trabajen simultáneamente y el desarrollo de bibliotecas de diseño garantiza la coherencia visual. Además, Figma promueve la revisión y la retroalimentación del diseño, integra herramientas de desarrollo para una transición fluida y ofrece un control de versiones sólido, consolidándose como una herramienta esencial que optimiza el desarrollo de diseño y el desarrollo de aplicaciones móviles se optimiza en su totalidad. (Putra et al., 2021).

1.5. Modelo de éxito de sistemas de información de DeLone y McLean

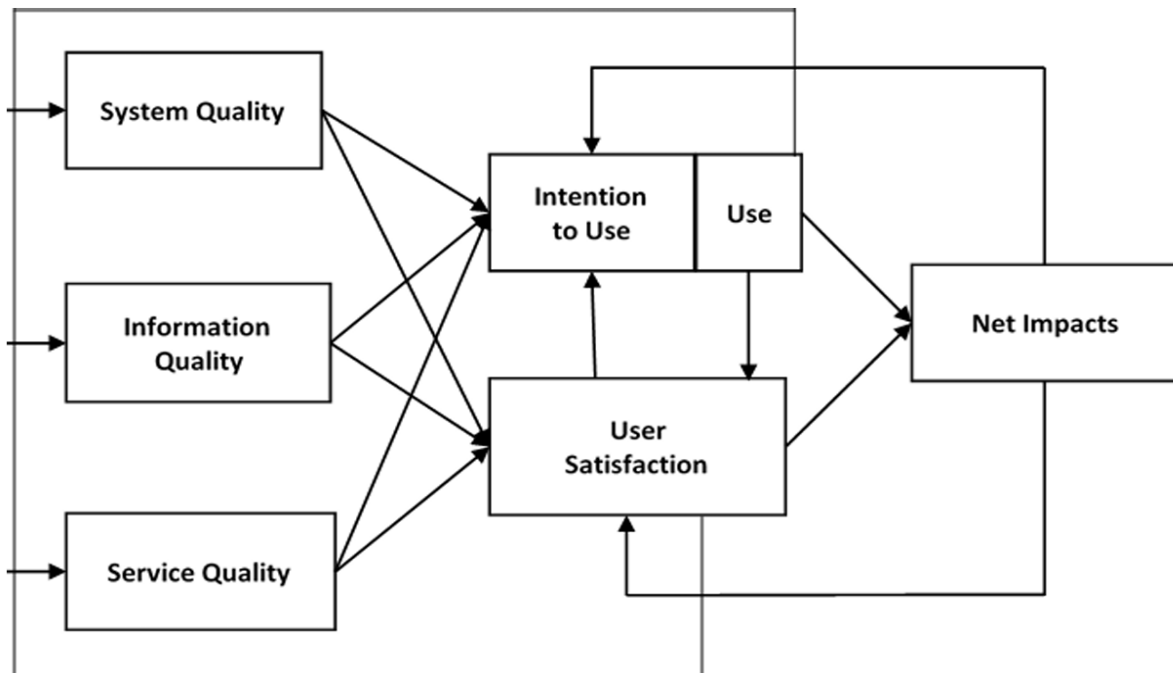
El modelo desarrollado por W. H. DeLone y E. R. McLean, se ha convertido en un marco conceptual fundamental para analizar la utilidad y relevancia de estos sistemas dentro de entornos corporativos y organizacionales. Dentro de este modelo, factores como la calidad del sistema, la calidad de la información, la satisfacción del usuario, el nivel de impacto individual y el efecto organizacional son pilares esenciales que sustentan su metodología. Según (Ramírez, 2019), la interacción entre estas características influye directamente en la funcionalidad y el rendimiento de los sistemas de información en diversas aplicaciones.

El propósito central del modelo de DeLone y McLean es establecer estándares que permitan evaluar la eficacia de los sistemas de información más allá de su implementación técnica. Se emplea este enfoque para comprender cómo distintos elementos, como la calidad del sistema, la satisfacción del usuario y la entrega de información estratégica, impactan en el

rendimiento general dentro de un contexto de información a nivel humano y organizacional, también nos permite identificar áreas que requieren optimización y mejora en la administración y ejecución de estos sistemas (Zepeda et al., 2018a). se muestra el modelo del año 2016 muestran en la Figura 9.

Figura 9

Modelo DeLone y McLean 2016



Nota: Tomado de (Reascos, 2020).

1.5.1. Calidad del sistema

Dentro del marco del desarrollo de una aplicación móvil para el reconocimiento de especies maderables mediante redes neuronales convolucionales (CNN), aborda la eficiencia, confiabilidad y adaptabilidad del sistema de acuerdo con el modelo propuesto por DeLone y McLean. El rendimiento óptimo del reconocimiento en tiempo real está vinculado con la eficiencia. La fiabilidad se basa en la solidez y uniformidad del sistema, minimizando fallas y asegurando una experiencia de usuario fiable. La flexibilidad destaca la capacidad del sistema para adaptarse a cambios y actualizaciones, siendo fundamental para incorporar nuevas

especies o mejoras en la CNN. Además, se considera la seguridad, escalabilidad y capacidad de manejar cargas variables.

1.5.2. Calidad de la información

Se centra en los criterios de relevancia, precisión e integridad propuestos por DeLone y McLean. Los usuarios interesados en la identificación de especies maderables pueden beneficiarse de la información proporcionada por su relevancia. Mientras que la integridad se refiere a la totalidad de la información ofrecida, la precisión se refiere a la exactitud de los resultados que produce el sistema de identificación. Además, se tienen en cuenta los métodos para mantener la información actual, así como la visualización y la interpretabilidad para consumidores no técnicos.

1.5.3. Calidad del servicio

El modelo de éxito de sistemas de información de DeLone y McLean considera la Calidad del Servicio como un factor clave para evaluar la eficiencia y efectividad del soporte proporcionado a los usuarios de un sistema de información. Esta evaluación abarca elementos como la fiabilidad, la capacidad de respuesta, la competencia del personal, la empatía y la disponibilidad del soporte.

Esta dimensión, junto con la calidad del sistema y la calidad de la información, influye directamente en la satisfacción del usuario, la intención de uso y los resultados organizacionales, desempeñando un papel esencial en la generación de confianza y el aprovechamiento óptimo del sistema.

1.5.4. Intención de uso/uso

Analiza la voluntad de los usuarios de acoger y usar el aplicativo móvil de forma constante. En el caso del reconocimiento de especies maderables, se identifica cómo el diseño del sistema y sus resultados impactan en la confianza de los usuarios para depender del sistema en su trabajo cotidiano. Para fortalecer esta dimensión, es clave promover el interés y la utilidad percibida del sistema mediante demostraciones prácticas, tutoriales integrados y capacitaciones que resalten su efectividad en escenarios reales. Además, se sugiere implementar estrategias para superar la indecisión en los usuarios potenciales, como la mejora continua de la interfaz y la inclusión de funcionalidades adicionales que optimicen la experiencia general. Estas

acciones pueden aumentar la aceptación y garantizar una mayor frecuencia de uso, consolidando el impacto del sistema en la gestión forestal.

1.5.5. Satisfacción del usuario

Se enfoca en la experiencia del usuario evaluando la usabilidad, asegurando interfaces intuitivas y eficientes para la identificación de especies maderables. La accesibilidad es clave, buscando que la aplicación sea fácilmente utilizada por diversos usuarios, independientemente de sus habilidades técnicas. Además, se aborda la respuesta a las expectativas del usuario, asegurando que la aplicación cumpla con precisión y relevancia en la identificación de especies maderables. Estrategias de retroalimentación del usuario, como encuestas y análisis de comentarios, son esenciales para ajustar continuamente la aplicación, garantizando una experiencia satisfactoria y alineada con las preferencias y necesidades de la audiencia.

1.5.6. Impactos netos

La dimensión de Impactos Netos mide el valor total que el sistema de información aporta, tanto a nivel individual (eficiencia y satisfacción) como organizacional (productividad, reducción de costos y ventaja competitiva). Representa los resultados finales del uso del sistema, evaluados a través de métricas tangibles e intangibles.

1.5.7. Relevancia en el aplicativo de reconocimiento de madera

Aquí se destaca cómo los principios de Delone and McLean se alinean estrechamente con el objetivo central de desarrollar una aplicación móvil para el reconocimiento de cinco especies maderables a partir de imágenes macroscópicas de madera. La calidad de la información se enfoca en proporcionar datos precisos y relevantes para la identificación de especies. La calidad del sistema asegura la eficiencia y confiabilidad del sistema de reconocimiento, mientras que la satisfacción del usuario se logra mediante la usabilidad y accesibilidad de la aplicación. La adaptabilidad del sistema garantiza su capacidad de evolucionar con la incorporación de nuevas especies o mejoras en el modelo de reconocimiento, estos principios de Delone y McLean proporcionan un esquema robusto para valorar y garantizar la calidad y eficacia de la aplicación para móviles.

CAPÍTULO 2

2. Desarrollo

El propósito de este capítulo es desarrollar una aplicación para móviles capaz de identificar cinco especies de madera mediante imágenes de gran macroscópicas, la cual llevará el nombre de “Wood Identifier UTN”. Para el desarrollo de esta aplicación, se tomó como base la aplicación móvil MaderApp, desarrollada en Perú, que también se enfoca en el reconocimiento de especies maderables. Con este fundamento, se empleará una red neuronal convolucional para incrementar la exactitud y agilidad en la identificación de estas especies. La meta es proporcionar a los profesionales del sector forestal una herramienta eficiente y accesible para identificar especies maderables en el campo, reduciendo así la dependencia de métodos manuales y costosos.

2.1. Visión general

Para el desarrollo de la aplicación se utilizó la metodología Kanban con todas las fases que abarca la metodología, fue lo más conveniente ya que necesitábamos trabajar con tareas que estaban por realizarse o pendientes, tareas que estaban en proceso y las tareas que ya habían sido completadas para llevar un correcto flujo de trabajo.

2.1.1. Planificación

La tabla 1 presenta la planificación sugerida para el desarrollo de la aplicación móvil.

Tabla 1

Planificación Para el Desarrollo

Actividades	Tiempo Estimado
Obtención de 400 imágenes macroscópicas por cada especie maderable	6 semanas
Clasificación y procesamiento de las imágenes obtenidas	3 semanas
Anotación de imágenes	4 semanas

Programación de la red neuronal convolucional	2 semanas
Entrenamiento de la CNN con el Data set de imágenes	1 semana
Realización de mejoras en el algoritmo para evitar pérdidas	3 semanas
Desarrollo del aplicativo móvil para el reconocimiento de 5 especies maderables	4 semanas
Instalación de la aplicación en un dispositivo Android para posteriores pruebas	1/2 semana

Nota. Elaboración propia

2.1.2. Entregables

Aquí se detallan los entregables del proyecto que serán entregados al final de mismo, se puede ver en la tabla 2.

Tabla 2

Entregables del Proyecto

Entregables	Descripción
Data set	Data set conformada por todas las muestras de imágenes macroscópicas de madera por cada especie
Modelo entrenado de la red neuronal convolucional utilizada en el desarrollo del proyecto	El mejor modelo compilado en formato <i>.tflite</i>
Métricas de inteligencia artificial	La interpretación y el análisis de los resultados obtenidas en el entrenamiento del modelo.
APK	APK de instalación de la aplicación realizada
Código	Código realizado en Python de la red neuronal utilizada y de la aplicación realizada en Android Studio para futuras modificaciones y mejoras.

Nota. Elaboración propia

2.1.3. Materiales y herramientas

Las herramientas y materiales utilizados en este proyecto se observan en la tabla 3

Tabla 3

Materiales y Herramientas Utilizadas en el Desarrollo

Materiales o Herramientas	Costo estimado
Hardware:	
Laptop	800.00
Celular	300.00
Microscopio	280.00
Google Colabority	0.00
Lupa 10x	25.00
Cámara microscopio USB 10x	180.00
Microscopio USB Android	25.00
Software:	
Visual Studio Code	0.00
Office 365	0.00
Roboflow	0.00
Android Studio	0.00
Otros:	
Transporte	325.00
Internet	300.00
Electricidad	300.00
Total:	\$2535.00

Nota. Elaboración propia

2.2. Especies maderables

Las 5 especies seleccionadas en este proyecto se observa en la tabla 4.

Tabla 4

Especies Maderables

Índice	Nombre común	Nombre científico
1	Cedro	<i>Cedrela odorata</i> L
2	Chonta Caspi	<i>Andira inermis</i> (W. Wright) Kunth ex DC
3	Sande o Lechoso	<i>Brosimum utile subsp. occidentale</i> C.C Berg
4	Nogal	<i>Juglans neotropica</i> Diels
5	Chalviande	<i>Virola dixonii</i> Little

Nota. Elaboración propia

En esta sección se ha seleccionado los tipos de madera que se muestran en la tabla 4 las cuales son el Cedro, Chonta Caspi, Sande o Lechoso, Nogal y Chalviande. En cada especie seleccionada se ha tomado como base el corte transversal de la madera ya que aquí se puede apreciar las diferentes estructuras que tiene cada una. A continuación, se describe características de cada especie.

Chonta Caspi

Presenta una madera de color marrón claro a rojizo, con un grano recto o ligeramente entrelazado. Su textura es gruesa y densa, con poros grandes y dispersos que la hacen fácilmente identificable. Esta especie es conocida por su alta resistencia al desgaste y su dureza. Los anillos de crecimiento son muy visibles en los cortes transversales, lo que facilita su identificación por los expertos en el campo. Una imagen macroscópica de esta especie se puede visualizar en la figura 10.

Figura 10 *Chonta Caspi*



Nota: Elaboración propia.

Sande o Lechoso

Tiene un color que va del blanco al amarillo pálido. Su grano es recto o ligeramente ondulado, y la textura es fina y uniforme. Tiene una baja porosidad, con poros pequeños y dispersos, lo que la hace fácil de trabajar. Aunque su densidad es más baja en comparación con otras maderas, su suavidad al tacto y la falta de anillos de crecimiento muy marcados son características que los expertos utilizan para identificarla. Una imagen macroscópica de esta especie se puede visualizar en la figura 11.

Figura 11 *Sande o Lechoso*




Nota: Elaboración propia.

Cedro

El Cedro tiene una estructura celular característica que se distingue por las fibras largas y flexibles. Los expertos forestales suelen identificarla por su fragancia característica y la ausencia de anillos de crecimiento muy definidos, que la diferencian de otras especies. La densidad relativamente baja y la resistencia a las plagas también son factores clave en su identificación. Una imagen macroscópica de esta especie se puede visualizar en la figura 12.

Figura 12 *Cedro*




Nota: Elaboración propia.

Nogal

Es fácilmente reconocible por su color marrón oscuro a negro, con matices más claros. Su grano puede ser recto o ligeramente ondulado, y su textura varía de fina a media. La porosidad de la madera es baja, con una estructura celular compacta que le da una alta resistencia. Los profesionales la identifican por sus patrones característicos, como los “ojos de bife” en la sección transversal, y por su peso y densidad, lo que la hace resistente al desgaste y altamente duradera. Una imagen macroscópica de esta especie se puede visualizar en la figura 13.

Figura 13 *Nogal*



Nota: Elaboración propia.

Chalviande

Tiene un color que varía de marrón claro a amarillo pálido, con un grano recto y una textura uniforme y fina. Su porosidad es moderada, con poros pequeños y dispersos. Es una madera de densidad media, flexible y fácil de trabajar. Los anillos de crecimiento son bien definidos, lo que facilita su identificación. La madera se distingue por su consistencia y la facilidad con que puede ser manipulada, lo que hace que sea elegida en la fabricación de muebles y otros productos de carpintería. Una imagen macroscópica de esta especie se puede visualizar en la figura 14.

Figura 14 *Chalviande*

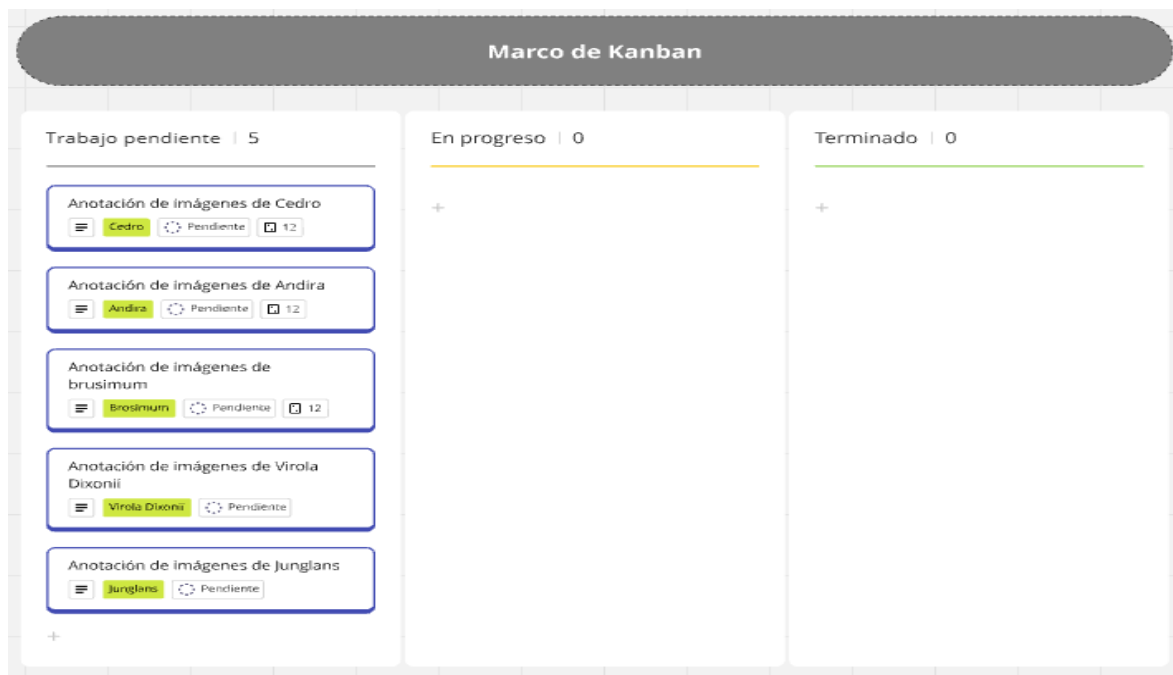


Nota: Elaboración propia.

2.3. Proceso de anotación de imágenes

La anotación del conjunto de datos es un componente crucial dentro de las etapas de selección, preprocesamiento y transformación de los datos. Debido a su gran relevancia, se ha creado esta sección para detallar el proceso realizado. En la figura 15, se puede observar el tablero Kanban con las tareas asignadas para esta sección.

Figura 15 Tablero Kanban para anotación de imágenes



Nota: Elaboración propia

Para realizar todas las tareas de anotación, se utilizó la plataforma Roboflow. Esta herramienta es muy popular, fácil de aprender y usar, y ofrece diversos métodos de anotación de imágenes, como el bounding box (Roboflow, 2024). En este proyecto se ha optado por este tipo de anotación.

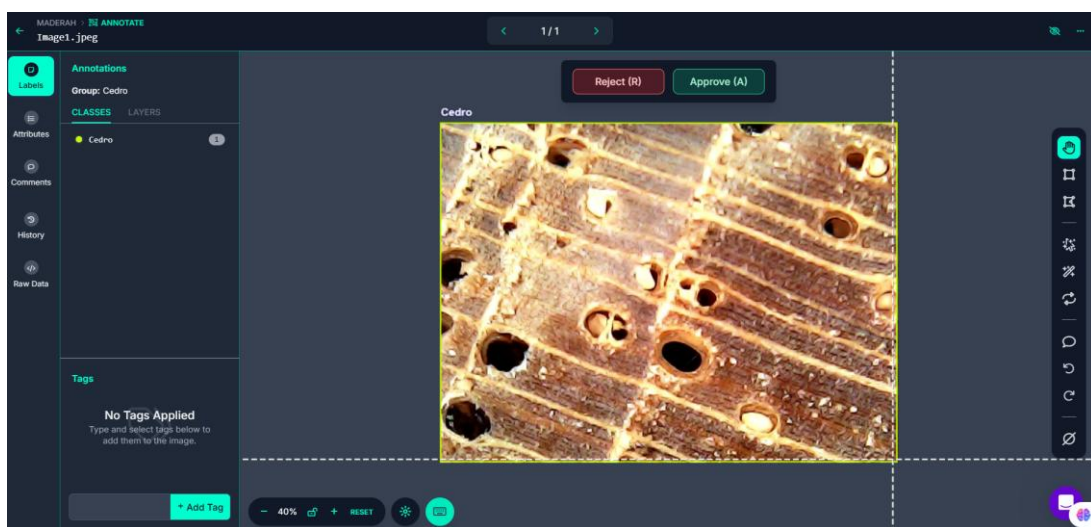
Se creó un proyecto individual para cada tipo de madera dentro de la plataforma, con el fin de facilitar la anotación de las imágenes y asegurar una distribución equitativa entre los conjuntos de entrenamiento y validación. Roboflow proporciona herramientas que simplifican la etiquetación de las imágenes, algunas de manera manual y se optó por realizar la anotación

de manera manual con el objetivo de incrementar la confiabilidad del proceso en la detección de objetos mediante inteligencia artificial.

En la figura 16, se presenta la interfaz gráfica de Roboflow para la anotación de imágenes. También se muestra como se hizo la anotación respectiva de la madera utilizando la herramienta de anotación Roboflow, donde se le asigna su nombre de categoría a la que pertenece separándolas por carpetas.

Figura 16

Anotación de imágenes en roboflow de la especie cedro








Nota: Elaboración propia.

En la figura 17, se observa la creación de las cinco carpetas en las que se almacenan las imágenes mencionadas previamente.

Figura 17

Clasificación por carpetas

Nombre	Fecha de modificación	Tipo	Tamaño
 Cedro	27/01/2025 15:10	Carpeta de archivos	
 Chalviande	27/01/2025 15:10	Carpeta de archivos	
 Chonta Caspi	27/01/2025 15:08	Carpeta de archivos	
 Nogal	27/01/2025 15:11	Carpeta de archivos	
 Sande	27/01/2025 15:12	Carpeta de archivos	

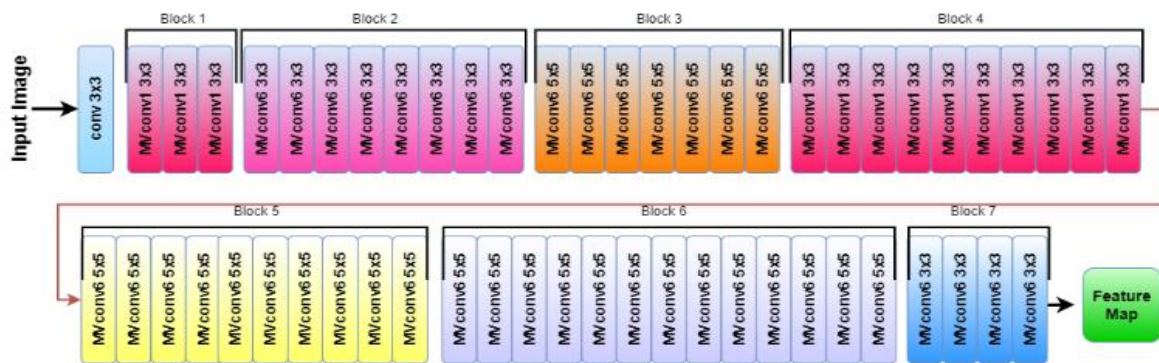
Nota: Elaboración propia.

2.4. Definición de la Red Neuronal Convolutiva

La red neuronal convolutiva seleccionada para este proyecto es EfficientNetB7, elegida debido a su alto rendimiento y eficiencia, factores clave para la tarea de identificación de tipos de madera. EfficientNetB7 es una variante avanzada de la familia EfficientNet, que se destaca por su enfoque de escalado eficiente, optimizando tanto la profundidad como la resolución y el ancho del modelo. Según los autores de la arquitectura, EfficientNetB7 ofrece un rendimiento superior en comparación con otras redes convolucionales similares (Saavedra et al., 2020). Esto es particularmente útil para la tarea de identificación de tipos de madera, dada la complejidad y dificultad de esta labor con otros métodos, en la figura 18 se muestra la arquitectura de esta red neuronal convolutiva.

Figura 18

Arquitectura EfficientNetB7




Nota: Arquitectura EfficientNetB7. Tomado de (Joy et al., 2023).

La arquitectura EfficientNetB7 puede tener diferentes estructuras escalables de 3 dimensiones que son, profundidad o cantidad de número de capas (depth), anchura (width) o cantidad de filtros por cada capa, y resolución de las entradas al sistema a lo que es llamado también como Compound Scaling. en la figura 19 se muestran cuáles son.

Figura 19

Arquitectura de Compound Scaling



Nota: Compound Scaling de EfficientNetB7. Tomado de (Joy et al., 2023).

2.5. Desarrollo y entrenamiento del modelo

Esta etapa consiste en preparar un conjunto de datos representativo, definir y entrenar la red neuronal convolucional (CNN) para reconocer las cinco especies maderables. Se aplican técnicas como el preprocesamiento de imágenes, ajuste de hiperparámetros y validación con métricas clave, asegurando la precisión del modelo antes de integrarlo al aplicativo móvil. Para este proceso se ha realizado una planificación Kanban que se puede ver en la figura 20.

Figura 20

Tablero Kanban para entrenamiento del modelo

























Nota: Elaboración propia.

Para la obtención del modelo entrenado en un formato *.flite*, y poderlo utilizar en la aplicación móvil para la identificación correcta de las 5 especies maderables se siguió los siguientes pasos.

1. Como primer paso debemos tener una cuenta de Google drive con el fin de almacenar el dataset de imágenes.
2. Como segundo paso se necesitó de los servicios de Google colab donde se va a realizar el código en lenguaje Python el cual va a ser ejecutado en recursos gratuitos de Google que ofrece este entorno de desarrollo y no utilizar los recursos de nuestra computadora, esto ayudará que el entrenamiento sea mucho más optimo, frente a esto se procedió a crear un nuevo cuaderno de desarrollo con el nombre *Wood_identifierUTN-_efficientNet-B7.ipynb* que se puede visualizar en la figura 21.

Figura 21

Cuaderno de desarrollo Google colab

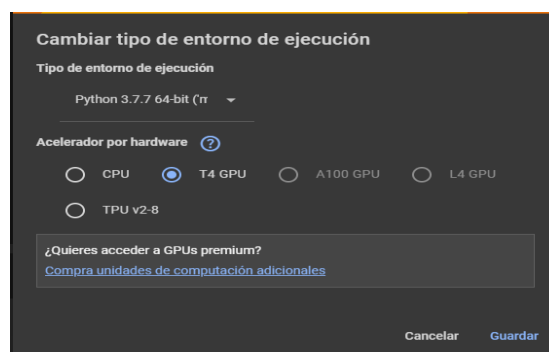
Nombre	Propietario	Última modifica...	Tamaño del :
 MMMacroscopic tree images classification with emcientNe...	 yo	6 ago 2024 yo	12.7 MB
 M22Macroscopic tree images classification with efficientN...	 yo	6 ago 2024 yo	14.4 MB
 Copia de M22Macroscopic tree images classification with e...	 yo	8 ago 2024 yo	14.3 MB
 ZWood_Classification.ipynb	 yo	26 ago 2024 yo	2.4 MB
 22Macroscopic tree images classification with efficientNet...	 yo	26 oct 2024 yo	3.2 MB
 EfficientNet.ipynb	 yo	29 oct 2024 yo	30 KB
 Base_CNN_OK.ipynb	 yo	11 nov 2024 yo	21.3 MB
 Copia de Base_CNN_OK.ipynb	 yo	11 nov 2024 yo	7.7 MB
 Macroscopic tree images classification with efficientNet-B...	 yo	13 nov 2024 yo	7 MB
 Copia de Wood_IdentifierUTN_efficientNet-B7.ipynb	 yo	5:16 p.m. yo	14.3 MB
 Wood_IdentifierUTN_efficientNet-B7.ipynb	 yo	5:16 p.m. yo	14.2 MB

Nota: Elaboración propia.

3. En este paso, se continúa con la configuración del entorno de desarrollo, donde es necesario seleccionar la configuración adecuada. Esto permitirá modificar el uso del acelerador por hardware y tipo de entorno. Para este contexto, se recomienda elegir la GPU T4, ya que optimiza el rendimiento en el proceso de aprendizaje de la red neuronal convolucional. La figura 22 ilustra este procedimiento.

Figura 22

Ajustes de entorno de desarrollo Google Colab



Nota: Elaboración propia.

- Después de configurar el entorno, se procede con la implementación del código de programación, el cual culminará con el entrenamiento del modelo. El primer paso en este proceso es establecer la conexión del entorno de ejecución con Google Drive, donde se encuentra el conjunto de imágenes necesario para el entrenamiento de la red neuronal. Esto se puede observar en la figura 23.

Figura 23

Conexión de Google drive con el entorno de desarrollo

```
[ ] # Import Drive
    from google.colab import drive
    # Montar Google Drive
    drive.mount('/content/drive')
```

Nota: Elaboración propia.

- Este paso consiste en importa librerías y módulos como tensorflow, keras, numpy entre otros que van a ser necesarios para el relacionándose con el procesamiento de imágenes. También se realiza la instalación de la Biblioteca de red neuronal convolucional Efficientnet la cual vamos a utilizar, todo esto se muestra en la figura 24.

Figura 24

Librerías, Módulos y Biblioteca Efficientnet

```
import matplotlib.pyplot as plt
import numpy as np
import os, datetime
import PIL
import tensorflow as tf
import numpy as np

from tensorflow import keras
from tensorflow.keras import layers
from tensorflow.keras.models import Sequential
from tensorflow.keras import optimizers
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from sklearn.metrics import f1_score, precision_score, recall_score, confusion_matrix

!pip install efficientnet
import efficientnet.tfkeras as efn
```

Nota: Elaboración propia.

6. En este paso se agrega un bloque de código que tiene como objetivo mover imágenes a carpetas específicas según los dos primeros caracteres de su nombre, convertirlas a formato JPEG y eliminar las versiones originales. La función `convert_save_img` abre una imagen, la convierte a RGB y la guarda en una nueva ubicación. `move_images` decide la carpeta según la especie (los dos primeros caracteres), crea la carpeta si no existe, convierte la imagen y borra el archivo original, pero si la especie no está en `img_classes`, simplemente elimina la imagen. En la figura 25 se puede ver este bloque de código.

Figura 25

Conversión de Imágenes a Formato JPG



```
def convert_save_img(source, destination):
    # importing the image
    im = Image.open(source)

    # converting to jpg
    rgb_im = im.convert("RGB")

    # exporting the image
    rgb_im.save(destination)

def move_images(file):
    # Creates source and destination files
    if len(file.parts) == 2:
        folder, img_file = file.parts
        specie = "" if "." in img_file else img_file[0:2]
        source = Path(folder, img_file)
        destination = file.parent / specie / (file.name[:-4] + ".JPEG")

    if specie in img_classes:
        # Create directory and place image there
        directory_specie = Path(folder, specie)
        directory_specie.mkdir(parents=True, exist_ok=True)
        convert_save_img(str(source), str(destination))
        source.unlink()
        return destination

    source.unlink()
```

Nota: Elaboración propia.

7. Como siguiente paso se carga un conjunto de imágenes desde una carpeta específica desde el Drive de Google para usarlas en un modelo de machine learning. Primero, se define la ruta donde están almacenadas las imágenes en este caso en `/content/drive/My Drive/BI/Maderas/train/` y se cuenta cuántas hay. Luego se utiliza TensorFlow (`tf.data.Dataset`) para listar las rutas de las imágenes, mezclándolas aleatoriamente con un tamaño de buffer para mejorar la eficiencia. A continuación, obtiene las clases (nombres de subcarpetas) y divide el dataset en dos partes: 80% para entrenamiento y 20% para validación. Finalmente, imprime los nombres de las clases y la cantidad de datos asignados a cada conjunto. Esto se puede ver en la figura 26.

Figura 26

Carga y División de Imágenes

```
Loading datasets

import pathlib

# Path to drive folder
dataset_url = "/content/drive/My Drive/BI/Maderas/train/"

data_dir = pathlib.Path(dataset_url)
image_count = len(list(data_dir.glob('*/*.JPEG')))
# CHECK if image_count is zero and warn the user if so
if image_count == 0:
    print("Warning: No images found in directory. Check the path.")

list_ds = tf.data.Dataset.list_files(str(data_dir/'*/*'), shuffle=False)
# SET a buffer size greater than 0
BUFFER_SIZE = 1000 # example value, adjust as needed
list_ds = list_ds.shuffle(BUFFER_SIZE, reshuffle_each_iteration=False)

class_names = np.array(sorted([item.name for item in data_dir.glob('*') if item.name != "LICENSE.txt"]))
print(class_names)

val_size = int(image_count * 0.2)
train_ds = list_ds.skip(val_size)
val_ds = list_ds.take(val_size)

print(len(train_ds))
print(len(val_ds))

Warning: No images found in directory. Check the path.
['Andira' 'Brosimum' 'Cedrela' 'Juglans' 'Virola']
4119
0
```

Nota: Elaboración propia.

8. Luego se agrega un bloque de código para definir funciones para cargar, procesar y etiquetar imágenes en un modelo de machine learning utilizando TensorFlow. La función `get_label` extrae la etiqueta de una imagen a partir del nombre de su carpeta. `decode_img` convierte los archivos JPEG en tensores 3D y redimensiona las imágenes al tamaño deseado. La función `process_path` carga una imagen desde su ruta, la decodifica y asocia su etiqueta correspondiente. Luego, los conjuntos de entrenamiento y validación se procesan en paralelo mediante `map` con `AUTOTUNE` para mejorar el rendimiento. Este parte de código se muestra en la figura 27.

Figura 27

Definición de Funciones Cargar, Procesar y Etiquetar Imágenes

```
Train - Test ds
[ ] def get_label(file_path):
    # Convert the path to a list of path components
    parts = tf.strings.split(file_path, os.path.sep)
    # The second to last is the class-directory

    one_hot = parts[-2] == class_names
    # Integer encode the label
    return tf.argmax(one_hot)

def decode_img(img):
    # convert the compressed string to a 3D uint8 tensor
    img = tf.image.decode_jpeg(img, channels=3)
    # resize the image to the desired size
    return tf.image.resize(img, [IMG_SIZE, IMG_SIZE])

def process_path(file_path):
    label = get_label(file_path)
    # load the raw data from the file as a string
    img = tf.io.read_file(file_path)
    img = decode_img(img)
    return img, label

# Set 'num_parallel_calls' so multiple images are loaded/processed in parallel.
train_ds = train_ds.map(process_path, num_parallel_calls=AUTOTUNE)
val_ds = val_ds.map(process_path, num_parallel_calls=AUTOTUNE)

for image, label in train_ds.take(1):
    print("Image shape: ", image.numpy().shape)
    print("Label: ", label.numpy())
```

Image shape: (256, 256, 3)
Label: 0

Nota: Elaboración propia.

9. Aquí utilizamos la red EfficientNetB7 la cual nos ayudará a obtener una cantidad máxima de parámetros para una mejor eficiencia en comparación de otras versiones de esta familia de redes neuronales. A continuación, en la figura 28 se puede ver parte del código utilizando esta versión de CNN.

Figura 28

Uso de EfficientNetB7

```
import tensorflow as tf
import efficientnet.tfkeras as efn

# Usar EfficientNetB7 en lugar de EfficientNetB0
effb7_model = efn.EfficientNetB7(weights='noisy-student', include_top=False, input_shape=[*IMG_SIZE, IMG_SIZE], 3)

# Descongelar la base del modelo
effb7_model.trainable = False

model1 = tf.keras.Sequential([
    resize_and_rescale,
    effb7_model,
    tf.keras.layers.GlobalAveragePooling2D(),
    tf.keras.layers.Dropout(0.5),
    tf.keras.layers.Dense(NUM_CLASS, activation='softmax')
])

model1.build(input_shape=[*None, IMG_SIZE, IMG_SIZE], 3)
model1.summary()
```

Nota: Elaboración propia.

10. A continuación, se agrega un bloque de código que configura el preprocesamiento y la preparación de datos. Se define una capa secuencial llamada `resize_and_rescale`, que normaliza los valores de píxeles dividiéndolos entre 255 para llevarlos al rango [0, 1]. La función `data_cfg_aug` aplica varias configuraciones a un dataset, mezcla los datos si se indica, los organiza en lotes y, si se activa la opción de aumento se aplica data augmentation. Finalmente, utiliza `prefetch` para cargar datos en paralelo, optimizando el rendimiento con un aumento de datos. Se muestra en la figura 29.

Figura 29

Preprocesamiento y Aumento de Datos

```

Data preprocessing and augmentation
[ ] resize_and_rescale = tf.keras.Sequential([
    layers.Rescaling(1./255)
])

[ ] def data_cfg_aug(ds, shuffle=False, augment=False, repeat=True):
    ds = ds.cache()
    if repeat:
        ds = ds.repeat()
    if shuffle:
        ds = ds.shuffle(buffer_size=BUFFER_SIZE)
    ds = ds.batch(BATCH_SIZE)
    # Use data augmentation only on the training set
    if augment:
        ds = ds.map(lambda x, y: (data_augmentation(x, training=True), y),
            num_parallel_calls=AUTOTUNE)
    ds = ds.prefetch(buffer_size=AUTOTUNE)
    return ds

[ ] train_ds_cfg_a = data_cfg_aug(train_ds, shuffle=True, augment=True)
    val_ds_cfg_a = data_cfg_aug(val_ds, shuffle=True, augment=False, repeat=True)

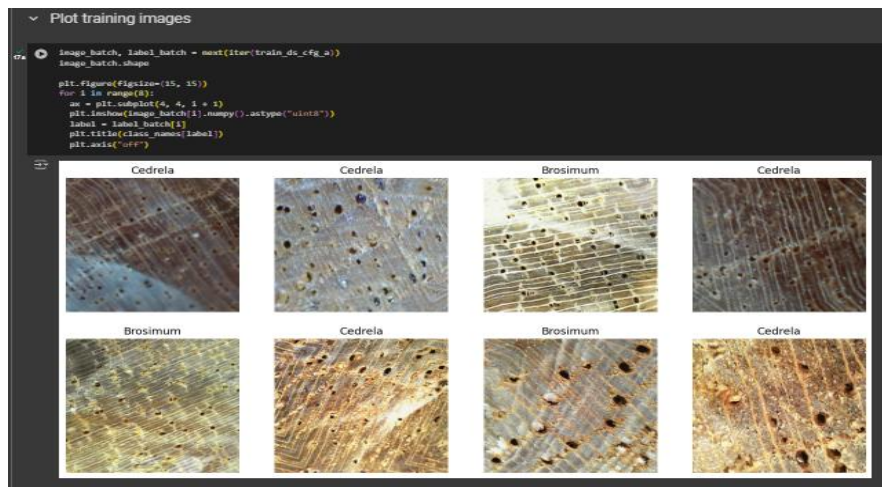
```

Nota: Elaboración propia.

11. Agregamos un pequeño bloque de código que nos permitirá visualizar un pequeño lote de 8 imágenes y etiquetas del conjunto de entrenamiento configurado utilizando Matplotlib. Esto se puede visualizar en la figura 30.

Figura 30

Visualización de un Lote de Imágenes de Entrenamiento

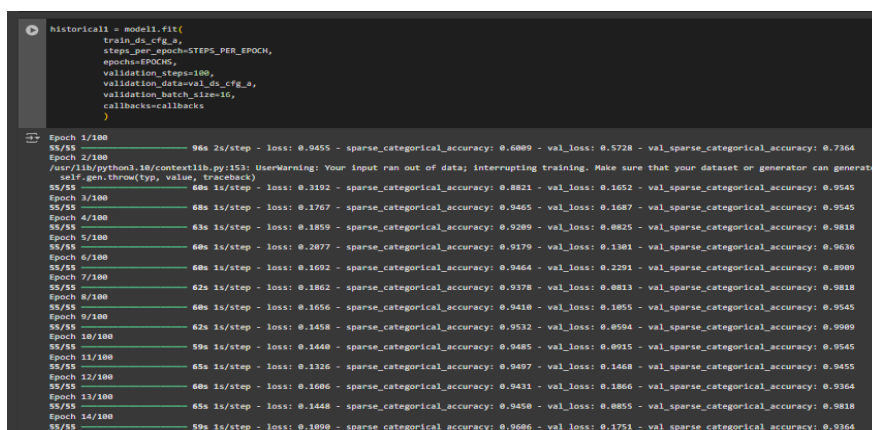


Nota: Elaboración propia.

12. Luego ya ponemos a entrenar el modelo con 100 épocas utilizando la función callbacks la cual nos va a permitir escoger el mejor modelo entrenado siendo así escogido en una época menor a la asignada, También restando el uso de recursos al realizar el entrenamiento y evitando perdidas que puedan afectar al modelo entrenado. En la figura 31 se puede observar el entrenamiento.

Figura 31

Entrenamiento del Modelo



Nota: Elaboración propia.

13. Por último, después de algunas configuraciones y la finalización del entrenamiento generamos el archivo .tflite del modelo entrenado para usarlo más adelante en la aplicación móvil. Se puede observar en la figura 32 a continuación.

Figura 32

Obtención del Archivo Tensorflow Lite del Modelo

```
[ ] # Convertir el modelo entrenado a TensorFlow Lite
converter = tf.lite.TFLiteConverter.from_keras_model(model1)
tflite_model = converter.convert()
with open("model.tflite", 'wb') as f:
    f.write(tflite_model)

139462219118048: TensorSpec(shape=(), dtype=tf.resource, name=None)
139462219120160: TensorSpec(shape=(), dtype=tf.resource, name=None)
139462219109248: TensorSpec(shape=(), dtype=tf.resource, name=None)
139462219115760: TensorSpec(shape=(), dtype=tf.resource, name=None)
139462219225520: TensorSpec(shape=(), dtype=tf.resource, name=None)
139462219228688: TensorSpec(shape=(), dtype=tf.resource, name=None)
139462219227808: TensorSpec(shape=(), dtype=tf.resource, name=None)
139462219231152: TensorSpec(shape=(), dtype=tf.resource, name=None)
139462519937632: TensorSpec(shape=(), dtype=tf.resource, name=None)
139462574464640: TensorSpec(shape=(), dtype=tf.resource, name=None)
139462574464112: TensorSpec(shape=(), dtype=tf.resource, name=None)
139462222690640: TensorSpec(shape=(), dtype=tf.resource, name=None)
139462574465696: TensorSpec(shape=(), dtype=tf.resource, name=None)
139462219232912: TensorSpec(shape=(), dtype=tf.resource, name=None)
139462219352016: TensorSpec(shape=(), dtype=tf.resource, name=None)
139462219350432: TensorSpec(shape=(), dtype=tf.resource, name=None)
139462219233088: TensorSpec(shape=(), dtype=tf.resource, name=None)
139462219235024: TensorSpec(shape=(), dtype=tf.resource, name=None)
139462219354656: TensorSpec(shape=(), dtype=tf.resource, name=None)
139462219355360: TensorSpec(shape=(), dtype=tf.resource, name=None)
```

Nota: Elaboración propia.

2.6. Matriz de confusión y métricas

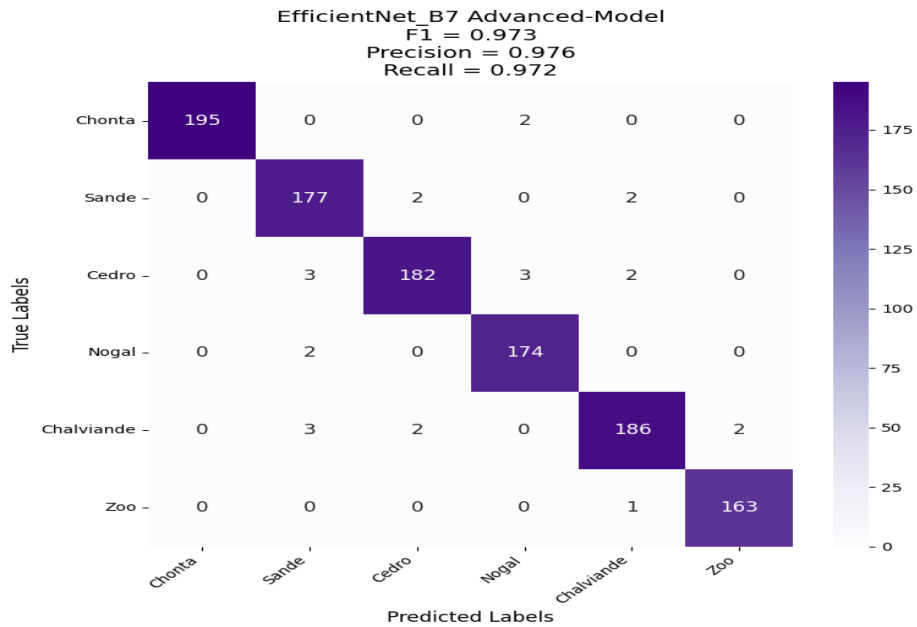
En esta sección, se exponen y examinan los resultados obtenidos a partir de las métricas utilizadas para evaluar el desempeño de la red neuronal en la clasificación de especies maderables. Para ello, se seleccionaron diversas métricas de rendimiento, como la precisión, la recuperación (Recall), el F1-Score y la matriz de confusión. Estas métricas permiten medir de manera objetiva la capacidad del modelo para identificar correctamente las especies según sus características visuales. El análisis detallado de estos indicadores proporciona una visión clara sobre la efectividad del modelo en la clasificación, así como sus posibles limitaciones y áreas de mejora.

2.7.1. Matriz de confusión

Estas métricas de igual manera se encuentran en la figura 33.

Figura 33

Matriz de Confusión



Nota: Elaboración propia.

Nota:

Pudimos darnos cuenta de que en la figura 33 existe el nombre "Zoo" como otra especie, esto se incluyó para mejorar la capacidad de la red neuronal de diferenciar las especies maderables de interés frente a imágenes no relacionadas. Este conjunto aporta imágenes aleatorias que permite aprender a la red neuronal a ignorar patrones irrelevantes y concentrarse exclusivamente en las especies de madera, ayudando al modelo a evitar falsos positivos. Además, permite evaluar con mayor precisión su desempeño mediante una matriz de confusión más robusta, garantizando la fiabilidad del aplicativo móvil en situaciones prácticas.

La palabra "Zoo" fue de manera estratégica ya que lleva la letra "Z" y esto puede influir en el orden alfabético, con esto se asegura que este conjunto de datos, que contiene imágenes aleatorias y no relacionadas con las especies maderables, sea procesado al final, permitiendo

que el algoritmo priorice inicialmente las clases principales de interés facilitando un entrenamiento más organizado y estructurado.

EXPLICACIÓN:

- **Eje vertical (Eje Y):** Representa las etiquetas reales (la verdadera clase a la que pertenece cada muestra).
- **Eje horizontal (eje X):** Representa las etiquetas predichas (la clase que el modelo predijo para cada muestra).
- **Celdas de la matriz:**
 - Las celdas diagonales (las más oscuras en el gráfico) indican las predicciones correctas, es decir, los casos en los que la clase predicha por la red coincide con la clase real. Estas celdas muestran el número de muestras correctamente clasificadas para cada categoría.
 - Las celdas fuera de la diagonal muestran las predicciones incorrectas (falsos positivos y falsos negativos). Estas celdas indican cuántas veces una clase fue confundida con otra.

En la tabla 5 se puede ver de manera detallada las cantidades de imágenes del entrenamiento e imágenes correctamente predichas e incorrectamente predichas.

Tabla 5

Análisis de Resultados

Especies	# de imágenes de validación	Correctas	Incorrectas
Chonta Caspi	197	195	2
Sande o Lechoso	181	177	4
Cedro	190	182	8
Nogal	176	174	2
Chalviande	193	186	7
TOTAL	937	914	23

Nota. Elaboración propia

Como se observa en la tabla 5, el modelo logró predecir correctamente 914 imágenes, lo que representa la mayoría de los datos. Es relevante destacar que, dado que el total de datos es de 937 (100%), estas 914 imágenes corresponden a más del 90%. Esto indica un alto nivel de precisión del sistema y demuestra su capacidad para reconocer con eficacia las cinco especies maderables.

También cabe señalar que porcentaje de imágenes fueron predichas de manera errónea lo cual este total incluye falsos positivos y falsos negativos. Estos nos llevan a afirmar lo siguiente.

Cuando el modelo predice de manera errónea se debe a que las imágenes no son claras, tiene sombras o ruido en las imágenes lo cual hizo que el modelo no funcionara de la mejor forma afirmando que una clase de madera pertenecía a otra clase o que no logre identificar alguna madera que si sea alguna de las entrenadas, todo esto causa cierta confusión en el modelo pero aun así este porcentaje es bastante bajo en comparación con la cantidad de imágenes que si logro reconocer el tipo de madera que era realmente.

2.7.2. Métricas

Estas métricas de igual manera se encuentran en la figura 33.

- **Precision (Precisión):** Indica la proporción de predicciones correctas para una clase en relación con todas las predicciones que se hicieron para esa clase. Es decir, se calcula dividiendo la cantidad de predicciones correctas entre el total de predicciones positivas.
- **Recall (Recuperación o sensibilidad):** Indica el porcentaje de predicciones correctas en comparación con todas las muestras reales de una clase. Se obtiene dividiendo el número de verdaderos positivos entre el total de casos reales.
- **F1 Score:** Corresponde a la media armónica entre la precisión y el recall, proporcionando un valor equilibrado cuando es necesario comparar ambas métricas.

En la figura 32, se observa que el modelo alcanza un F1 score de 0.973, con una precisión de 0.976 y un recall de 0.972. Esto sugiere que el modelo mantiene un buen equilibrio entre precisión y recuperación en la identificación de las cinco clases de especies maderables.

Para obtener mejores resultados, fue necesario ampliar el conjunto de datos de imágenes, alcanzando aproximadamente 980 imágenes por especie. Inicialmente, se había previsto trabajar con solo 400 imágenes por especie, lo que generaba métricas con precisiones entre el 90 % y el 92 %. Sin embargo, estos resultados no fueron satisfactorios, por lo que se optó por expandir el conjunto de datos con el propósito de mejorar tanto el rendimiento como la precisión de la red neuronal.

2.8. Prototipado

El proceso de prototipado es una etapa fundamental en el desarrollo de aplicaciones móviles, ya que permite visualizar y evaluar la funcionalidad y la experiencia del usuario antes de la implementación final. Mediante el uso de Figma, se pueden crear prototipos interactivos que simulen el comportamiento de la aplicación, lo que facilita la detección de problemas y la validación del diseño.

A continuación, se presenta el proceso de prototipado de la interfaz de usuario de nuestra aplicación móvil de reconocimiento de especies maderables, dividido en varias secciones que se describen más adelante.

2.8.1. Prototipo de pantalla de inicio

Se muestra la pantalla inicial del aplicativo móvil "Wood Identifier", que incluye el logotipo de la Universidad Técnica del Norte (UTN), el nombre del aplicativo y un botón interactivo con la etiqueta "INICIAR". En la figura 34 se ilustra el prototipo de inicio diseñado en Figma.

Figura 34

Prototipo de Inicio



Nota: Elaboración propia.

2.8.2. Prototipo de pantalla de información

Se presenta el diseño de la pantalla de información del aplicativo móvil, en la que se incluyen detalles sobre las muestras de madera, un campo de búsqueda para facilitar la navegación, y un menú inferior con opciones para acceder a diferentes secciones de la aplicación. Se puede observar en la figura 35 el prototipo de información realizado en figma.

Figura 35

Prototipo de Pantalla de Información




Nota: Elaboración propia.

2.8.3. *Prototipo de pantalla de funcionamiento*

Esta pantalla muestra el funcionamiento del aplicativo móvil, donde se observa el análisis de la muestra de madera seleccionada. Incluye un área de visualización con marcadores interactivos, un menú inferior para acciones específicas y opciones de navegación. Se muestra en la figura 36 el prototipo de funcionamiento realizado en figma.

Figura 36

Prototipo de Funcionamiento



Nota: Elaboración propia.

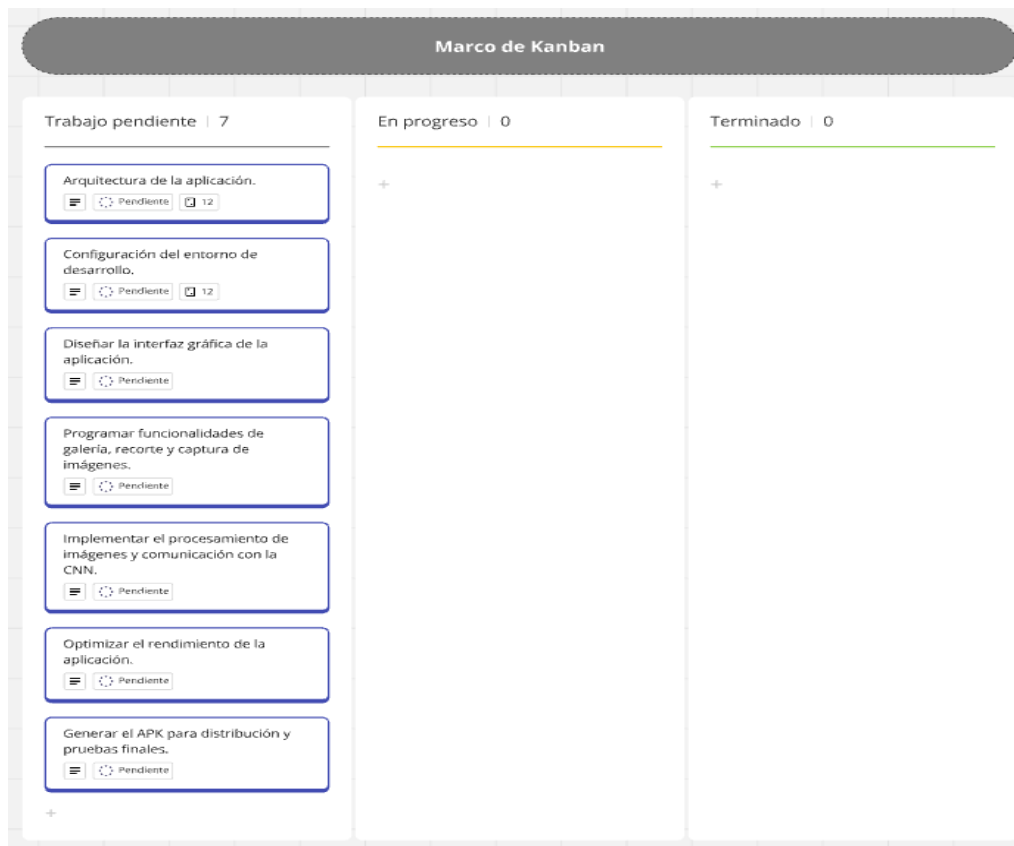
En esta pantalla también se encontrará un botón de ayuda de uso de la aplicación para el correcto manejo de mismo en vista que no se contará con un servicio técnico.

2.9. Desarrollo de la aplicación móvil

Para desarrollar la aplicación que le hemos dado el nombre de “Wood Identifier UTN”, primero hemos seleccionado cuidadosamente un entorno de desarrollo integrado (IDE) y herramientas específicas que se adaptan a las necesidades del proyecto, garantizando eficiencia y robustez en el resultado final. Este proceso es importante por lo que se ha detallado en un tablero Kanban que se muestra en la figura 37.

Figura 37

Tablero Kanban Para el Desarrollo de la Aplicación

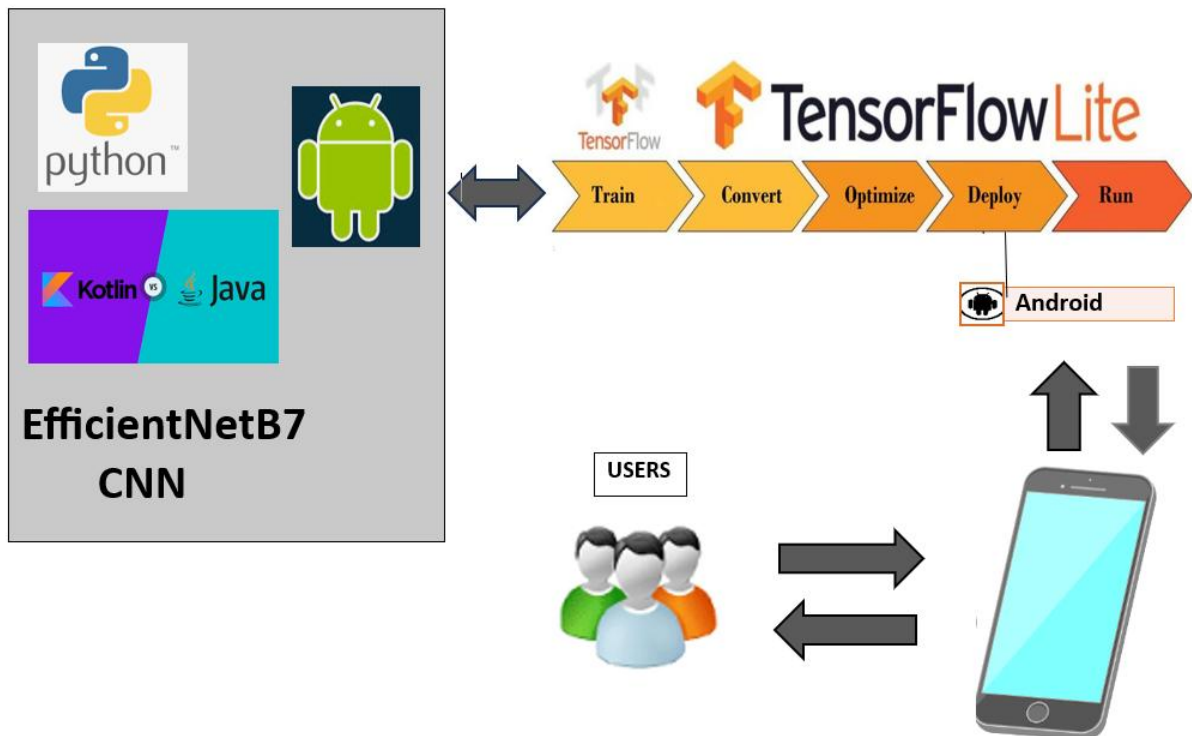


Nota: Elaboración propia.

La plataforma elegida para el desarrollo es Android, debido a su amplio alcance y flexibilidad. Para ello, hemos optado por utilizar Android Studio como IDE, una herramienta frecuentemente utilizada para el desarrollo de aplicaciones Android. Android Studio además ofrece un entorno integral con características que facilitan desarrollar, depurar e implementar aplicaciones móviles. En la figura 38 se muestra la arquitectura que se va a tener la aplicación móvil desarrollada con las herramientas anteriormente mencionadas.

Figura 38

Arquitectura de la Aplicación Móvil



Nota: Elaboración propia.

Luego de mostrar la arquitectura que va a tener la aplicación se procede a la parte del desarrollo que se lo ha dividido en diferentes secciones.

2.9.1. Preparación de entorno de desarrollo

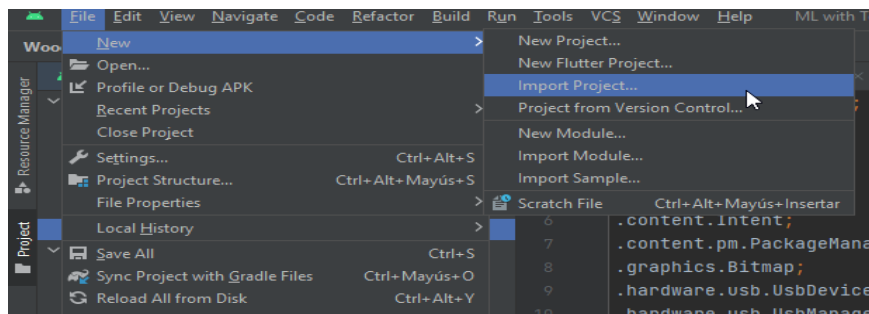
Para preparar nuestro entorno de desarrollo es necesario realizar los siguientes pasos que se explican a continuación.

1. Como paso 1 se necesita realizar la instalación del entorno de desarrollo en este caso Android Studio que se lo obtiene desde el enlace: <https://developer.android.com>, ya estando dentro de la página presionamos en Descargar Android Studio Koala esto nos redirigirá a una pestaña de la misma página donde tendremos que aceptar términos y condiciones para iniciar la descarga.

- Continuamos con la instalación ya una vez realizado el paso anterior damos clic derecho en el archivo descargado y en abrir como administrador luego se verificará la ruta donde será instalado en este caso lo dejaremos por defecto y procedemos a dar clic en el botón siguiente, también podemos elegir qué tipo de versión deseamos instalar esto ya depende de las preferencias de cada programador según lo que vaya a utilizar.
- Desde la librería de código abierto Tensorflow vamos a proceder a descargar un ejemplo de aplicación modificable que nos ofrece de manera gratuita esta librería, debemos asegurarnos que sea compatible con Android, (Aquí podremos cargar el modelo anteriormente entrenado), para lo cual debemos dirigirnos al siguiente enlace::
https://github.com/tensorflow/examples/tree/master/lite/examples/image_classification/android.
- En este paso lo que haremos es cargar el modelo descargado de la aplicación de Tensorflow mencionado en el anterior punto. Dentro de Android Studio lo primero que haremos es dirigirnos al apartado file, new, luego Import Project y por último navegamos hasta la carpeta donde se encuentra la aplicación, lo seleccionamos y damos clic en abrir, en caso de pedirnos alguna actualización sobre el Gradle ponemos que sí y aceptamos todas las actualizaciones que aparezcan, ya que son necesarias para el correcto funcionamiento de la aplicación. Parte de este proceso se muestra en la Figura 39.

Figura 39

Abrir Proyecto en Android Studio

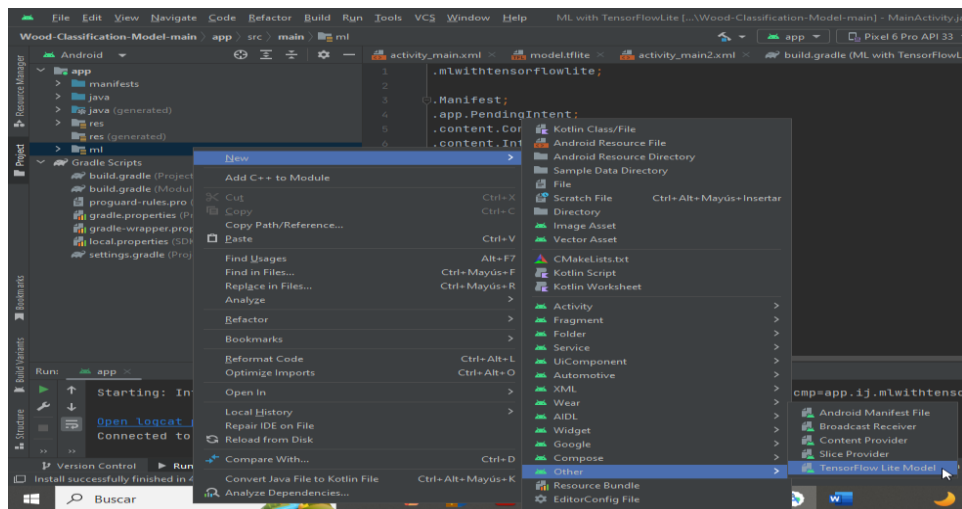


Nota: Elaboración propia.

5. Ahora procederemos a cargar el modelo .flite que ha sido previamente entrenado, mencionado en la actividad 2.4.1. Para ello, accedemos a la carpeta "ml" dentro de nuestro proyecto, luego seleccionamos "nuevo", "other" y elegimos "TensorFlow Lite Model". Finalmente, navegamos hasta la carpeta donde se encuentra el archivo del modelo entrenado y lo cargamos. Este procedimiento se ilustra en la figura 40.

Figura 40

Carga de Archivo .flite al Aplicativo



Nota: Elaboración propia.

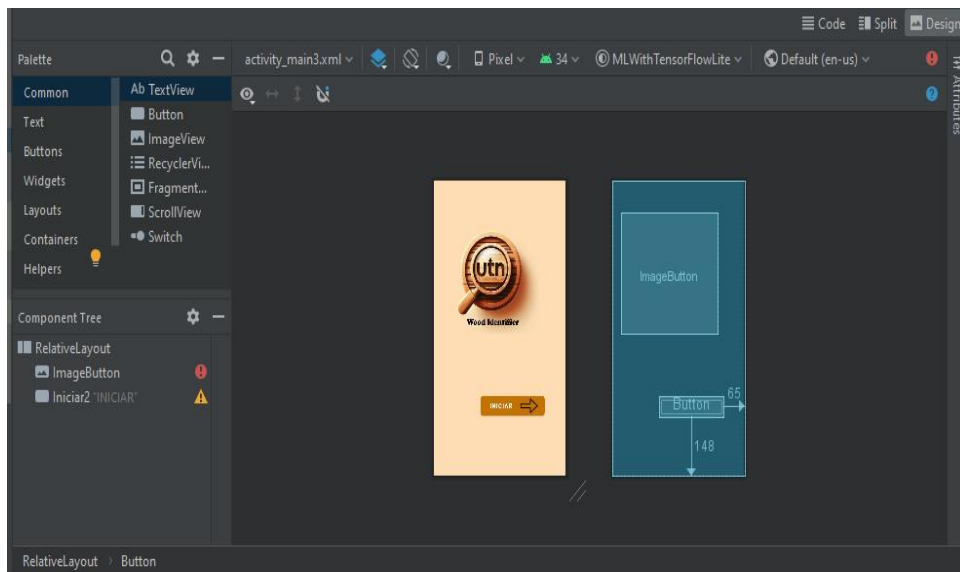
2.9.2. Codificación de la aplicación móvil

A continuación, se muestra una serie de pasos para la codificación de la aplicación:

1. Como primer paso realizamos la pantalla de inicio, para lo cual creamos un *Activity* donde colocaremos el logo de la aplicación de bienvenida y un botón de iniciar la aplicación, con su respectiva función. Esto se muestra en la figura 41.

Figura 41

Pantalla de Inicio en Android Studio

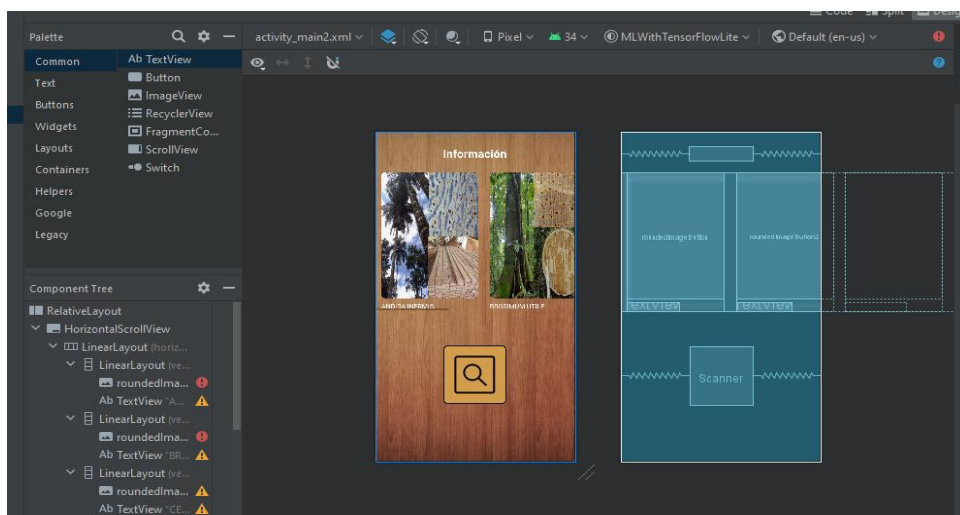


Nota: Elaboración propia.

2. Luego creamos un nuevo Activity donde vamos a tener información sobre los 5 tipos de madera que hemos entrenado. Se puede observar en la figura 42.

Figura 42

Pantalla de Información en Android Studio

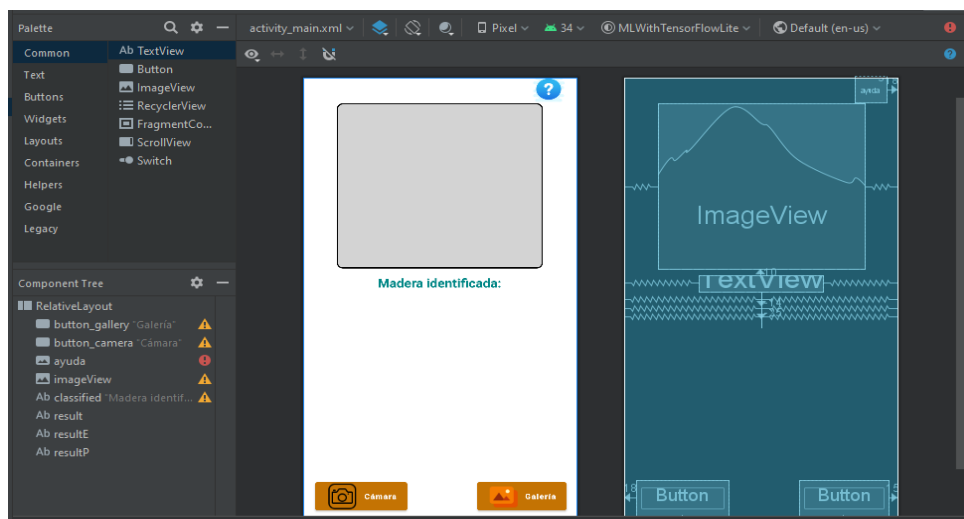


Nota: Elaboración propia.

3. Por último, vamos a tener la pantalla de funcionamiento e identificación de especies de la aplicación para el reconocimiento de los tipos de madera donde agregaremos las imágenes de madera a reconocer, podremos cargar imágenes desde la gallería de nuestro teléfono y también utilizar la cámara directamente, se puede observar en la figura 43.

Figura 43

Pantalla de Funcionamiento en Android Studio



Nota: Elaboración propia.

4. Luego continuaremos con las funcionalidades, lo primero que haremos es codificar el botón cámara añadiendo los eventos para utilizar la cámara principal del celular y capturar las imágenes, se puede visualizar en la figura 44.

Figura 44

Codificación del Botón Cámara

```
92 camera.setOnClickListener(new View.OnClickListener() {
93     @Override
94     public void onClick(View view) {
95         if (ContextCompat.checkSelfPermission(context, Manifest.permission.CAMERA) == PackageManager.PERMISSION_GRANTED) {
96             takePicture();
97         } else {
98             requestPermissions(new String[]{Manifest.permission.CAMERA}, requestCode, 100);
99         }
100     }
101 });
102
103 private void takePicture() {
104     Intent cameraIntent = new Intent(MediaStore.ACTION_IMAGE_CAPTURE);
105     if (cameraIntent.resolveActivity(getPackageManager()) != null) {
106         try {
107             tempFile = createTempImageFile();
108             if (tempFile != null) {
109                 Uri photoURI = FileProvider.getUriForFile(context, this, authority, "app.ij.mlwitensorflowlite.fileprovider", tempFile);
110                 cameraIntent.putExtra(MediaStore.EXTRA_OUTPUT, photoURI);
111                 startActivityForResult(cameraIntent, REQUEST_IMAGE_CAPTURE);
112             }
113         } catch (IOException ex) {
114             Toast.makeText(context, this, text, "Error al crear archivo temporal", Toast.LENGTH_SHORT).show();
115         }
116     }
117 }
```

Nota: Elaboración propia.

5. Ahora codificaremos el botón de galería que nos permitirá cargar imágenes de las maderas que se encuentren guardadas en nuestro dispositivo móvil, esto se puede ver en la figura 45.

Figura 45

Codificación del botón galería

```
93 gallery.setOnClickListener(new View.OnClickListener() {
94     @Override
95     public void onClick(View view) {
96         Intent galleryIntent = new Intent(Intent.ACTION_PICK, MediaStore.Images.Media.EXTERNAL_CONTENT_URI);
97         startActivityForResult(galleryIntent, REQUEST_GALLERY);
98     }
99 });
100 }
```

Nota: Elaboración propia.

Cabe mencionar que es una forma de resumir el desarrollo ya que para terminar con el desarrollo debemos codificar algunas otras funcionalidades como la forma de utilizar el modelo entrenado, la función crop para recortar las imágenes y entre otras funciones esenciales para el correcto funcionamiento de la aplicación, permitiendo así su instalación en el dispositivo para realizar las pruebas correspondientes.

2.10. Instalación y generación de APK

Después de terminar con el desarrollo debemos instalar la App en un dispositivo Android, para lo cual tenemos 2 formas de realizarlo que se explican más adelante


2.10.1. Instalación directa vía USB

Este tipo de instalación se puede realizar en 3 sencillos pasos que se detallan a continuación:

1. Debemos conectar el celular a nuestra computadora y aceptar permisos correspondientes.
2. En Android Studio, dirigimos nuestra atención a la parte superior y seleccionamos la opción "Run App". En este caso, se puede observar que el dispositivo "TECNO CL6" está conectado, como se ilustra en la figura 46.

Figura 46

Run App Para la Instalación



Nota: Elaboración propia.

3. Realizado lo anteriormente mencionado solo debemos esperar que termine el proceso y automáticamente ya se nos instalará y abrirá la App en nuestro dispositivo.

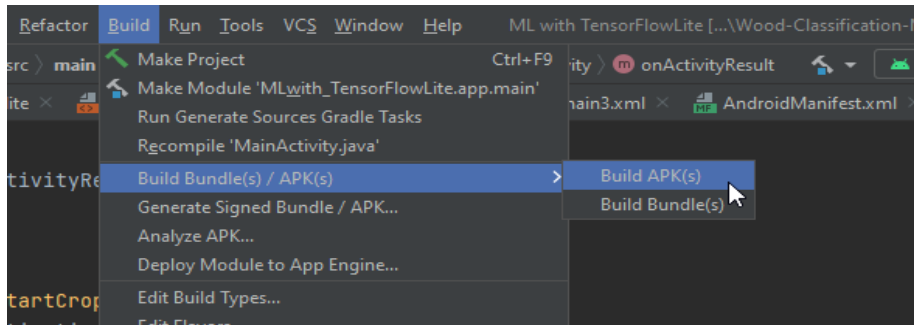
2.10.2. Generación de APK e instalación

Después de terminar con el desarrollo debemos instalar la App en un dispositivo Android, para lo cual tenemos 2 formas de realizarlo que se explican más adelante.

1. Nos vamos a la parte superior, hacemos clic en Build, luego en Build Bundle(s)/APK(s) y, finalmente, en Build APK(s), como se observa en la Figura 47.

Figura 47

Generación de APK




Nota: Elaboración propia.

2. Después de haber realizado el anterior paso esperamos un momento hasta que finalice la generación del APK de instalación que lo podremos encontrar en la siguiente ruta `C:\Users\PC_97\AndroidStudioProjects\Wood-Classification-Model-main\app\build\outputs\apk\debug`, reemplazamos PC_97 por el usuario de nuestra PC y en esa dirección se encontrará el APK generado con el nombre “app-debug.apk”, el APK generado se puede observar en la figura 48.

Figura 48

APK Generado



Nota: Elaboración propia

3. El archivo generado en el paso 2 vamos a copiar o enviar a nuestro dispositivo móvil en el cual vamos a instalar nada más presionado sobre el APK y seleccionando instalar (se tendrá que aceptar algunos permisos y se instalará de forma correcta).

2.11. Funcionalidad de la aplicación instalada

En este subtema se describe las capacidades de funcionamiento que tiene la aplicación, abarcando las tareas que los usuarios podrán realizar desde obtención de información, la captura y carga de imágenes hasta la clasificación de las especies maderables. Esto siempre siendo de la manera más intuitiva y sobre todo facilidad de uso.

2.11.1. Pantalla de inicio instalada

La Figura 49 muestra la pantalla de inicio en funcionamiento en un dispositivo móvil.

Figura 49 *Pantalla de Inicio de la App Funcionando*



Nota: Elaboración propia.

2.11.2. Pantalla de información instalada

En esta pantalla podremos deslizar hacia los lados y podremos ver las imágenes con el nombre de cada especie que fue entrenada en cada una de estas podremos presionar para obtener una pequeña información de cada especie. Se puede observar en la figura 50.

Figura 50 Pantalla de Información Funcionando



Nota: Elaboración propia.

Después de presionar en cada una de las especies como lo anteriormente mencionado podremos obtener información de la especie de madera que deseemos en este caso de Chonta Caspi. Esto se puede observar en la figura 51.

Figura 51 Pantalla de Información de Chonta Caspi




Nota: Elaboración propia.

2.11.3. Pantalla funcionamiento e identificación de especies

La pantalla para capturar y cargar de imágenes tal como se puede ver en la figura 52.

Figura 52 *Pantalla de Identificación de Especies Maderables*



Nota: Elaboración propia.

2.11.4 Herramientas para el uso de la aplicación

Para garantizar un adecuado reconocimiento de las especies maderables mediante el aplicativo móvil, es fundamental el uso de herramientas especializadas que permitan obtener imágenes de alta calidad y precisión. Entre los instrumentos esenciales se encuentran una lupa 10x, un microscopio USB compatible con Android y una cuchilla para corte de madera, a continuación, se dan a conocer estas herramientas,

Cuchilla para corte de madera

Con esta herramienta podremos hacer el corte transversal de la madera que queramos analizar para luego capturar la imagen necesaria para su identificación, se muestra esta herramienta en la figura 53.

Figura 53 *Cuchilla para Corte*



Nota: Elaboración propia.

Lupa 10x

Es una herramienta necesaria que facilita la observación detallada de las características de la madera con la cual podremos capturar directamente las imágenes macroscópicas con la cámara de nuestro celular, a continuación, se muestra la lupa 10x en la figura 54.

Figura 54 *Lupa 10x*



Nota: Elaboración propia.

Microscopio USB para Android

Esta herramienta es ideal para capturar imágenes ampliadas con mayor resolución lo cual le permitirá tener un mejor desempeño a la aplicación móvil, en la figura 55 se puede ver esta herramienta.

Figura 55
Microscopio USB



Nota: Elaboración propia.

2.11.5. Capturas con cámara del celular y lupa 10x

1. Como se muestra en la figura 52 en esa pantalla podremos capturar imágenes desde el botón cámara, la captura tendrá que ser con una lupa de 10x y zoom de 2.5x a 3x para un funcionamiento correcto (Se puede utilizar directamente solo con la cámara en caso de tener un dispositivo con cámara Macro de no ser el caso no se recomienda), se muestra la forma correcta de capturar las imágenes en la figura 56.


Figura 56 *Captura de Imagen con Lupa 10x*



Nota: Elaboración propia.

2. Después de capturar las imágenes tendremos que recortar seleccionando la parte importante de la madera en la imagen con la función Crop integrada en “Wood Identifier UTN” como se puede observar en la figura 57.

Figura 57 *Pantalla de Recorte de Imagen*



Nota. Elaboración propia

3. Luego de haber realizado el anterior paso aceptamos presionando en el check o visto para proceder a la identificación de la madera y mostrar resultados. Tal como se observa en la Figura 58.

Figura 58 *Pantalla de Resultado*



Nota. Elaboración propia.

2.11.6. Capturas con Microscopio USB y uso de la galería

1. Esta vez utilizaremos una aplicación de terceros para lo cual debemos descargar la App MScopes desde la Play Store buscando directamente o desde el siguiente enlace <https://play.google.com/store/apps/details?id=com.zyepro.mobilescopes> que prácticamente es lo mismo.
2. Una vez descargado la aplicación mencionada en el paso 1 procedemos a conectar el microscopio USB en el dispositivo móvil y procedemos a capturar las imágenes de madera como se visualiza en la figura 59.

Figura 59

Captura de Imagen con Microscopio USB



Nota. Elaboración propia.

3. Una vez ya capturadas las imágenes podremos cargarlas desde la galería lo cual nada más seleccionaremos la imagen de la madera y ya nos enviará a la sección de recorte de imagen, debemos recortar la imagen de ser necesario, de no ser el caso solo aceptamos y ya nos mostrará la correcta identificación de reconocimiento de la madera que se puede visualizar en la figura 60.

Figura 60 Resultado con Imagen de Microscopio USB



Nota. Elaboración propia

2.12. Precisión menor a 90%

En cualquier caso, cuando la confianza de reconocimiento sea mayor a 90% nos dará los resultados como se mostró anteriormente pero cuando sea menor no se reconocerá la madera dándonos un mensaje como se muestra en la figura 61, esto sucede por 2 factores, la imagen ingresada no es suficientemente clara o la madera no es una de las entrenadas.

Figura 61 Resultado de Confianza de Precisión Menor a 90%



Nota. Elaboración propia

CAPÍTULO 3

3. Evaluación y validación de resultados

En este capítulo se describe el proceso de validación del aplicativo móvil diseñado para el reconocimiento de cinco especies maderables mediante una red neuronal convolucional. La validación se realizó utilizando el modelo de éxito de sistemas de información propuesto por DeLone y McLean, el cual permite analizar la calidad, el impacto y la efectividad del sistema desde diversas dimensiones.

El propósito de esta sección es garantizar que el aplicativo cumpla con los estándares de calidad esperados, considerando tanto una perspectiva técnica como la experiencia del usuario final. Para ello, se evaluarán distintos aspectos del sistema, como la calidad del sistema, la calidad de la información y la calidad del servicio, además de su impacto en la satisfacción del usuario y los efectos generados.

A través de este proceso de validación, se busca proporcionar una visión integral del desempeño del aplicativo, asegurando que no solo cumpla con los objetivos de la investigación, sino que también sea funcional, confiable y efectivo en la identificación de las especies maderables seleccionadas. Este análisis servirá como base para determinar la viabilidad del sistema en aplicaciones prácticas, así como para identificar áreas de mejora y evaluar su posible adopción en el sector forestal.

3.1. Diseño del instrumento de medición

Para evaluar la efectividad de la implementación del aplicativo móvil desarrollado para el reconocimiento de cinco especies maderables, se diseñó un proceso integral compuesto por diversas fases. Inicialmente se realizó la planificación, seguida por la recolección de datos y finalmente un análisis detallado de la información obtenida junto con la interpretación de los resultados. Este enfoque estructurado garantizó la validez y confiabilidad de las métricas empleadas en la validación del sistema.

3.1.1. Planificación

Durante la fase de planificación del diseño del instrumento de medición, se llevaron a cabo dos actividades fundamentales. En primer lugar, se estableció la unidad de análisis con el objetivo de evaluar el éxito del aplicativo móvil en la identificación de cinco especies maderables, tomando como referencia el modelo de DeLone y McLean. Este enfoque sirvió como base para guiar el proceso de validación.

En segundo lugar, se diseñó el instrumento de recolección de datos, el cual consistió en un cuestionario desarrollado específicamente para este estudio. La estructura del cuestionario se basó en las dimensiones y variables propuestas en el modelo de DeLone y McLean, ajustándolas al contexto del aplicativo móvil. Las preguntas fueron organizadas en una matriz que establece su relación con cada dimensión evaluada, cuyos detalles se presentan en la Tabla 6.

Tabla 6

Análisis de Resultados

Dimensión	Variable	Preguntas
Calidad del sistema	Facilidad de uso	1. ¿La interfaz de la aplicación es fácil de entender y utilizar?
	Estabilidad	2. ¿La aplicación es estable (es decir, no se cierra inesperadamente)?
	Eficiencia	3. ¿La aplicación responde rápidamente a las acciones realizadas?
	Rendimiento	4. ¿El sistema responde de manera rápida y eficiente al cargar o tomar fotos de las especies maderables?
	Precisión	5. ¿El sistema identifica correctamente las especies maderables a partir de las imágenes capturadas?
	Confiabilidad	6. ¿El reconocimiento de especies es preciso y confiable?

Calidad de la información	Claridad	7. ¿Los resultados presentados son claros y fáciles de interpretar?
	Relevancia	8. ¿La información proporcionada por la aplicación es relevante para sus necesidades?
	Visualización	9. ¿La interfaz incluye gráficos, imágenes u otros elementos visuales útiles?
	Detalle	10. ¿La aplicación proporciona detalles útiles como nombres científicos o características visuales de las especies maderables?
Calidad del servicio	Ayuda	11. ¿La aplicación incluye ayuda clara para aprender su uso?
	Soporte	12. ¿La ayuda integrada es útil para resolver dudas comunes?
	Facilidad	13. ¿El diseño de la aplicación reduce la necesidad de soporte técnico al ser intuitivo y fácil de usar?
	Confianza	14. ¿La aplicación fomenta la confianza al ser clara sobre sus limitaciones o resultados?
Intensión de uso	Frecuencia	15. ¿Utilizará la aplicación regularmente para el reconocimiento de especies?
	Intuición	16. ¿Considera la aplicación intuitiva para su uso diario?
	Recomendación	17. ¿Recomendaría esta aplicación a otras personas interesadas en la identificación de especies?
	Adaptabilidad	18. ¿La aplicación satisface sus necesidades actuales y futuras?
	Entorno	19. ¿Qué tan bien se adapta la aplicación a entornos de uso en campo, considerando condiciones como poca iluminación o ruido ambiental?
Satisfacción general	Satisfacción general	20. ¿Está satisfecho con la experiencia general al usar la aplicación?
	Cumplimiento	21. ¿La aplicación cumple con las expectativas que tenía?

Satisfacción del usuario	Continuidad	22. ¿Es probable que continúe utilizando la aplicación en el futuro?
	Facilidad de uso	23. ¿Se siente satisfecho con la facilidad de uso del sistema?
	Calidad general	24. ¿Considera que la calidad general es adecuada para un uso profesional?
Impactos netos	Productividad	25. ¿La aplicación ha mejorado su eficiencia en la identificación de especies maderables?
	Reducción de tiempo	26. ¿Se ha reducido el tiempo necesario para identificar una especie gracias a la aplicación?
	Impacto positivo	27. ¿Considera que la aplicación ha tenido un impacto positivo en su trabajo o estudio?
	Seguridad	28. ¿Se siente más seguro al tomar decisiones basadas en los resultados de la aplicación?
	Influencia	29. ¿Cree que la aplicación puede influir en la industria o en otros usuarios?

Nota. Elaboración propia

3.2. Interpretación de resultados

La interpretación de los resultados es una fase clave dentro del proceso de validación, ya que permite examinar y comprender los datos obtenidos para evaluar el desempeño del aplicativo móvil. En esta sección, se analizan las métricas de evaluación basadas en el modelo de DeLone y McLean, las cuales reflejan el éxito del sistema desde diversas perspectivas.

El análisis de los datos se llevó a cabo considerando cada una de las dimensiones propuestas en el modelo: calidad del sistema, calidad de la información, calidad del servicio, intención de uso, satisfacción del usuario e impactos netos. A partir de este enfoque, se buscó identificar fortalezas, así como posibles limitaciones y oportunidades de mejora en el aplicativo.

3.2.1. *Análisis de datos*

Para examinar los datos obtenidos mediante el cuestionario, se utilizó el software IBM SPSS Statistics 30 en su versión de prueba. El propósito principal de este análisis fue determinar la fiabilidad de las dimensiones del cuestionario y del instrumento de medición en su conjunto.

En este contexto, se aplicó el coeficiente de Cronbach para evaluar la fiabilidad del cuestionario. Este coeficiente es una herramienta estadística ampliamente utilizada para medir la consistencia interna de un conjunto de ítems dentro de un cuestionario o escala. De manera sencilla, este método permite determinar en qué medida los ítems de un instrumento guardan relación entre sí, asegurando que todos evalúan un mismo constructo o dimensión. Un valor cercano a 1 indica una alta consistencia interna, mientras que valores bajos sugieren poca relación entre los ítems, lo que podría comprometer la fiabilidad de la escala.

El coeficiente de Cronbach se calcula mediante la siguiente fórmula:

$$\alpha = \frac{N}{N - 1} \left(1 - \frac{\sum_{i=1}^N \sigma_i^2}{\sigma_t^2} \right)$$

Corresponde a:

α = Coeficiente de Cronbach

N = Cantidad de preguntas del cuestionario

σ_i^2 = varianza de cada pregunta individual

σ_t^2 = varianza total de todas las preguntas combinadas.

Este coeficiente varía entre 0 y 1, y los valores generalmente aceptados para considerar un cuestionario confiable de acuerdo con sus niveles se puede observar en la tabla 7.

Tabla 7
Entregables del Proyecto

Índice	Valor del Coeficiente de Cronbach	Nivel de Fiabilidad
1	0.90 - 1.00	Excelente
2	0.80 - 0.89	Buena
3	0.70 - 0.79	Aceptable
4	0.60 - 0.69	Moderada
5	0.50 - 0.59	Baja
6	< 0.50	Inaceptable

Nota. Elaboración propia

En la Tabla 8 se presentan los datos obtenidos para cada ítem del cuestionario aplicado a un grupo de 30 participantes, incluyendo estudiantes de ingeniería forestal y profesionales del área, como el personal de control forestal de Ibarra. Estos participantes utilizaron el aplicativo móvil para identificar cinco especies maderables.

Las columnas de la tabla corresponden a las preguntas del cuestionario (P), mientras que cada fila representa a un usuario encuestado (E).

Las respuestas fueron recopiladas utilizando una escala de Likert, la cual emplea valores del 1 al 5. En esta escala, el valor 1 representa "Totalmente en desacuerdo", el 2 corresponde a "En desacuerdo", el 3 indica una posición neutral con "Ni de acuerdo ni en desacuerdo", el 4 equivale a "De acuerdo" y el 5 a "Totalmente de acuerdo". Esta metodología facilita la evaluación de la percepción de los usuarios sobre diferentes aspectos del aplicativo móvil, permitiendo interpretar su eficacia y usabilidad.

Tabla 9*Interpretación de Resultado del Alfa de Cronbach*

Estadísticas de Fiabilidad	
Alfa de Cronbach	Número de elementos
,975	29

Nota. Elaboración propia

A partir de los datos obtenidos en la encuesta, se llevó a cabo el cálculo del coeficiente de fiabilidad de Cronbach empleando el software IBM SPSS Statistics 30 en su versión de prueba. Este análisis permitió medir la coherencia interna del cuestionario como instrumento de evaluación del éxito del aplicativo móvil. En la Tabla 9 se presenta el valor resultante del alfa de Cronbach, que fue de 0.975.

El coeficiente alfa obtenido refleja un nivel de fiabilidad considerado como "excelente", lo que indica que los ítems evaluados dentro del cuestionario presentan una alta relación entre sí. Esto respalda la pertinencia de las dimensiones establecidas con base en el modelo de DeLone y McLean, garantizando que el instrumento utilizado sea válido y confiable para la evaluación del desempeño del aplicativo móvil.

Este nivel de confiabilidad reafirma la validez del cuestionario como una herramienta adecuada para recopilar información relevante y evaluar la efectividad del sistema en su contexto de aplicación. De esta manera, los datos obtenidos reflejan de manera precisa el impacto del aplicativo en los usuarios.

A continuación, en la Tabla 10, se presentan los valores estadísticos correspondientes a cada dimensión evaluada en el cuestionario.

Tabla 10
Valores Estadísticos por Dimensión

Dimensión	Preguntas	Media de escala si el elemento se ha suprimido	Varianza de escala si el elemento de ha suprimido	Correlación total de elementos corregida	Alfa de Cronbach si el elemento se ha suprimido
Calidad del sistema	P 1	125,07	188,340	,631	,975
	P 2	125,30	188,700	,340	,978
	P 3	125,17	186,695	,721	,975
	P 4	125,20	184,097	,807	,974
	P 5	125,27	183,513	,722	,975
Calidad de la información	P 6	125,37	188,447	,518	,976
	P 7	125,10	185,886	,787	,974
	P 8	125,13	187,775	,654	,975
	P 9	125,13	184,257	,888	,974
	P 10	125,20	186,028	,764	,974
Calidad del servicio	P 11	125,17	183,385	,852	,974
	P 12	125,30	186,148	,769	,974
	P 13	125,30	185,872	,788	,974
	P 14	125,30	184,286	,807	,974
Intensión de uso	P 15	125,27	185,582	,662	,975
	P 16	125,37	183,895	,778	,974
	P 17	125,20	185,821	,778	,974
	P 18	125,40	183,766	,798	,974
	P 19	125,27	183,513	,778	,974
Satisfacción del usuario	P 20	125,23	184,530	,782	,974
	P 21	125,27	185,444	,730	,975
	P 22	125,20	182,924	,879	,974
	P 23	125,20	182,924	,879	,974
	P 24	125,23	181,702	,877	,974
Impactos netos	P 25	125,20	184,717	,851	,974
	P 26	125,20	184,097	,807	,974
	P 27	125,17	184,902	,840	,974
	P 28	125,27	183,099	,802	,974
	P 29	125,20	184,097	,807	,974

Nota. Elaboración propia

Es importante resaltar que, para garantizar la fiabilidad del instrumento de medición, podrían considerarse ajustes en los ítems del cuestionario. Sin embargo, los valores estadísticos presentados en la Tabla 10, donde el coeficiente alfa de Cronbach muestra una alta consistencia interna en todas las dimensiones analizadas, con valores que oscilan entre 0.973 y 0.974, indican que eliminar ítems no tendría un impacto significativo en la mejora del alfa de Cronbach. Esto sugiere que los ítems actuales contribuyen adecuadamente a la fiabilidad del instrumento.

Estos resultados sugieren que, aunque el instrumento es sólido en su forma actual, sería pertinente evaluar periódicamente la claridad y pertinencia de los ítems, especialmente en dimensiones como "Calidad del sistema" y "Satisfacción del usuario", para garantizar que sigan siendo comprensibles y relevantes para los usuarios. Esta revisión constante permitiría mantener y mejorar la calidad del instrumento, asegurando la precisión en la evaluación de las percepciones y niveles de satisfacción de los usuarios respecto al aplicativo móvil analizado.

3.3. Presentación de resultados

En este apartado se presentan los hallazgos obtenidos tras aplicar el cuestionario diseñado para medir el éxito del aplicativo móvil de reconocimiento de especies maderables, tomando como referencia el modelo de éxito de sistemas de información de DeLone y McLean. Se ofrece una exposición clara y estructurada de los datos, complementada con tablas y gráficos que facilitan la interpretación de las respuestas de los usuarios, así como los valores derivados de los análisis estadísticos. El propósito principal de esta sección es analizar e informar los resultados de manera comprensible, resaltando aspectos clave relacionados con la eficacia, satisfacción y usabilidad del aplicativo en estudio.

3.3.1. Variables del modelo de éxito de S.I de Delone & McLean

Esta sección presenta los hallazgos obtenidos a partir del cuestionario aplicado a los estudiantes de Ingeniería Forestal de la Universidad Técnica del Norte y al personal encargado del control forestal en Ibarra, quienes utilizaron el aplicativo móvil desarrollado para la identificación de cinco especies maderables. Los datos recopilados han sido organizados conforme a las dimensiones establecidas en el modelo de éxito de sistemas de información de

DeLone y McLean, proporcionando una visión estructurada sobre el impacto del sistema en términos de calidad, usabilidad y satisfacción del usuario.


Las respuestas de los participantes fueron registradas utilizando una escala tipo Likert, con valores que oscilan entre 1 y 5. En esta escala, el valor 1 representa "Totalmente en desacuerdo", indicando un bajo nivel de satisfacción, mientras que el valor 5 corresponde a "Totalmente de acuerdo", reflejando una alta satisfacción. Este enfoque permite medir con mayor precisión la percepción de los estudiantes respecto al desempeño y utilidad del aplicativo móvil en función de las dimensiones evaluadas.

Asimismo, se analiza cada dimensión del modelo de DeLone y McLean, estableciendo una relación entre los resultados obtenidos y aspectos clave como la calidad del sistema, la calidad de la información y la satisfacción del usuario, entre otros factores relevantes. Esto proporciona una base sólida para evaluar el impacto del aplicativo en el contexto académico y su posible aplicación en la industria forestal.

3.3.2. *Calidad del sistema*

La calidad del sistema constituye un factor esencial para evaluar el desempeño del aplicativo, tomando en cuenta características como facilidad de uso, estabilidad, eficiencia, precisión y rendimiento. En la Figura 62 se presentan los resultados de esta evaluación, reflejando indicadores clave relacionados con la usabilidad, interactividad y flexibilidad del sistema. Estos aspectos son fundamentales para garantizar una experiencia de usuario óptima entre los estudiantes de Ingeniería Forestal, asegurando que el aplicativo sea intuitivo y funcional para sus necesidades específicas.

Figura 62
Resultado de Dimensión Calidad del Sistema



En el análisis de la calidad del sistema del aplicativo móvil diseñado para el reconocimiento de especies maderables, los resultados evidencian una percepción favorable por parte de los estudiantes de Ingeniería Forestal de la Universidad Técnica del Norte. Respecto a la facilidad de uso, el 93,30% de los encuestados manifestó estar "De acuerdo" o "Totalmente de acuerdo", mientras que un 6,70% expresó una postura neutral. Esto indica que, en general, el aplicativo es percibido como intuitivo y sencillo de manejar.

Respecto a la estabilidad de la aplicación, el 86,70% de los participantes coincidió en que es estable al momento de su funcionamiento, mientras que el 10% adoptó una postura neutral. Un 3,30% de los encuestados, que corresponde a una persona, señaló estar "Totalmente en desacuerdo". Esto podría deberse a una falla de compatibilidad en su dispositivo o al uso excesivo de RAM por otras aplicaciones, lo cual causó que el aplicativo se cerrara.

En términos de eficiencia, el aplicativo recibió una valoración favorable, con un 96,70% de usuarios calificándolo como eficiente al realizar acciones dentro de la aplicación, y un 3,30% manteniendo una percepción neutral.

En cuanto al rendimiento, el 93,40% de los encuestados indicó que la aplicación tiene un buen rendimiento al cargar o tomar fotos de las especies maderables, mientras que un 6,60% tuvo una valoración neutral


Por último, en cuanto a la precisión, el 86,70% de los usuarios valoró la aplicación como precisa al reconocer correctamente las especies maderables, mientras que un 13,30% se mantuvo en una percepción neutral. Esto sugiere que el aplicativo tiene una alta precisión en el reconocimiento de especies.

Aunque los resultados son mayormente positivos, un pequeño porcentaje de usuarios expresó desacuerdo con la precisión de la aplicación. Esto podría deberse a que las imágenes capturadas no fueron lo suficientemente claras o a que la aplicación presenta un grado de confusión al reconocer especies con estructuras muy similares a las de otras especies que puede identificar. A futuro, esto se podría mejorar agregando más especies al sistema para que el aplicativo pueda diferenciar con mayor detalle entre ellas y de este modo ser más preciso.

3.3.3. Calidad de la información

La evaluación de la calidad de la información en el aplicativo móvil desarrollado consideró aspectos clave como confiabilidad, claridad, relevancia, visualización y nivel de detalle. En la Figura 63 se muestran los resultados obtenidos, resaltando que los datos proporcionados por el sistema son precisos, claros y pertinentes para las necesidades de los estudiantes de Ingeniería Forestal. Esto garantiza que la información entregada sea útil y adecuada para cumplir con los objetivos educativos y técnicos del aplicativo, asegurando su efectividad y alineación con los requerimientos de los usuarios.

Figura 63
Resultado de Dimensión Calidad de la Información



Evaluando esta dimensión sobre el aplicativo móvil para el reconocimiento de especies maderables, se obtuvieron resultados mayoritariamente positivos. Según los datos, el 90% de los estudiantes encuestados consideró que el reconocimiento de especies es confiable, con un 10% manteniendo una postura neutral.

En cuanto a la claridad de la información, un 96,70% calificó los resultados de la aplicación como fáciles de interpretar, mientras que un 3,30% se mostró neutral respecto al entendimiento de los datos.

En términos de relevancia de la información, el 60% de los usuarios indicó estar "Totalmente de acuerdo", el 33,30% "De acuerdo" y el 3,30% se mostró "Neutral", reflejando una percepción muy favorable. La visualización de la información obtuvo resultados similares, con un 60% de "Totalmente de acuerdo", un 33,30% de "De acuerdo" y un 3,30% "Neutral".


En relación con el nivel de detalle de la información, el 53,40 % de los participantes manifestó estar "Totalmente de acuerdo", mientras que el 43,30 % indicó estar "De acuerdo" y un 3,30 % expresó una postura neutral.

En general, los resultados reflejan un alto nivel de satisfacción respecto a la calidad de la información proporcionada por el sistema. No obstante, se identifica la necesidad de atender los aspectos que generan una percepción neutral, con el objetivo de seguir mejorando la calidad informativa ofrecida. Esto contribuirá a optimizar la experiencia de los usuarios y aumentar la efectividad del sistema.

3.3.4. Calidad del servicio

La calidad del servicio del aplicativo móvil fue evaluada considerando aspectos como el soporte, la confianza y la facilidad de uso ofrecidos por la plataforma. Los resultados, presentados en la Figura 64, subrayan factores clave relacionados con la confianza y la asistencia brindadas por el sistema. Estos elementos son fundamentales para asegurar una experiencia positiva para los usuarios y un aprovechamiento óptimo de la aplicación.

Figura 64
Resultado de Dimensión Calidad del Servicio



Los resultados obtenidos indican un alto nivel de satisfacción respecto a la calidad del servicio proporcionado por la aplicación. El 93,30 % de los usuarios encuestados manifestó estar de acuerdo o totalmente de acuerdo en que la aplicación es efectiva para resolver dudas o problemas, mientras que un 6,70 % expresó una postura neutral. Además, el 96,70 % consideró que la ayuda integrada en la aplicación es útil, con solo un 3,30 % mostrando una opinión neutral.

En cuanto a la necesidad de soporte técnico debido al fácil uso de la aplicación, el 43,40% de los participantes estuvo totalmente de acuerdo, el 53,30% estuvo de acuerdo y un 3,30% se mantuvo neutral. Por último, respecto a la confianza en la calidad del servicio, el 93,40% estuvo "De acuerdo" o "Totalmente de acuerdo", y un 6,70% respondió neutral.


En general, los resultados muestran que los usuarios valoran positivamente la ayuda y confianza ofrecidas por la aplicación, ya que más del 90 % de los encuestados expresó conformidad con estos aspectos. No obstante, un pequeño grupo indicó una postura neutral o de desacuerdo, sugiriendo oportunidades de mejora para optimizar la experiencia del usuario. Atender estas percepciones podría contribuir a aumentar la calidad del servicio y la satisfacción global de los usuarios.

3.3.5. *Intensión de uso/uso*

Esta sección aborda el propósito del usuario al emplear las funcionalidades de la aplicación. Para analizar esta variable, se consideran factores como la frecuencia de uso, la facilidad de interacción con el sistema, las recomendaciones realizadas por los usuarios, la adaptabilidad y el entorno donde se utiliza la aplicación.

En la Figura 65 se presentan los datos obtenidos en la evaluación de la intención de uso, destacando aspectos como el alcance del uso, la recomendación para emplearla y el propósito con que es utilizada. Estos resultados permiten entender la disposición de los usuarios para continuar utilizando la aplicación, así como las razones detrás de su uso, lo que aporta información valiosa para mejorar la funcionalidad del sistema en futuras actualizaciones.

Figura 65
Resultado de Dimensión Intensión de Uso



En cuanto a la frecuencia de uso de la aplicación, los resultados muestran una alta aceptación por parte de los encuestados. El 90% de los participantes está de acuerdo o totalmente de acuerdo en que la aplicación será utilizada regularmente, mientras que un 10% se mantiene neutral. Asimismo, el 90% considera que la aplicación es intuitiva para el uso diario, y un 10% adoptó una postura neutral.


Respecto a la recomendación de uso, el 53,40% de los encuestados expresó estar totalmente de acuerdo, el 43,30% estuvo de acuerdo, y un 3,30% se mostró neutral. En cuanto a la adaptabilidad de la aplicación, el 90% se mostró de acuerdo o totalmente de acuerdo, mientras que el 10% permaneció neutral. Finalmente, en relación al entorno de uso en campo, el 90% de los participantes estuvo de acuerdo o totalmente de acuerdo, y el 10% adoptó una postura neutral.

En términos generales, más del 89% de los encuestados manifiestan una alta aceptación y utilidad de la aplicación para el reconocimiento de especies maderables, lo que refleja una fuerte intención de uso. La mayoría considera que el sistema será utilizado regularmente y lo recomendaría, lo que sugiere que la aplicación es vista como una herramienta útil.

3.3.6. Satisfacción del usuario

En la Figura 66 se muestran los datos obtenidos tras evaluar la satisfacción del usuario, este análisis incluye aspectos clave como el nivel general de satisfacción, el cumplimiento, la continuidad, la facilidad de uso y la percepción de calidad del servicio ofrecido.

Figura 66
Resultado de Dimensión Satisfacción del Usuario



La Figura 63 presenta los hallazgos obtenidos en la evaluación de la satisfacción de los usuarios, considerando elementos clave como la conformidad con el proceso de la aplicación para identificar especies maderables, el cumplimiento de sus expectativas, la facilidad de uso y la calidad de la información proporcionada por la aplicación móvil.

Los hallazgos derivados de la evaluación de los efectos generales de la aplicación evidencian beneficios significativos en diversos aspectos importantes. El 96,70% de los encuestados destacó que la aplicación ha mejorado la eficiencia al reconocer especies maderables. Además, el 93,40% resaltó que la aplicación optimiza el tiempo en la identificación de maderas. En este sentido, el 96,70% de los usuarios coincidió en que la aplicación genera un efecto favorable tanto en contextos laborales como académicos, facilitando una experiencia más eficaz.


Los hallazgos reflejan un alto nivel de satisfacción por parte de los usuarios, donde el 93,30% expresó estar "De acuerdo" o "Totalmente de acuerdo" con la eficacia de la aplicación al identificar cinco tipos de madera. El 93,30% de los participantes concordó en que la aplicación satisface sus expectativas en términos de utilidad, mientras que el 93,40% afirmó su intención de seguir utilizándola.

Con respecto a la facilidad de uso, el 96,70% de los encuestados declaró estar conforme, y el 90% destacó la calidad de la aplicación en aplicaciones profesionales. En resumen, más del 89% de los participantes señalaron estar satisfechos con el sistema, lo que demuestra que la aplicación ha logrado responder a las expectativas de los usuarios.

3.3.7. Impactos Netos

La Figura 67 muestra los resultados obtenidos en la evaluación "Impactos Netos", destacando aspectos clave como la productividad, reducción de tiempo, impacto positivo, seguridad e influencia proporcionados por la aplicación. Estos factores reflejan cómo el uso de la aplicación contribuye positivamente a la eficiencia y efectividad en el reconocimiento de especies maderables.

Figura 67
Resultado de la Dimensión Impactos Netos



Los hallazgos derivados de la evaluación de los impactos netos de la aplicación evidencian beneficios significativos en diversos aspectos importantes. El 96,70% de los encuestados destacó que la aplicación ha mejorado la eficiencia al reconocer especies maderables. Además, el 93,40% resaltó que la aplicación optimiza el tiempo en la identificación de maderas. En este sentido, el 96,70% de los usuarios coincidió en que la aplicación genera un efecto favorable tanto en contextos laborales como académicos, facilitando una experiencia más eficaz.

Respecto a la fiabilidad en la toma de decisiones fundamentadas en los resultados proporcionados por la aplicación, el 90% de los participantes manifestó satisfacción con su desempeño. Asimismo, el 93,40% indicó estar "De acuerdo" o "Totalmente de acuerdo" en que la aplicación impacta positivamente tanto en el sector industrial como en sus usuarios. Estos resultados reflejan una mejora significativa en la productividad y reducción de tiempo, lo cual es notable para los usuarios en la

identificación de especies maderables. En general, los datos sugieren que la aplicación tiene un impacto neto positivo, alcanzando un 90% o más de aceptación en todos los aspectos evaluados.

3.4. Análisis de favorabilidad y desfavorabilidad

Para medir cómo perciben los usuarios las diferentes dimensiones del sistema, se realizó un análisis de favorabilidad y desfavorabilidad. Este proceso considera las respuestas de los encuestados de la siguiente manera:

- Las opciones "**En desacuerdo**" o "**Totalmente en desacuerdo**" indican una percepción desfavorable respecto a la dimensión evaluada.
- Las opciones "**De acuerdo**" o "**Totalmente de acuerdo**" reflejan una percepción favorable.
- Las respuestas neutrales o poco definidas se clasifican dentro de la categoría de indecisión.

Este enfoque permite obtener una visión más precisa de la percepción de los usuarios sobre cada dimensión, facilitando la identificación de áreas que requieren mejoras o ajustes. En los resultados obtenidos (ver Tabla 11), esta categorización ayuda a brindar una comprensión más detallada de la satisfacción general.

Tabla 11
Análisis de Favorabilidad

Dimensión	Favorabilidad	Indecisión	Desfavorabilidad
Calidad del Sistema	91,36%	7,98%	0,66%
Calidad de la Información	95,36%	4,64%	0%
Calidad del Servicio	95,025%	4,975%	0%
Intensión de Uso	91,34%	8,66%	0%
Satisfacción del Usuario	93,34%	6,66%	0%
Impactos Netos	94,04%	5,96%	0%

Nota: Elaboración Propia

En la Tabla 11 se evidencia que todas las dimensiones evaluadas del aplicativo móvil presentan un alto nivel de favorabilidad. Se destacan especialmente la calidad de la información (95,36%) y la calidad del servicio (95,025%), sin registrar valores de desfavorabilidad y con bajos niveles de indecisión (4,64% y 4,975%, respectivamente).

La percepción sobre la calidad del sistema es mayormente positiva, alcanzando un 91,36%. Sin embargo, se observa un nivel de indecisión ligeramente superior (7,98%) y una mínima desfavorabilidad (0,66%). Esto indica que, aunque la mayoría de los usuarios expresaron satisfacción con la calidad del sistema, un pequeño porcentaje manifestó ciertas inquietudes respecto a su desempeño.

En relación con la intención de uso, esta dimensión muestra un 91,34% de favorabilidad, pero también el índice más alto de indecisión (8,66%). Esto sugiere que algunos usuarios aún tienen dudas sobre la continuidad en el uso del sistema, posiblemente debido a experiencias previas o expectativas no completamente alcanzadas.

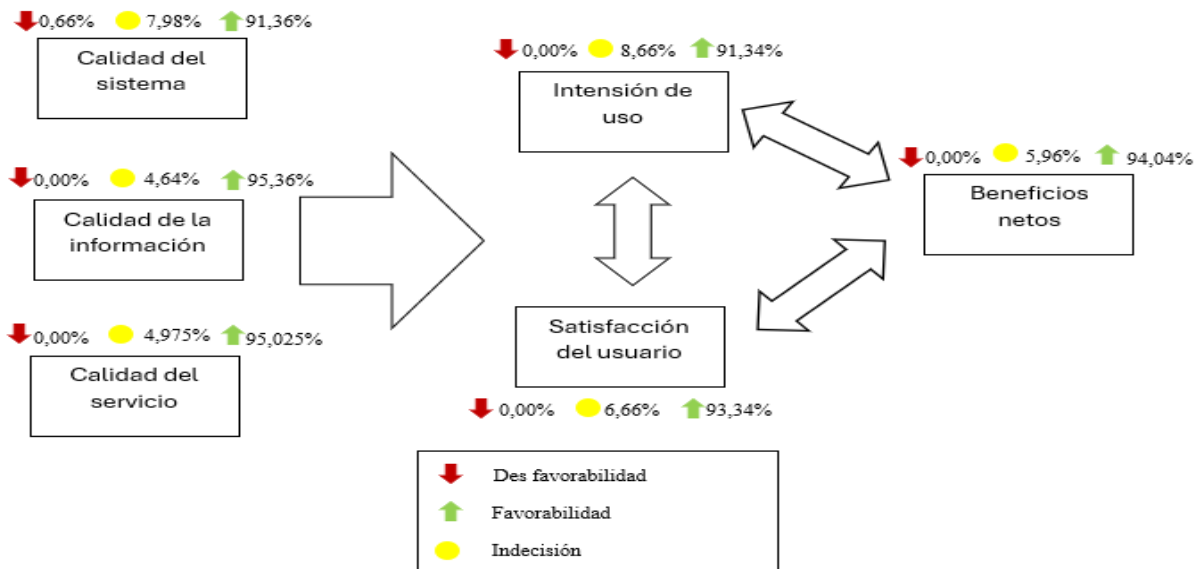
Por otro lado, la satisfacción del usuario es mayormente positiva, con un 93,34%, mientras que la indecisión se mantiene en un nivel moderado (6,66%) y no se registran valores de desfavorabilidad. Esto sugiere que, aunque en general los usuarios perciben la aplicación de manera favorable, aún existen oportunidades para mejorar y alcanzar una plena satisfacción.

Finalmente, los impactos netos reflejan un 94,04% de favorabilidad y solo un 5,96% de indecisión, lo que muestra una percepción clara de valor y beneficio que los usuarios atribuyen al sistema.

En resumen, el análisis evidencia una percepción muy positiva en todas las dimensiones evaluadas. No obstante, las principales áreas de mejora están en reducir la indecisión, especialmente en intención de uso y calidad del sistema, con el fin de aumentar la claridad de las expectativas de los usuarios y mejorar su confianza en la aplicación.

Figura 68

Diagrama de Favorabilidad y Desfavorabilidad



Nota: Adaptado de (Quelopana et al., 2018b).

El análisis del gráfico muestra que todas las dimensiones evaluadas presentan una alta favorabilidad, con porcentajes superiores al 91 %. Destacan especialmente la calidad de la información (95,36 %) y la calidad del servicio (95,025 %) como los aspectos más valorados. La indecisión se mantiene en niveles moderados, oscilando entre el 4,64 % y el 8,66 %, siendo más evidente en la intención de uso. Esto sugiere posibles áreas de mejora para incrementar la claridad y confianza de los usuarios. La percepción desfavorable es prácticamente inexistente, con valores que varían entre el 0 % y el 0,66 %, lo que indica que las opiniones negativas son mínimas.

En general, los resultados reflejan una percepción ampliamente favorable del sistema, la calidad de la información, el servicio, la satisfacción del usuario, los impactos netos y la intención de uso, con oportunidades para reducir aún más la indecisión.

CONCLUSIONES

1. La revisión del estado del arte permitió identificar los avances más relevantes en técnicas y tecnologías relacionadas con el reconocimiento de especies maderables, destacando la efectividad de las redes neuronales convolucionales (CNN) en tareas de clasificación y análisis de imágenes. Este análisis proporcionó la base teórica necesaria para la implementación del aplicativo móvil, garantizando que las metodologías y herramientas seleccionadas estuvieran alineadas con los estándares actuales en el ámbito de la inteligencia artificial y la gestión forestal.
2. El desarrollo del aplicativo móvil cumplió con los objetivos planteados, integrando de manera eficiente una red neuronal convolucional capaz de identificar con precisión las cinco especies maderables seleccionadas. El sistema presenta una interfaz amigable, fácil de usar y accesible, diseñada para facilitar el uso por parte de investigadores, estudiantes y profesionales del sector forestal. La implementación de este sistema representa una solución tecnológica práctica que promueve el manejo sostenible de los recursos forestales y fortalece la identificación rápida y precisa de especies.
3. El aumento en la cantidad de imágenes por especie dentro del conjunto de datos fue un aspecto clave para mejorar el rendimiento de la red neuronal. Este ajuste permitió superar las limitaciones iniciales, reflejadas en métricas insuficientes, y logró incrementar de manera significativa la precisión del modelo. Este resultado muestra la importancia de contar con un conjunto de datos amplio y diverso en el entrenamiento de redes neuronales, demostrando que una mayor cantidad de muestras fortalece la capacidad del modelo para generalizar y desempeñarse con mayor eficacia en tareas de clasificación.
4. La evaluación del aplicativo, basada en el modelo de DeLone y McLean, mostró resultados sumamente positivos. Se obtuvieron índices de favorabilidad superiores al 91%, lo que valida la eficiencia y aceptación del sistema entre los usuarios destacando aspectos como la calidad del sistema, la calidad de la información y la calidad del servicio. Además, los datos recogidos permitieron identificar áreas de mejora, como la necesidad de reducir la indecisión en la intención de uso y así poder optimizar futuras versiones del aplicativo, con el objetivo de mejorar aún más la experiencia del usuario.

RECOMENDACIONES

1. Se recomienda continuar actualizando periódicamente información, incorporando las investigaciones más recientes en redes neuronales y técnicas de reconocimiento de especies maderables. Es crucial explorar estas innovaciones para mejorar la precisión, eficiencia y capacidad general del modelo. Mantener una revisión constante y profunda de los avances permitirá identificar tendencias emergentes y adaptar las soluciones tecnológicas de manera proactiva, asegurando que el modelo se mantenga actualizado, competitivo y altamente efectivo en el reconocimiento de especies maderables, incluso en condiciones desafiantes o con especies adicionales.
2. Se sugiere realizar pruebas de usabilidad adicionales con una variedad más amplia de usuarios en el sector forestal, incluidos aquellos con menos experiencia tecnológica. Esto permitirá identificar posibles barreras en el uso del sistema y ajustar la interfaz para que sea aún más accesible y eficiente, garantizando que el aplicativo sea adoptado por un público más amplio, incluyendo aquellos en áreas rurales o de difícil acceso.
3. Para mejorar aún más la precisión y aplicabilidad del modelo, se recomienda expandir el conjunto de datos de entrenamiento incluyendo una mayor diversidad de especies maderables. Incluir más especies de madera permitirá que el modelo sea más robusto y generalizable, aumentando su capacidad para reconocer una variedad más amplia de especies en condiciones diversas. Además, el entrenamiento con un conjunto de datos ampliado contribuirá a reducir posibles sesgos y mejorar el desempeño en casos donde las especies maderables sean visualmente similares o donde las condiciones de captura de las imágenes varíen considerablemente.
4. Se recomienda emplear el uso del microscopio USB compatible con Android para capturar imágenes con la mayor nitidez y claridad posible lo que minimiza los errores en la identificación de especies. Es preferible evitar el uso directo de la cámara del teléfono y uso con lupas de 10x, ya que la calidad de las imágenes puede variar significativamente entre modelos de celulares, afectando la exactitud del sistema.

BIBLIOGRAFÍA

- Ahmed, M., Afreen, N., Ahmed, M., Sameer, M., & Ahamed, J. (2023). An inception V3 approach for malware classification using machine learning and transfer learning. *International Journal of Intelligent Networks*, 4, 11–18. <https://doi.org/10.1016/j.ijin.2022.11.005>
- Aljabri, M., AlAmir, M., AlGhamdi, M., Abdel-Mottaleb, M., & Collado-Mesa, F. (2022). Towards a better understanding of annotation tools for medical imaging: a survey. *Multimedia Tools and Applications*, 81(18), 25877–25911. <https://doi.org/10.1007/s11042-022-12100-1>
- Alpuente, H., Luis, L. E., & Juan, M. R. (2014). *Caracterización automática de especies de madera mediante técnicas de clasificación de imágenes*.
- Andrade, H., Sinche Maita, S., & Hidalgo Lascano, P. (2021). Modelo para detectar el uso correcto de mascarillas en tiempo real utilizando redes neuronales convolucionales. *Revista de Investigación En Tecnologías de La Información*, 9(17), 111–120. <https://doi.org/10.36825/riti.09.17.011>
- Atila, Ü., Uçar, M., Akyol, K., & Uçar, E. (2021). Plant leaf disease classification using EfficientNet deep learning model. *Ecological Informatics*, 61. <https://doi.org/10.1016/j.ecoinf.2020.101182>
- Bhavsar, K. A., Abugabah, A., Singla, J., AlZubi, A. A., Bashir, A. K., & Nikita. (2021). A comprehensive review on medical diagnosis using machine learning. *Computers, Materials and Continua*, 67(2), 1997–2014. <https://doi.org/10.32604/cmc.2021.014943>
- Booth, P., Maxwell, I., & Schork, T. (2017). *Timber 4.0: A Computer-Vision Approach for Visual Grading Low-Grade Plantation* (Issue 51).
- Chakrabarti, S., Saha, H. N., Institute of Electrical and Electronics Engineers. New York Section, Institute of Electrical and Electronics Engineers. Region 1, IEEE-USA, Columbia University, & Institute of Electrical and Electronics Engineers. (2019). *Thin MobileNet: An Enhanced MobileNet Architecture*.
- Dassot, M., Constant, T., & Fournier, M. (2021). The use of terrestrial LiDAR technology in forest science: Application fields, benefits and challenges. *Annals of Forest Science*, 68(5), 959–974. <https://doi.org/10.1007/s13595-011-0102-2>
- Dey, N., Zhang, Y. D., Rajinikanth, V., Pugalenth, R., & Raja, N. S. M. (2021). Customized VGG19 Architecture for Pneumonia Detection in Chest X-Rays. *Pattern Recognition Letters*, 143, 67–74. <https://doi.org/10.1016/j.patrec.2020.12.010>

- Durkee, M. S., Abraham, R., Clark, M. R., & Giger, M. L. (2021). Artificial Intelligence and Cellular Segmentation in Tissue Microscopy Images. In *American Journal of Pathology* (Vol. 191, Issue 10, pp. 1693–1701). Elsevier Inc. <https://doi.org/10.1016/j.ajpath.2021.05.022>
- Acero, J., & Linares, M. : (2020). *Empirical Testing for Establishing Benchmarks: Process Review and Comparison Between Java, Kotlin and Dart's Performance*.
- Fadlilah, U., Mahamad, A. K., & Handaga, B. (2021). The Development of Android for Indonesian Sign Language Using Tensorflow Lite and CNN: An Initial Study. *Journal of Physics: Conference Series*, 1858(1). <https://doi.org/10.1088/1742-6596/1858/1/012085>
- Fassnacht, F. E., White, J. C., Wulder, M. A., & Næsset, E. (2023). Remote sensing in forestry: current challenges, considerations and directions. *Forestry: An International Journal of Forest Research*. <https://doi.org/10.1093/forestry/cpad024>
- Putra, F., Ajie, H., Safitri, I. A., & Jakarta. (2021). Designing A User Interface and User Experience from Piring Makanku Application by Using Figma Application for Teens. *International Journal of Information System & Technology Akreditasi*, 5(3), 308–315. <https://www.figma.com/design/>
- Figuroa, G., Valverde, J., & Arias, D. (2018). *Automated Image-based Identification of Forest Species: Challenges and Opportunities for 21st Century Xylotheques*.
- Fuentes, C., & Zacarías, B. (2023, September 28). *Biometría facial: La evolución de la autenticación de tus clientes - Legalarío*. <https://legalario.com/blog/biometria-facial-la-evolucion-de-la-autenticacion-de-tus-clientes/>
- Gajewski, M. (2023, April 7). *Meta podzielita się z naukowcami ważną technologią. Co potrafi SI właściciela Facebooka?* <https://spidersweb.pl/2023/04/meta-rozpoznawanie-obrazu.html>
- Guan, Q., Wang, Y., Ping, B., Li, D., Du, J., Qin, Y., Lu, H., Wan, X., & Xiang, J. (2019). Deep convolutional neural network VGG-16 model for differential diagnosing of papillary thyroid carcinomas in cytological images: A pilot study. *Journal of Cancer*, 10(20), 4876–4882. <https://doi.org/10.7150/jca.28769>
- Hagos, T. (2018). Android Studio. In *Learn Android Studio 3* (pp. 5–17). Apress. https://doi.org/10.1007/978-1-4842-3156-2_2

- Hansen, U. S., Landau, E., Patel, M., & Hayee, B. (2021). Novel artificial intelligence-driven software significantly shortens the time required for annotation in computer vision projects. *Endoscopy International Open*, 09(04), E621–E626. <https://doi.org/10.1055/a-1341-0689>
- Irigaray, M. (2021). *Inteligencia Artificial para Reconocimiento Visual*. <https://www.ideati.net/blog/ia-computer-vision/>
- Dalmasso, I., Soumya Kanti Datta, Christian Bonnet, & Navid Nikaein. (2022). *9th International Wireless Communications and Mobile Computing Conference (IWCMC), 2013 1-5 July 2013, Cagliari, Sardinia, Italy*.
- Izko, X., & Burneo, D. (2018). *Herramientas para la valoración y manejo forestal sostenible de los bosques sudamericanos*.
- Jahandad, Sam, S. M., Kamardin, K., Amir Sjarif, N. N., & Mohamed, N. (2019). Offline signature verification using deep learning convolutional Neural network (CNN) architectures GoogLeNet inception-v1 and inception-v3. *Procedia Computer Science*, 161, 475–483. <https://doi.org/10.1016/j.procs.2019.11.147>
- Joy, A., Siddiqua, A., Islam, Md. N., & Chowdhury, M. (2023). *Automated Parkinson's Disease Detection from Brain MRI Images Using Deep Convolutional Neural Network*. <https://doi.org/10.1109/ICCIT60459.2023.10441102>
- Kaya, Y., & Gürsoy, E. (2023). A MobileNet-based CNN model with a novel fine-tuning mechanism for COVID-19 infection detection. *Soft Computing*, 27(9), 5521–5535. <https://doi.org/10.1007/s00500-022-07798-y>
- Khalid, M., Lew, E., Lee, Y. I., Yusof, R., & Nadaraj, M. (2008). *DESIGN OF AN INTELLIGENT WOOD SPECIES RECOGNITION SYSTEM*. 9(3).
- Khasoggi, B., Ermatita, & Samsuryadi. (2019). Efficient mobilenet architecture as image recognition on mobile and embedded devices. *Indonesian Journal of Electrical Engineering and Computer Science*, 16(1), 389–394. <https://doi.org/10.11591/ijeecs.v16.i1.pp389-394>
- Kumar, N., Belhumeur, P. N., Biswas, A., Jacobs, D. W., Kress, W. J., Lopez, I. C., & Soares, J. V. B. (2022). *LNCS 7573 - Leafsnap: A Computer Vision System for Automatic Plant Species Identification*. <http://leafsnap.com/code/>

- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. In *Nature* (Vol. 521, Issue 7553, pp. 436–444). Nature Publishing Group. <https://doi.org/10.1038/nature14539>
- Li, B., & He, Y. (2018). An Improved ResNet Based on the Adjustable Shortcut Connections. *IEEE Access*, 6, 18967–18974. <https://doi.org/10.1109/ACCESS.2018.2814605>
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. In *Sensors (Switzerland)* (Vol. 18, Issue 8). MDPI AG. <https://doi.org/10.3390/s18082674>
- Liu, Z., John, J., & Agu, E. (2022). Diabetic Foot Ulcer Ischemia and Infection Classification Using EfficientNet Deep Learning Models. *IEEE Open Journal of Engineering in Medicine and Biology*, 3, 189–201. <https://doi.org/10.1109/OJEMB.2022.3219725>
- Lu, Z., Bai, Y., Chen, Y., Su, C., Lu, S., Zhan, T., Hong, X., & Wang, S. (2020). The classification of gliomas based on a Pyramid dilated convolution resnet model. *Pattern Recognition Letters*, 133, 173–179. <https://doi.org/10.1016/j.patrec.2020.03.007>
- Machado, J. S., Pereira, F., & Quilhó, T. (2019). Assessment of old timber members: Importance of wood species identification and direct tensile test information. *Construction and Building Materials*, 207, 651–660. <https://doi.org/10.1016/j.conbuildmat.2019.02.168>
- Mantilla, N., Ruiz Jiménez, L., Ortega Boada, H., & Sepúlveda Sepúlveda, A. (2021). *Identificación de especies de maderas locales mediante el uso de nariz electrónica y aprendizaje automático: Un experimento preliminar*. <https://doi.org/10.17981/ingecuc.17.1.2021.15>
- Saavedra, Matías., Andrés, C., Francisco, C., & Pablo, G. (2020). *Implementación de un sistema de detección de residuos reciclables basado en visión computacional*.
- Mio, R. Pool., & Mejia, Ivan. (2022). *Comparación de algoritmos de aprendizaje supervisado para la clasificación automática de madera aserrada mediante procesamiento de imágenes digitales*. <https://orcid.org/0000-0002-9800-5445>
- Montero, E., Figueroa, G., Arias, D., Valverde, J., Zamora, N., Paniagua, J., & López, S. (2020). *Identificación automática de especies forestales maderables amenazadas de Costa Rica, mediante técnicas de visión artificial*.

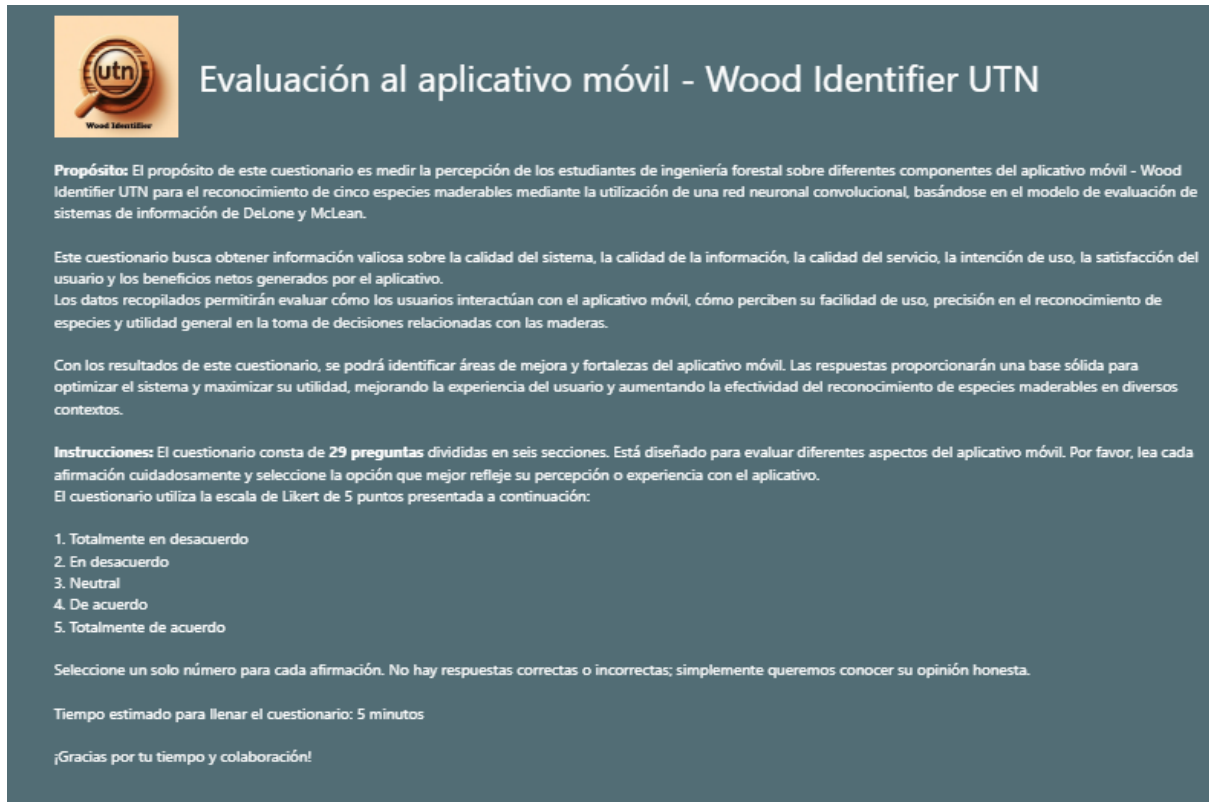
- Muellner, A. N., Schaefer, H., & Lahaye, R. (2011). Evaluation of candidate DNA barcoding loci for economically important timber species of the mahogany family (Meliaceae). *Molecular Ecology Resources*, 11(3), 450–460. <https://doi.org/10.1111/j.1755-0998.2011.02984.x>
- Neena, A., & Geetha. (2017). *Proceedings of the 2017 IEEE International Conference on Communication and Signal Processing (ICCSP) : 6th-8th April, 2017, Melmaruvathur, India.*
- Niso, G., Botvinik-Nezer, R., Appelhoff, S., De La Vega, A., Esteban, O., Etzel, J. A., Finc, K., Ganz, M., Gau, R., Halchenko, Y. O., Herholz, P., Karakuzu, A., Keator, D. B., Markiewicz, C. J., Maumet, C., Pernet, C. R., Pestilli, F., Queder, N., Schmitt, T., ... Rieger, J. W. (2022). Open and reproducible neuroimaging: From study inception to publication. In *NeuroImage* (Vol. 263). Academic Press Inc. <https://doi.org/10.1016/j.neuroimage.2022.119623>
- Ojha, U., Adhikari, U., & Singh, D. K. (2017). *Image Annotation Using Deep Learning: A Review.*
- Rafique, D., & Velasco, L. (2018). Machine learning for network automation: Overview, architecture, and applications [Invited Tutorial]. *Journal of Optical Communications and Networking*, 10(10), D126–D143. <https://doi.org/10.1364/JOCN.10.00D126>
- Raschka, S., Patterson, J., & Nolet, C. (2020). Machine learning in python: Main developments and technology trends in data science, machine learning, and artificial intelligence. In *Information (Switzerland)* (Vol. 11, Issue 4). MDPI AG. <https://doi.org/10.3390/info11040193>
- Jambe, K., & Yogyakarta, B. (2020). *The 3 rd ISRITI 2020 STMIK AKAKOM YOGYAKARTA.* www.isriti.akakom.ac.id
- Reascos, I. (2020). *ThesisPDTSI_IrvingReascos_1.*
- Ramírez, R. (2019). *Evaluación del módulo de Recursos Humanos del Enterprise Resource Planning (ERP) en una empresa colombiana usando el modelo de Delone y Mclean.*
- Roboflow. (2024). *Roboflow: Computer vision tools for developers and enterprises.* <https://roboflow.com/>
- Romero, & Caicedo. (2022). Deep learning model based on MobileNetV2 for mask detection with Raspberry Pi. *2022 IEEE Colombian Conference on Applications of Computational Intelligence, ColCACI 2022 - Proceedings.* <https://doi.org/10.1109/ColCACI56938.2022.9905388>


- Romo, R. (2021). *Clasificación De Imágenes 2/2*. <https://rubenjromo.com/clasificacion-de-imagenes-2/>
- Rybczak, M., & Kozakiewicz, K. (2023). *Deep Machine Learning of the MobileNet, Efficient and Inception Models*. <https://doi.org/10.20944/preprints202311.2003.v1>
- Sarwinda, D., Paradisa, R. H., Bustamam, A., & Anggia, P. (2021). Deep Learning in Image Classification using Residual Network (ResNet) Variants for Detection of Colorectal Cancer. *Procedia Computer Science*, 179, 423–431. <https://doi.org/10.1016/j.procs.2021.01.025>
- Schmitt, M., Brück, A., Schönberger, J., & Stilla, U. (2023). Potential of Airborne Single-Pass Millimeterwave InSAR Data for Individual Tree Recognition. In *DGPF Tagungsband (Vol. 22)*. <http://www.pf.bv.tum.de>
- Si, C., Yu, W., Zhou, P., Zhou, Y., Wang, X., & Yan, S. (2022). *Inception Transformer*. <https://github.com/sail-sg/iFormer>.
- Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*.
- Sjödin, D., Parida, V., Palmié, M., & Wincent, J. (2021). How AI capabilities enable business model innovation: Scaling AI through co-evolutionary processes and feedback loops. *Journal of Business Research*, 134, 574–587. <https://doi.org/10.1016/j.jbusres.2021.05.009>
- Sonya, A., Zachary, T., & Maya, C. (2015). *Robotics and Automation (ICRA), 2015 IEEE International Conference on : date, 26-30 May 2015*.
- Sun, C., Songhao, Z., & Zhe, S. (2015). *IAPR MVA 2015 proceedings of the fourteenth IAPR International Conference on Machine Vision Applications : May 18-22, 2015, Miraikan, Tokyo, Japan*. Institute of Electrical and Electronics Engineers.
- Vedaldi, A., & Zisserman, A. (2016). *VGG Convolutional Neural Networks Practical*. <http://www.robots.ox.ac.uk/~vgg/practicals/cnn/index.html#part-31-traini...>
- Zepeda, Quelopana, A., Flores, C., & Munizaga, A. (2018a). Application guide for the evaluation of software products based on the delone and McLean model of success. *RISTI - Revista Iberica de Sistemas e Tecnologias de Informacao*, 29, 14–29. <https://doi.org/10.17013/risti.29.14-29>

- Quelopana, Flores, C., & Munizaga, A. (2018b). Application guide for the evaluation of software products based on the delone and McLean model of success. *RISTI - Revista Iberica de Sistemas e Tecnologias de Informacao*, 29, 14–29. <https://doi.org/10.17013/risti.29.14-29>
- Voeikov, R., Falaleev, N., & Baikulov, R. (2020). *TNet: Real-time temporal and spatial video analysis of table tennis*. <https://lab.osai.ai/datasets/openttgames>
- Wang, Y., Zhang, W., Gao, R., Jin, Z., & Wang, X. (2021). Recent advances in the application of deep learning methods to forestry. In *Wood Science and Technology* (Vol. 55, Issue 5, pp. 1171–1202). Springer Science and Business Media Deutschland GmbH. <https://doi.org/10.1007/s00226-021-01309-2>
- Wu, Y., & Ji, Q. (2019). Facial Landmark Detection: A Literature Survey. *International Journal of Computer Vision*, 127(2), 115–142. <https://doi.org/10.1007/s11263-018-1097-z>
- Yuan, Y., Mou, L., & Lu, X. (2015). Scene Recognition by Manifold Regularized Deep Learning Architecture. *IEEE Transactions on Neural Networks and Learning Systems*, 26(10), 2222–2233. <https://doi.org/10.1109/TNNLS.2014.2359471>
- Zhang, Islam, M., & Lu, G. (2022). A review on automatic image annotation techniques. *Pattern Recognition*, 45(1), 346–362. <https://doi.org/10.1016/j.patcog.2011.05.013>
- Zhang, Tang, B., Deng, L., & Liu, X. (2021). A hybrid attention improved ResNet based fault diagnosis method of wind turbines gearbox. *Measurement: Journal of the International Measurement Confederation*, 179. <https://doi.org/10.1016/j.measurement.2021.109491>

ANEXOS

Anexo 1: Encuesta de evaluación del aplicativo con el modelo de éxito de sistemas de información de DeLone y McLean



 **Evaluación al aplicativo móvil - Wood Identifier UTN**

Propósito: El propósito de este cuestionario es medir la percepción de los estudiantes de ingeniería forestal sobre diferentes componentes del aplicativo móvil - Wood Identifier UTN para el reconocimiento de cinco especies maderables mediante la utilización de una red neuronal convolucional, basándose en el modelo de evaluación de sistemas de información de DeLone y McLean.

Este cuestionario busca obtener información valiosa sobre la calidad del sistema, la calidad de la información, la calidad del servicio, la intención de uso, la satisfacción del usuario y los beneficios netos generados por el aplicativo.

Los datos recopilados permitirán evaluar cómo los usuarios interactúan con el aplicativo móvil, cómo perciben su facilidad de uso, precisión en el reconocimiento de especies y utilidad general en la toma de decisiones relacionadas con las maderas.

Con los resultados de este cuestionario, se podrá identificar áreas de mejora y fortalezas del aplicativo móvil. Las respuestas proporcionarán una base sólida para optimizar el sistema y maximizar su utilidad, mejorando la experiencia del usuario y aumentando la efectividad del reconocimiento de especies maderables en diversos contextos.

Instrucciones: El cuestionario consta de **29 preguntas** divididas en seis secciones. Está diseñado para evaluar diferentes aspectos del aplicativo móvil. Por favor, lea cada afirmación cuidadosamente y seleccione la opción que mejor refleje su percepción o experiencia con el aplicativo. El cuestionario utiliza la escala de Likert de 5 puntos presentada a continuación:

1. Totalmente en desacuerdo
2. En desacuerdo
3. Neutral
4. De acuerdo
5. Totalmente de acuerdo

Seleccione un solo número para cada afirmación. No hay respuestas correctas o incorrectas; simplemente queremos conocer su opinión honesta.

Tiempo estimado para llenar el cuestionario: 5 minutos

¡Gracias por tu tiempo y colaboración!



Hola, EDWIN PACO. Cuando envíe este formulario, el propietario verá su nombre y dirección de correo electrónico.

* Obligatorio

Información base

1. Edad *

Escriba su respuesta

2. Género *

Femenino

Masculino

Otro

Siguiente

Página 1 de 2

Preguntas - Modelo de éxito de Delone & McLean



3. CALIDAD DEL SISTEMA *

	Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
¿La interfaz de la aplicación es fácil de entender y utilizar?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿La aplicación es estable (es decir, no se cierra inesperadamente)?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿La aplicación responde rápidamente a las acciones realizadas?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿El sistema responde de manera rápida y eficiente al cargar o tomar fotos de las especies maderables?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿El sistema identifica correctamente las especies maderables a partir de las imágenes capturadas?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

4. CALIDAD DE LA INFORMACIÓN *

	Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
¿El reconocimiento de especies es preciso y confiable?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿Los resultados presentados son claros y fáciles de interpretar?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿La información proporcionada por la aplicación es relevante para sus necesidades?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿La interfaz incluye gráficos, imágenes u otros elementos visuales útiles?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿La aplicación proporciona detalles útiles como nombres científicos o características visuales de las especies maderables?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

5. CALIDAD DEL SERVICIO *

	Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
¿La aplicación incluye ayuda clara para aprender su uso?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿La ayuda integrada es útil para resolver dudas comunes?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿El diseño de la aplicación reduce la necesidad de soporte técnico al ser intuitivo y fácil de usar?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿La aplicación fomenta la confianza al ser clara sobre sus limitaciones o resultados?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

6. INTENCIÓN DE USO *

	Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
¿Utilizará la aplicación regularmente para el reconocimiento de especies?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿Considera la aplicación intuitiva para su uso diario?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿Recomendaría esta aplicación a otras personas interesadas en la identificación de especies?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿La aplicación satisface sus necesidades actuales y futuras?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿Qué tan bien se adapta la aplicación a entornos de uso en campo, considerando condiciones como poca iluminación o ruido ambiental?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

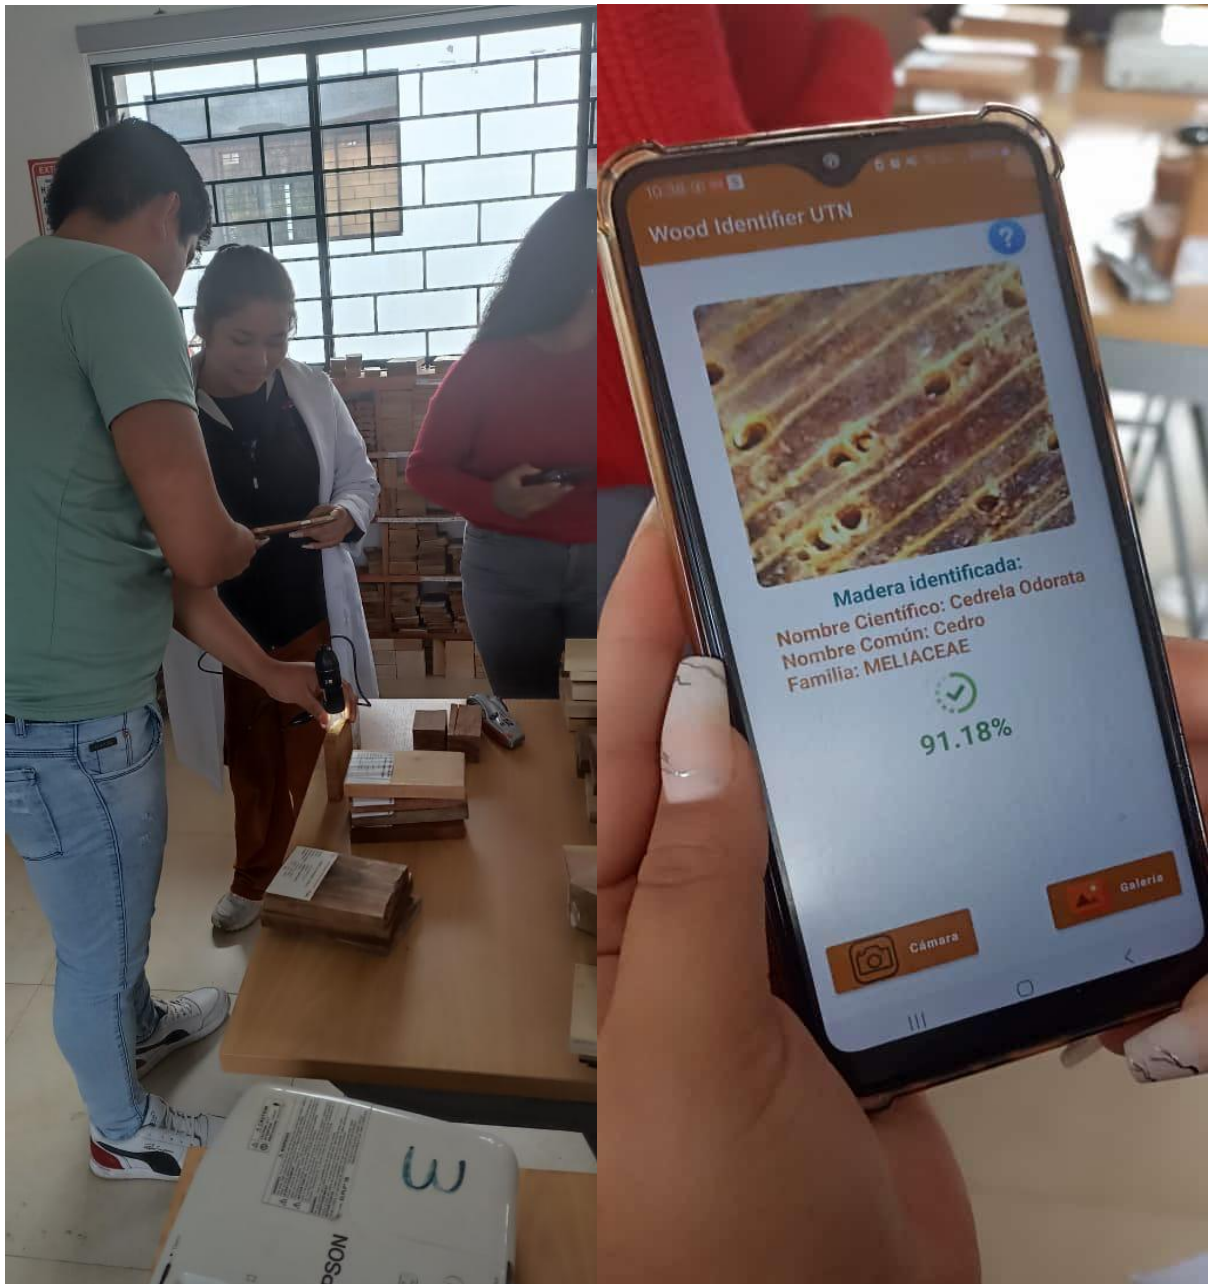
7. SATISFACCIÓN DEL USUARIO *

	Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
¿Está satisfecho con la experiencia general al usar la aplicación?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿La aplicación cumple con sus expectativas que tenía?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿Es probable que continúe utilizando la aplicación en el futuro?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿Se siente satisfecho con la facilidad de uso del sistema?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿Considera que la calidad general es adecuada para un uso profesional?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

8. BENEFICIOS NETOS *

	Totalmente en desacuerdo	En desacuerdo	Ni de acuerdo ni en desacuerdo	De acuerdo	Totalmente de acuerdo
¿La aplicación ha mejorado su eficiencia en la identificación de especies maderables?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿Se ha reducido el tiempo necesario para identificar una especie gracias a la aplicación?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿Considera que la aplicación ha tenido un impacto positivo en su trabajo o estudio?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿Se siente más seguro al tomar decisiones basadas en los resultados de la aplicación?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
¿Cree que la aplicación puede influir en la industria o en otros usuarios?	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Anexo 2: Pruebas del aplicativo móvil con estudiantes de ingeniería forestal



Anexo 3: Socialización y elaboración de encuestas con estudiantes de ingeniería forestal

