

Inteligencia artificial para la conservación forestal: identificación de especies maderables mediante MobileNetV3 y mecanismos de atención en Ecuador

*Artificial Intelligence for Forest Conservation: Identification of Timber
Species Using MobileNetV3 and Attention Mechanisms in Ecuador*

 Jorge Daniel Ortega Alburquerque ^a

 Luis Antonio Chamba Eras ^a

^a Universidad Nacional de Loja, Ecuador. Facultad de la Energía. Carrera de Computación. Grupo de Investigación GITIC

Cómo citar: Ortega Alburquerque, J. D., & Chamba Eras, L. A. (2026). Inteligencia artificial para la conservación forestal: identificación de especies maderables mediante MobileNetV3 y mecanismos de atención en Ecuador. *Revista Kawsaypacha: Sociedad Y Medio Ambiente*, (18), A014. <https://doi.org/10.18800/kawsaypacha.202602.A014>



Resumen: La tala ilegal y la deforestación —tráfico de madera— representan amenazas críticas para la sostenibilidad de los ecosistemas forestales en el sur de Ecuador, lo que exige herramientas de control más eficientes y accesibles. Este trabajo presenta un modelo basado en inteligencia artificial (IA) que utiliza la arquitectura MobileNetV3 —especializada en la detección de patrones en imágenes y optimizada para dispositivos de bajo poder de cómputo— para la identificación anatómica de cuatro especies maderables: cedro (*Cedrela odorata*), nogal (*Juglans neotropica*), faique (*Prosopis pallida*) y guayacán (*Handroanthus chrysanthus*). Los resultados evidenciaron un desempeño adecuado y estable en diferentes escenarios de validación, incluyendo condiciones controladas de laboratorio y entornos con mayor variabilidad y complejidad, alcanzando una precisión del 81% y del 80%, respectivamente, lo que demuestra que el modelo aprendió a discriminar las especies a partir de características anatómicas como vasos, radios y anillos. Se concluye que la solución basada en IA constituye una herramienta tecnológica para apoyar la lucha contra el tráfico de madera y, al mismo tiempo, un valioso recurso didáctico para la formación de futuros profesionales en computación, gestión forestal y conservación ambiental.

Palabras clave: Redes neuronales convolucionales. Computación en el borde. Aprendizaje supervisado. Aplicación de la ley. Botánica. Ecología.

Abstract: Illegal logging and deforestation—timber trafficking—represent critical threats to the sustainability of forest ecosystems in southern Ecuador, demanding more efficient and accessible monitoring tools. This work presents an Artificial Intelligence (AI) model that leverages the MobileNetV3 architecture—specialized in image pattern detection and optimized for low-resource devices—for the anatomical identification of four timber species: *Cedrela odorata*, *Juglans neotropica*, *Prosopis pallida*, and *Handroanthus chrysanthus*. The results showed adequate and stable performance across validation scenarios, including controlled laboratory conditions and more variable, complex environments, reaching accuracies of 81% and 80%, respectively, indicating that the model learned to discriminate species based on anatomical features such as vessels, rays, and rings. This AI-based solution is both a technological tool to support the fight against timber trafficking and a valuable educational resource for training future professionals in computer science, forest management, and environmental conservation.

Keywords: Convolutional Neural Networks. Edge Computing. Supervised Learning. Law Enforcement. Botany. Ecology.

1. Introducción

La gestión sostenible de los recursos forestales enfrenta desafíos críticos en el contexto global actual. La tala ilegal se ha consolidado como uno de los principales motores de la deforestación, lo que provoca un manejo insostenible de los bosques y el deterioro sistemático de los ecosistemas (Mascarello et al., 2021; Ojeda Luna et al., 2020). Si bien los bosques tropicales desempeñan un rol fundamental en la mitigación del cambio climático y existen normativas para la protección de especies vulnerables (García-Cox et al., 2023; Mascarello et al., 2021), la problemática persiste, con impactos económicos devastadores; por ejemplo, en Estados Unidos, las multas asociadas a estas prácticas oscilan entre 52 y 157 billones de dólares (Datta et al., 2025). En el contexto ecuatoriano, esta situación adquiere matices alarmantes: entre 2016 y 2018, las provincias de Zamora-Chinchipe y Loja registraron pérdidas forestales de 6864 ha y 2183 ha, respectivamente (Ministerio del Ambiente, Agua y Transición Ecológica [MAATE], 2018). Reportes entre 2020 y 2022 señalan una tasa de deforestación del -0.8%, cifra que supera la capacidad de regeneración natural de los bosques locales (MAATE, 2023, p. 14).

Ante este escenario, la identificación taxonómica precisa de la madera emerge como un mecanismo crucial para la conservación, cuya eficacia puede maximizarse mediante la visión por computadora (CV, por sus siglas en inglés), una rama de la inteligencia artificial (IA) capaz de analizar patrones anatómicos de forma análoga a la visión humana (Liu et al., 2024; Sugiarto et al., 2024). De la misma manera, la CV utiliza algoritmos que procesan

imágenes y extraen características para obtener información descriptiva de los objetos del mundo real (De Andrade et al., 2020; Mou et al., 2024). Los principales avances tecnológicos han dado lugar a sistemas informáticos para la identificación automática de madera (Díaz-de-Arcaya et al., 2024; Srinivasan et al., 2025), presentando una mejora de precisión y velocidad ante los métodos tradicionales.

Los métodos tradicionales de identificación de madera, según Kumar et al. (2024) y Senthilvadivu y David, (2025), limitan la fiabilidad y agilidad de los expertos en el reconocimiento de especies maderables al depender de técnicas como la observación manual, la examinación macroscópica/microscópica, sistemas de clasificación (Silva et al., 2022; Venugopal et al., 2024), listas de referencias y el análisis de propiedades físicas/químicas (International Association of Wood Anatomists, 1989). Desde la perspectiva de Raju et al. (2025), estos procesos son tediosos, lentos y dependen del juicio humano, lo que los vuelve más susceptibles a fallos de clasificación; situación que, de acuerdo con Herrera-Poyatos et al. (2024) y Riesco Muñoz et al. (2019), con frecuencia deriva en equivocaciones en los inventarios forestales, lo que permite a los traficantes evadir los controles aduaneros con mayor facilidad.

Así mismo, existen soluciones basadas en IA, las cuales apoyan a los profesionales en su campo de estudio (Liu et al., 2024; Srinivasan et al., 2025; Venugopal et al., 2024), sin embargo, su ejecución en dispositivos de bajos recursos, como los teléfonos móviles, es rara vez abarcada o incluso no especificada (Ajay et al., 2025; Harika et al., 2024; Li et al., 2025). La mayoría de las soluciones tiende a superar los desafíos de identificación en entornos con mayor variabilidad y complejidad, lo que demanda un alto consumo de recursos computacionales y prioriza la potencia de cálculo por encima de la portabilidad (Ajay et al., 2025; Mou et al., 2024; Wang et al., 2024). Esto ha generado un vacío de conocimiento evidente: la ausencia de soluciones orientadas a entornos móviles que se desempeñen de forma óptima en campo y que, a su vez, proporcionen resultados precisos y estables en entornos con mayor variabilidad y complejidad.

En respuesta a este vacío, se propone el uso de la arquitectura ligera MobileNetV3-Large, que —como argumentan Howard et al. (2019)— fue diseñada para tareas de CV en dispositivos con recursos limitados, lo que favorece la extracción de características importantes con un consumo reducido de batería y memoria. Estas características convierten a la arquitectura MobileNetV3 en una alternativa adecuada para su implementación en dispositivos móviles y similares, orientada a escenarios de procesamiento de campo, como el monitoreo forestal mediante dispositivos portátiles (Raju et al., 2025). Como respaldo a esta propuesta, diversos estudios ya han evidenciado la capacidad de arquitecturas similares, al resolver con gran precisión la clasificación de enfermedades en cultivos, la identificación de especies de madera y maleza, e incluso la detección de peatones (Jiao et al., 2024; Li et al., 2024; Sugiarto et al., 2024; Tang et al., 2025).

En este contexto, este trabajo aborda la problemática de la tala ilegal mediante el desarrollo y evaluación de un modelo de CV basado en la arquitectura MobileNetV3 para la identificación automática de cuatro especies maderables de relevancia ecológica y cultural en el sur del Ecuador: cedro (*Cedrela odorata*), nogal (*Juglans neotropica*), faique (*Prosopis pallida*) y guayacán (*Handroanthus chrysanthus*). En particular, se propone evaluar el desempeño del modelo en distintos escenarios de validación, que abarcan desde condiciones controladas de laboratorio hasta entornos con mayor variabilidad y complejidad. Asimismo, se analiza la capacidad de generalización del modelo a otras especies y su posible despliegue en entornos móviles, con el fin de valorar su viabilidad como herramienta de apoyo en procesos formativos y como soporte complementario para la identificación realizada por especialistas del área.

2. Metodología

La metodología se estructuró con el propósito de evaluar el desempeño del modelo en distintos niveles de complejidad experimental, considerando tanto condiciones controladas como escenarios de mayor variabilidad. Para ello, se definieron tres líneas de análisis complementarias: (i) entrenamiento y validación en un conjunto de cuatro especies ecuatorianas obtenidas mediante captura directa, (ii) pruebas de estrés en condiciones no controladas y (iii) extrapolación del modelo a especies de una región geográfica distinta. Esta estructura metodológica permitió examinar no solo la capacidad de clasificación del modelo, sino también su robustez y potencial de generalización.

2.1 Especies forestales y especificación de captura

Las especies forestales se dividieron en dos regiones: Ecuador, para el entrenamiento y la evaluación del modelo; y Brasil, para analizar la capacidad de evaluación del modelo. En la región sur de Ecuador, las cuatro especies objetivo fueron: cedro, nogal, faique y guayacán. Mientras que en la región de Brasil se seleccionaron tres especies: itaúba (*Mezilaurus itauba*), caimito (*Micropholis venulosa*) y mogno (*Swietenia macrophylla*).

Con el objetivo de abordar la brecha tecnológica asociada a la portabilidad de procesos de identificación en entornos de mayor variabilidad y complejidad, se empleó un macroscopio para capturar imágenes de especies forestales ecuatorianas en condiciones de laboratorio controladas. El dispositivo dispone de tres niveles de iluminación (bajo, normal y alto), genera imágenes en formato JPEG con una resolución de 640 × 480 píxeles y cuenta con un rango de zoom de 0-40 mm (equivalente a 1.75x-2x en comparación con un estereomicroscopio Euromex de referencia).

Por su parte, las imágenes de las especies brasileñas fueron obtenidas del repositorio público [Mendeley Data](#), asociado al estudio de Souza et al. (2020), quienes desarrollaron un sistema automático para el reconocimiento de especies de la flora brasileña a partir de características texturales de imágenes macroscópicas de madera. El conjunto de datos

comprende 1.901 imágenes de 46 especies, capturadas con un estereomicroscopio Zeiss Discovery V12, con una resolución de 2080×1540 píxeles y una magnificación de $10\times$.

2.2 Procesamiento y aumento de datos

Para el conjunto de datos de especies ecuatorianas, se ejecutaron las siguientes técnicas de aumento de datos —«permiten expandir un conjunto de datos simulando variabilidad real» (Xie et al., 2025; Xie & Ling, 2023) —: volteos horizontales/verticales, simulando un efecto de espejo; ajustes de brillo/contraste, modificando el valor en ± 0.2 y ± 0.1 puntos, respectivamente; desenfoque Gaussiano; rotaciones de ± 15 grados; y un proceso de reescalado de la imagen a 224 píxeles cuadrados. En el caso del conjunto de datos de las especies brasileñas, se aplicaron las mismas técnicas, excepto las rotaciones.

Asimismo, para el proceso de entrenamiento, el conjunto de datos se dividió en tres subconjuntos: entrenamiento, validación y prueba; garantizando que no existiera superposición de muestras provenientes de un mismo espécimen entre ellos. El código desarrollado e implementado durante el proceso experimental está disponible en un repositorio público de [GitHub](#).

2.3 Adquisición de imágenes y diseño experimental

La adquisición de imágenes de las especies ecuatorianas se organizó en dos fases experimentales. La primera, denominada línea base, comprendió el entrenamiento y la evaluación inicial del modelo a partir de imágenes capturadas en condiciones controladas de laboratorio, lo que aseguró una adecuada visualización de las características anatómicas mediante el control constante del enfoque y la iluminación. La segunda fase, correspondiente a las pruebas de estrés, consistió en la reevaluación del modelo previamente entrenado utilizando un nuevo conjunto de imágenes obtenidas en condiciones menos controladas, caracterizadas por imperfecciones superficiales más marcadas y variabilidad en la iluminación.

La línea base se estructuró en tres categorías anatómicas: (i) vasos y radios (VR), (ii) vasos, radios y anillos de crecimiento (VRA) y (iii) transición entre albura y duramen (TAD). Para cada especie se prepararon 10 especímenes distintos y se capturaron 15 imágenes por categoría, lo que sumó un total de 1800 imágenes originales. Mediante técnicas de aumento de datos, este conjunto se amplió a 3600 imágenes. Del total, 360 imágenes se destinaron a la evaluación del modelo y el resto al entrenamiento.

Las pruebas de estrés siguieron las mismas tres categorías anatómicas y se recolectaron 10 imágenes por categoría, lo que sumó 120 imágenes originales empleadas exclusivamente para la reevaluación del modelo.


Por último, las especies brasileñas se incorporaron en la fase denominada extrapolación del modelo, cuyo objetivo fue analizar su capacidad de generalización en un contexto

geográfico distinto. En esta etapa se utilizaron 896 imágenes en total, ampliadas mediante técnicas de aumento de datos, distribuidas de la siguiente manera: itaúba (332 imágenes), caimito (284 imágenes) y mogno (280 imágenes). La metodología completa se resume en la Figura 1.

2.4 Métodos de evaluación

El método principal de evaluación fue la matriz de confusión, utilizada para cuantificar la exactitud de las predicciones del modelo sobre datos no observados durante el entrenamiento (Fei et al., 2023). Complementariamente, se empleó un mapa de similitud para analizar la estructura interna de los datos y la separabilidad entre clases, lo que facilitó la interpretación de patrones de agrupamiento (Xie et al., 2025). Asimismo, el diagrama de caja y bigotes permitió describir la distribución y la variabilidad de los resultados obtenidos. Este análisis se reforzó mediante la prueba estadística de Kruskal-Wallis, una técnica no paramétrica orientada a determinar si existen diferencias significativas entre grupos (Devore, 2008). Finalmente, se utilizaron mapas de calor para identificar las regiones de la imagen con mayor contribución a la decisión del modelo, lo que facilitó la interpretación de las características más influyentes (Zhang et al., 2025).

Figura 1. Esquema general de la metodología empleada en el trabajo



3. Resultados y discusión


La presente sección expone los resultados obtenidos y su análisis correspondiente. En primer lugar, la subsección 3.1 (Etapa previa) describe las características de las muestras y las condiciones de adquisición. Posteriormente, la subsección 3.2 (Línea base) presenta la evaluación del modelo en condiciones de laboratorio controladas. La subsección 3.3 (Prueba de estrés) evalúa su desempeño en escenarios con mayor complejidad visual. En la subsección 3.4 (Extrapolación del modelo) se examina la capacidad de generalización

al despliegue en nuevas especies, incluyendo consideraciones sobre su potencial de despliegue. Finalmente, la subsección 3.5 (Discusión) integra e interpreta los hallazgos, seguida de la subsección 3.5.1 (Limitaciones), donde se identifican las principales restricciones metodológicas del trabajo.

3.1 Etapa previa

Las muestras obtenidas de cada especie presentan una calidad adecuada para las capacidades del dispositivo de captura empleado, lo que garantiza la visualización de rasgos anatómicos discriminativos como vasos, radios y anillos de crecimiento. Las especies cedro, faique y guayacán fueron recolectadas a partir de discos, definidos como la sección transversal completa del tronco (Riesco Muñoz et al., 2019). En contraste, el nogal se obtuvo mediante núcleos de extracción —muestras longitudinales cilíndricas que atraviesan el radio del tronco (International Association of Wood Anatomists, 1989)— debido a la ausencia de material en formato disco. Esta diferencia en el tipo de muestra generó variaciones en la distribución de la iluminación, lo que permitió captar, en el caso del nogal, regiones con mayor incidencia lumínica. Adicionalmente, algunas muestras de cedro, faique y nogal presentan pequeñas imperfecciones superficiales, como cavidades, que no afectaron de manera significativa el desempeño del modelo y potencialmente contribuyeron a mejorar su tolerancia a irregularidades menores. La Figura 2 muestra un mosaico representativo de las cuatro especies analizadas.

Figura 2. Muestra representativa de cuatro especies maderables




Nota: (a) cedro, (b) nogal, (c) faique y (d) guayacán. Imágenes de cortes transversales con manipulación superficial mínima.

3.2 Línea base: Evaluación del desempeño en condiciones de laboratorio

El modelo alcanzó una precisión global del 81%, como se observa en la matriz de confusión de la Figura 3. En dicha matriz se identifica un mayor nivel de error en la clase nogal, con 14 muestras mal clasificadas. Este comportamiento podría estar asociado a la distribución irregular de la iluminación derivada de la superficie convexa de las muestras. En este sentido, se recomienda complementar la identificación automatizada con métodos tradicionales, como la observación manual y el análisis microscópico, tal como sugieren Ajay et al. (2025).

Figura 3. Matriz de confusión en condiciones de laboratorio



Nota: Se presenta el desempeño global del modelo al discriminar entre cuatro especies maderables. Las columnas representan las clases reales y las filas las clases predichas. Una mayor concentración de valores en la diagonal principal indica una mejor capacidad de clasificación.


Por otro lado, el faique es la especie mejor distinguida en el mapa de similitud (Figura 4), seguida del cedro. No obstante, se presenta un sesgo de confusión, dado los valores atípicos del nogal, mayoritariamente hacia el guayacán y un poco hacia el cedro, posiblemente debido a múltiples variables externas que, además de la iluminación, pueden abarcar numerosas imperfecciones, desenfoques o inconsistencias, tal como argumentan Ravindran y Wiedenhoeft (2022) y Wang y Zhang (2025).

Para resaltar la influencia de los rasgos anatómicos discriminativos en la identificación de las especies, el modelo fue evaluado mediante tres subconjuntos por especie, cada conjunto individual para un rasgo anatómico (VR, VRA y TAD). El mapa de calor de

exhaustividad (*recall*) de la Figura 5 evidenció patrones específicos: el rasgo anatómico TAD alcanzó la mayor tasa de aciertos para faique (93%), mientras que el conjunto VRA fue determinante para cedro (93%) y los VR para el nogal (93%). Por su parte, el guayacán alcanzó una identificación perfecta (100%) con ambos métodos, VRA y TAD. Estos resultados sugieren que la capacidad de identificación de todas las especies no se debe a un rasgo anatómico discriminativo, sino que varía entre ellas (Liu et al., 2024).

Por último, el mapa de calor (Figura 6) ilustra que el cedro concentra su actividad en las características discriminativas VRA, mientras que el faique lo hace mayoritariamente en los VR. Por otro lado, el guayacán abarca zonas más amplias y presenta un mayor número de características discriminativas. Sin embargo, es interesante notar que el nogal presenta un patrón centrado en características VRA y tampoco descuida las zonas con luminancia irregular.

Figura 4. Mapa de similitud entre especies maderables (t-SNE)



Nota: La proyección bidimensional muestra la agrupación de 90 muestras por especie. Una mayor separación entre los grupos indica una mejor discriminación entre clases, mientras que la superposición sugiere posibles confusiones. Los valores de los ejes X e Y corresponden únicamente a coordenadas de proyección y no tienen una interpretación directa.

Figura 5: Mapa de calor de exhaustividad (*recall*) del modelo basado en subconjuntos de rasgos anatómicos discriminativos por especie





Figura 6. Mapa de calor para las cuatro especies maderables




Nota: Cada fila corresponde a una especie y se organiza en tres columnas: imagen original, mapa de calor generado por el modelo y superposición del mapa de calor sobre la imagen original.

3.3 Prueba de estrés: Respuesta del modelo ante escenario de alta complejidad visual


La matriz de confusión (Figura 7) evidencia un desempeño global de precisión del 80%, un valor que puede considerarse dentro de un rango adecuado, según Prommakhot et al. (2025). No obstante, se observa un mayor nivel de confusión en la clase de guayacán, seguida de la de cedro. Por su parte, nogal y faique presentan imprecisiones menores que se mantienen dentro de un comportamiento estable. En este sentido, como señalan De Andrade et al. (2020), ningún modelo está exento de sesgo y varianza al enfrentarse a datos no observados previamente, por lo que la presencia de un número reducido de clasificaciones erróneas resulta esperable en escenarios de evaluación abiertos.

Figura 7. Matriz de confusión en escenario de alta complejidad visual



La Figura 8 presenta el diagrama de caja y bigotes correspondiente a la aplicación de la prueba de Kruskal-Wallis sobre la métrica F1-score, adecuada para escenarios con ligeros desequilibrios entre clases. El análisis arrojó un estadístico $H = 4.0$ y un valor $p = 0.25$, lo que indica que no existen diferencias estadísticamente significativas en el desempeño entre las especies. En consecuencia, el modelo mantiene un comportamiento estable en escenarios de mayor complejidad visual. Como se observa en la figura, todas las especies registran niveles de precisión superiores al 70%, destacando faique y cedro. Asimismo, las predicciones muestran una consistencia general, incluida la de guayacán, cuya precisión no desciende por debajo de dicho umbral. No obstante, aunque el nogal presenta resultados globalmente estables, se identifican algunos valores atípicos, un fenómeno que también se observa en el faique.

Figura 8. Prueba de Kruskal-Wallis para la evaluación del desempeño




Nota: El diagrama de caja y bigotes muestra la distribución estadística de la métrica de precisión por especie. La altura de cada caja representa el rango intercuartílico (variabilidad) y las cajas más pequeñas indican una mayor consistencia de los resultados. Los límites inferior, central y superior de la caja corresponden a los cuartiles Q1, Q2 (mediana) y Q3, respectivamente. Las líneas verticales señalan los valores mínimo y máximo observados, mientras que los puntos destacados representan valores atípicos. El eje vertical indica el porcentaje de precisión (30-100%) y el eje horizontal corresponde a las especies analizadas.

3.4 Extrapolación del modelo: Evaluación en nuevas especies y potencial despliegue en dispositivos móviles

En esta etapa se seleccionaron tres especies distintas (Figura 9): itaúba, caimito y mogno. Las imágenes correspondientes presentan una alta calidad en cuanto a resolución, enfoque e iluminación, lo que permite evaluar la capacidad de adaptación del modelo en un entorno técnicamente controlado.


Figura 9. Muestras correspondientes a especies maderables utilizadas en la fase de extrapolación del modelo



Nota: (a) Itaúba, (b) Caimito y (c) Mogno.

La Figura 10 muestra los resultados obtenidos durante la fase de extrapolación del modelo. En términos generales, el desempeño evidencia limitaciones en la clasificación de especies no incluidas durante el entrenamiento, lo que sugiere una capacidad de generalización restringida a nuevas clases. Esta situación puede atribuirse a diferencias en los patrones anatómicos con respecto a las especies previamente utilizadas. Resultados similares han sido reportados por Liu et al. (2024), quienes observaron descensos significativos en la precisión —inferiores al 20% en algunos casos— asociados a variaciones anatómicas específicas de cada especie. No obstante, caimito alcanzó una precisión del 100%, lo que sugiere que el modelo pudo haber aprendido características estructurales presentes en las especies de entrenamiento que también se manifiestan en esta especie, favoreciendo así su correcta clasificación.

Figura 10. Matriz de confusión correspondiente al conjunto de imágenes utilizadas en la fase de extrapolación



En coherencia con lo anterior, la Figura 11 presenta el mapa de similitud correspondiente a la fase de extrapolación. En esta proyección bidimensional se observa que el caimito constituye el único grupo claramente separado y correctamente delimitado en el espacio 2D. En contraste, la itaúba y el mogno muestran una superposición considerable, lo que evidencia dificultades del modelo para discriminar entre ambas especies.

Por su parte, el mapa de calor (Figura 12) indica que el modelo centró su atención en las características VRA al intentar clasificar la itaúba y el mogno, sin lograr una discriminación adecuada. En contraste, el caimito presenta un patrón de activación similar al observado previamente en el faique y el nogal, lo que sugiere afinidades en su distribución anatómica. Estos resultados indican que el modelo aprendió a identificar

rasgos discriminativos clave —como radios, vasos y anillos de crecimiento—; sin embargo, la presencia de patrones estructurales parcialmente coincidentes habría favorecido la confusión entre determinadas especies.

Figura 11. Mapa de similitud correspondiente al conjunto de imágenes empleadas en la fase de extrapolación





Figura 12. Mapa de calor correspondiente a las especies evaluadas en la fase de extrapolación



Finalmente, debido a limitaciones de compatibilidad entre el hardware disponible y el dispositivo de captura, así como a restricciones de tiempo, se desarrolló un prototipo de interfaz de escritorio para evaluar el modelo en funcionamiento. El modelo fue implementado en un servidor local y se estableció un umbral de confianza del 80%, de modo que las predicciones con probabilidad inferior a dicho umbral se clasifican como «madera desconocida».

3.5 Discusión

La evaluación del modelo en entornos controlados se evidencia en la matriz de confusión presentada en la sección 3.2 (Figura 3), donde el desempeño global se mantiene en un rango considerado adecuado, resultado comparable al obtenido en escenarios con mayor variabilidad y complejidad (sección 3.3, Figura 7). De acuerdo con Alhichri et al. (2021) y Xie y Ling (2023), este comportamiento sugiere que el modelo logró focalizar su atención en regiones relevantes de la imagen, reduciendo la influencia de la información irrelevante. En este sentido, el mapa de calor correspondiente a la fase de extrapolación (sección 3.4, Figura 12) confirma que el modelo aprendió a utilizar las características VRA como base para la identificación; sin embargo, dichas representaciones no fueron suficientes para evitar confusiones al enfrentarse a especies no vistas durante el entrenamiento.

Por otra parte, el mapa de calor obtenido en condiciones de laboratorio (sección 3.2, Figura 6) muestra que las regiones de activación asociadas al nogal y al cedro abarcan un área más reducida que las de las demás especies. En particular, en el caso del nogal, se observa que la atención del modelo se concentra en zonas cuyas características pueden ser similares a las del guayacán. A partir de ello, se plantea la hipótesis de que la confusión entre ambas especies podría deberse a la focalización del modelo en pequeñas imperfecciones superficiales del nogal que, al agruparse, generan patrones visualmente similares a los radios característicos del guayacán. Este comportamiento es coherente con lo señalado por Senthilvadivu y David (2025) y por Venugopal et al. (2024), quienes indican que la variabilidad anatómica, tanto intraespecífica como interespecífica, puede producir superposición de rasgos entre especies distintas. Asimismo, el proceso de reescalado de las imágenes descrito en la metodología (sección 2.2) pudo haber reducido la resolución de ciertos detalles discriminativos, lo que incrementó la probabilidad de confusión (Herrera-Poyatos et al., 2024).

Asimismo, la aplicación de la prueba estadística de Kruskal-Wallis —respaldada por Krishnamoorthy et al. (2025) como un método adecuado para evaluar diferencias significativas en el desempeño— permitió analizar la estabilidad del modelo entre las clases. Los resultados presentados en el diagrama de caja y bigotes (sección 3.3, Figura 8), junto con el estadístico H y el valor p obtenidos, indican que no existen diferencias estadísticamente significativas en el rendimiento, lo que sugiere que el modelo no experimenta una degradación sustancial en escenarios abiertos. En concordancia con Riesco Muñoz et al. (2019), las leves fluctuaciones observadas en las métricas pueden atribuirse a la variabilidad aleatoria, dado que el desempeño global se mantiene estable y en niveles elevados.

En el contexto de la adaptación del modelo, Gayathri et al. (2025), Liu et al. (2024) y Karnik et al. (2025) sostienen que la extrapolación a nuevas especies constituye un mecanismo pertinente para evaluar la robustez del modelo en escenarios diversos y cercanos a condiciones reales. En este trabajo, los resultados evidencian una capacidad

de adaptación limitada; sin embargo, también indican que el modelo aprendió a focalizar su atención en las características de VRA al intentar identificar nuevas especies.

La hipótesis, en concordancia con Liu et al. (2024), sugiere que el modelo internalizó rasgos anatómicos discriminativos relevantes durante el entrenamiento, pero su desempeño disminuyó porque las especies empleadas en la fase de adaptación presentan patrones estructurales que difieren de los previamente aprendidos. Esta interpretación se ve respaldada por los mapas de calor, en los que la activación del modelo se concentra de manera consistente en las regiones asociadas a las características de VRA. Como señalan Islam et al. (2024) y Kaleab Taye et al. (2025), los mapas de calor constituyen una herramienta útil para interpretar el proceso de decisión del modelo, proporcionando evidencia visual que fortalece la validez de esta hipótesis.

En definitiva, aunque la implementación directa en dispositivos móviles presentó limitaciones técnicas asociadas a la compatibilidad con el sistema de captura, el modelo basado en la arquitectura MobileNetV3 representa una alternativa eficiente en términos de consumo computacional, manteniendo un equilibrio adecuado entre rendimiento y precisión (Díaz-de-Arcaya et al., 2024; Howard et al., 2019; Kreuzberger et al., 2023). Asimismo, su diseño permite una implementación optimizada para la ejecución local, sin necesidad de conectividad a Internet, lo cual es una característica relevante para aplicaciones de monitoreo forestal en zonas remotas (Nguyen et al., 2023; Raju et al., 2025; Tang et al., 2025).

3.5.1 Limitaciones

A pesar del desempeño obtenido, se identificaron limitaciones metodológicas que deben considerarse al interpretar los resultados y orientan posibles mejoras en futuras etapas. En primer lugar, el uso de muestras de nogal en formato de núcleo dificultó la captura homogénea de la superficie, debido tanto al ángulo de visión fijo del dispositivo como a la geometría convexa del espécimen, lo que generó variaciones en la iluminación durante la adquisición de imágenes. Adicionalmente, esta condición, junto con la resolución espacial limitada del equipo utilizado, redujo la nitidez de ciertos detalles anatómicos finos en comparación con imágenes obtenidas conforme a estándares microscópicos, lo que constituye un aspecto técnico susceptible de optimización.

Asimismo, es pertinente señalar que el conjunto de datos de entrenamiento podría ampliarse mediante la incorporación de muestras con mayor variabilidad en sus rasgos anatómicos discriminativos. Como indican Alhichri et al. (2021), el tamaño y la diversidad del conjunto de datos constituyen factores clave para fortalecer la estabilidad y la robustez del algoritmo, tanto en entornos de laboratorio controlados como en escenarios de elevada complejidad visual.

Finalmente, si bien la arquitectura MobileNetV3 mostró un desempeño adecuado en entornos con recursos computacionales limitados, la falta de un prototipo móvil

completamente integrado para su evaluación directa en campo constituye una limitación técnica que debe abordarse en etapas futuras. La migración desde la interfaz de validación en un entorno de escritorio a una aplicación portátil autónoma permitirá evaluar el comportamiento del modelo en condiciones reales de operación.

4. Conclusiones

El presente trabajo aporta evidencia sobre la aplicación de técnicas de IA en el ámbito forestal y propone una herramienta tecnológica con potencial de utilidad tanto para especialistas como para procesos formativos. Los resultados experimentales muestran un desempeño favorable del modelo en distintos escenarios de evaluación. No obstante, se enfatiza que esta herramienta debe considerarse un apoyo complementario y no sustitutivo del criterio experto, por lo que sus predicciones deben contrastarse con métodos tradicionales de identificación para garantizar la validez de los resultados.

Asimismo, los resultados evidencian que el modelo presenta margen de mejora, particularmente mediante la ampliación del conjunto de datos con una mayor diversidad de especies forestales y una representación más amplia de sus características anatómicas discriminativas (Ajay et al., 2025). De igual manera, se recomienda abordar los posibles sesgos identificados en la clasificación —como los observados en nogal y guayacán— mediante la validación sistemática de las predicciones del modelo con criterio experto y con métodos tradicionales de identificación (Datta et al., 2025; Herrera-Feijoo et al., 2023).

Por último, como líneas de trabajo futuras, se propone la implementación y evaluación del modelo en dispositivos tecnológicos portátiles, lo que permitirá analizar su desempeño en condiciones reales de campo y consolidar su aplicabilidad práctica (Karnik et al., 2025). Asimismo, se plantea fortalecer la capacidad de generalización mediante la incorporación de muestras de nogal en formato disco y la ampliación del conjunto de imágenes con una mayor diversidad y riqueza de características anatómicas discriminativas.

Referencias

- Ajay, A.; Sandosh, S.; Saji, A. & Agarwal, H. (2025). An Explainable Deep Learning Framework for Sorghum Weed Classification Using Multi-Scale Feature Enhanced DenseNet. *IEEE Access*, 13, 26973-26990. <https://doi.org/10.1109/ACCESS.2025.3538937>
- Alhichri, H.; Alswayed, A. S.; Bazi, Y.; Ammour, N. & Alajlan, N. A. (2021). Classification of Remote Sensing Images Using EfficientNet-B3 CNN Model With Attention. *IEEE Access*, 9, 14078-14094. <https://doi.org/10.1109/ACCESS.2021.3051085>
- Datta, D.; Simeone, J. C.; Meadows, A. Outhwaite, W., Keong Chen, H., Self, N., Walker, L., & Ramakrishnan, N. (2025). Combating trade in illegal wood and forest products with machine learning. *PLOS ONE*, 20(1), pp. 1-24. <https://doi.org/10.1371/journal.pone.0311982>
- De Andrade, B. G.; Basso, V. M. & De Figueiredo Latorraca, J. V. (2020). Machine vision for field-level wood identification. *IAWA Journal*, 41(4), pp. 681-698. <https://doi.org/10.1163/22941932-bja10001>

- Devore, J. L. (2008). *Probabilidad y estadística para Ingeniería y ciencias (7.a ed.)*. Cengage Learning Editores, S.A. de C.V., una compañía de Cengage Learning, Inc.
- Díaz-de-Arcaya, J.; Torre-Bastida, A. I.; Zárate, G.; Miñón, R. & Almeida, A. (2024). A Joint Study of the Challenges, Opportunities, and Roadmap of MLOps and AIOps: A Systematic Survey. *ACM Computing Surveys*, 56(4), pp. 1-30. <https://doi.org/10.1145/3625289>
- Fei, Y.; Li, Z.; Zhu, T. & Ni, C. (2023). A Lightweight Attention-Based Convolutional Neural Networks for Fresh-Cut Flower Classification. *IEEE Access*, 11, 17283-17293. <https://doi.org/10.1109/ACCESS.2023.3244386>
- García-Cox, W.; López-Tobar, R.; Herrera-Feijoo, R. J.; Tapia, A.; Heredia-R, M.; Toulkeridis, T. & Torres, B. (2023). Floristic Composition, Structure, and Aboveground Biomass of the Moraceae Family in an Evergreen Andean Amazon Forest, Ecuador. *Forests*, 14(7), pp. 1-16. <https://doi.org/10.3390/f14071406>
- Gayathri, R.; Manohar, S.; Dayana, R.; Mathivanan, S. K. & Deshpande, N. M. (2025). An Optimized Algorithmic Frameworks for Transfer Learning to Enhance Efficiency and Accuracy in Pretrained Model Adaptation. *2025 4th OPJU International Technology Conference (OTCON) on Smart Computing for Innovation and Advancement in Industry 5.0*, Raigarh, India, pp. 1-5. <https://doi.org/10.1109/OTCON65728.2025.11070524>
- Harika, M. R.; Reddy, P. K.; Jannu, C.; Parisae, V.; Krishna, C. V. M. & Madhumati, G. L. (2024). Real Time Speech Enhancement Using Triple Attention U-Net. *2024 4th International Conference on Artificial Intelligence and Signal Processing (AISP)*, Vijayawada, India, 1-5. <https://doi.org/10.1109/AISP61711.2024.10870819>
- Herrera-Feijoo, R. J.; Torres, B.; López-Tobar, R.; Tipán-Torres, C.; Toulkeridis, T.; Heredia-R. M. & Mateo, R. G. (2023). Modelling Climatically Suitable Areas for Mahogany (*Swietenia macrophylla* King) and Their Shifts across Neotropics: The Role of Protected Areas. *Forests*, 14(2), pp. 1-23. <https://doi.org/10.3390/f14020385>
- Herrera-Poyatos, D.; Poyatos, A. H.; Soldado, R. M.; De Palacios, P.; Esteban, L. G.; Iruela, A. G.; Fernández, F. G. & Herrera, F. (2024). Deep Learning methodology for the identification of wood species using high-resolution macroscopic images. *2024 International Joint Conference on Neural Networks (IJCNN)*, Yokohama, Japan, 1-8. <https://doi.org/10.1109/IJCNN60899.2024.10650590>
- Howard, A.; Sandler, M.; Chen, B.; Wang, W.; Chen, L.-C.; Tan, M.; Chu, G.; Vasudevan, V.; Zhu, Y.; Pang, R.; Adam, H. & Le, Q. (2019). Searching for MobileNetV3. *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, 1314-1324. <https://doi.org/10.1109/ICCV.2019.00140>
- International Association of Wood Anatomists (1989). *IAWA list of microscopic features for hardwood identification with an appendix on non-anatomical information* (Boletín No. 10; pp. 219-332). <http://bit.ly/3MavfcC>
- Islam, M.; Aloraini, M.; Habib, S.; Alanazi, M. D.; Khan, I. & Khan, A. (2024). Optimal Features Driven Attention Network With Medium-Scale Benchmark for Wheat Diseases Recognition. *IEEE Access*, 12, 150739-150753. <https://doi.org/10.1109/ACCESS.2024.3434575>
- Jiao, R.; Xu, Z. & Zhang, Z. (2024). Improving YOLOv8 via Triple Attention for Pedestrian Detection. *2024 5th International Conference on Computer Vision, Image and Deep Learning (CVIDL)*, 1517-1521. <https://doi.org/10.1109/CVIDL62147.2024.10604206>
- Kaleab Taye, A.; Park, J.-M.; Cho, H.-J.; Kang, J.-T. & Seo, Y.-O. (2025). ResTreeNet: A Height-Aware LiDAR Tree Classification Model With Explainable AI for Forestry Applications. *IEEE Access*, 13, 81392-81405. <https://doi.org/10.1109/ACCESS.2025.3567042>
- Karnik, A. S.; Nair, N.; Sagili, Y. & Shanthi, P. B. (2025). Multi-Scale Venation Pattern Analysis for Medicinal Plant Species Recognition. *IEEE Access*, 13, 125526-125536. <https://doi.org/10.1109/ACCESS.2025.3589278>
- Kreuzberger, D.; Kühl, N. & Hirschl, S. (2023). Machine Learning Operations (MLOps): Overview, Definition, and Architecture. *IEEE Access*, 11, 31866-31879. <https://doi.org/10.1109/ACCESS.2023.3262138>
- Krishnamoorthy, M.; Sjoding, M. & Wiens, J. (2025). Cross-Validation for Longitudinal Datasets with Unstable Correlations. *Proceedings of the 31st ACM SIGKDD Conference on Knowledge Discovery and Data Mining V.2*, New York, NY, USA, 1219-1228. <https://doi.org/10.1145/3711896.3736898>

- Kumar, B.; Sinha, R. S.; Burman, R. K.; Alam, Md. S.; Kumari, A. & Sah, R. D. (2024). TreeIDNet: Species Identification through Video Analysis using Detectron2-Based Computer Vision. *2024 5th International Conference for Emerging Technology (INCET)*, Belgaum, India, 1-7. <https://doi.org/10.1109/INCET61516.2024.10592969>
- Li, H.; Li, N.; Wang, W.; Yang, C.; Chen, N. & Deng, F. (2024). Convolution Self-Guided Transformer for Diagnosis and Recognition of Crop Disease in Different Environments. *IEEE Access*, 12, 165903-165917. <https://doi.org/10.1109/ACCESS.2024.3495529>
- Li, W.; Ma, L. & Sciarra, A. (2025). Robust Multi-Agent Collaborative Perception via Triple-Attention and Dynamic Gating. *2025 IEEE 101st Vehicular Technology Conference (VTC2025-Spring)*, 1-5. <https://doi.org/10.1109/VTC2025-Spring65109.2025.11174503>
- Liu, S.; Zheng, C.; Wang, J.; Lu, Y.; Yao, J.; Zou, Z.; Yin, Y. & He, T. (2024). How to discriminate wood of CITES-listed tree species from their look-alikes: Using an attention mechanism with the ResNet model on an enhanced macroscopic image dataset. *Frontiers in Plant Science*, 15, pp. 1-14. <https://doi.org/10.3389/fpls.2024.1368885>
- Mascarello, M.; Amalfi, M.; Asselman, P.; Smets, E.; Hardy, O. J.; Beeckman, H. & Janssens, S. B. (2021). Genome skimming reveals novel plastid markers for the molecular identification of illegally logged African timber species. *PLOS ONE*, 16(6), pp. 1-18. <https://doi.org/10.1371/journal.pone.0251655>
- Ministerio del Ambiente, Agua y Transición Ecológica (MAATE) (2018). *Estadísticas del patrimonio natural del Ecuador continental*. <https://doi.org/10.5281/zenodo.18158663>
- Ministerio del Ambiente, Agua y Transición Ecológica (MAATE) (2023). Rendición de cuentas. <https://doi.org/10.5281/zenodo.17866986>
- Mou, X.; Chen, H.; Yu, X.; Chen, L.; Peng, Z. & Wang, R. (2024). Lightweight Segmentation Method for Wood Panel Images Based on Improved DeepLabV3+. *Electronics*, 13(23), pp. 1-13. <https://doi.org/10.3390/electronics13234658>
- Nguyen, P. Q.; Truong, D. T. M.; Huynh, T. V.; Nguyen, T. H. N. & Le, Q.-H. (2023). Design and Build a System for Illegal Logging Detection Based on Acoustic Signal and Automatic Warning Using LoRA Network. *2023 International Conference on System Science and Engineering (ICSSE)*, Ho Chi Minh, Vietnam, 265-270. <https://doi.org/10.1109/ICSSE58758.2023.10227201>
- Ojeda Luna, T.; Eguiguren, P.; Günter, S.; Torres, B. & Dieter, M. (2020). What Drives Household Deforestation Decisions? Insights from the Ecuadorian Lowland Rainforests. *Forests*, 11(11), pp. 1-20. <https://doi.org/10.3390/f11111131>
- Prommakhot, A.; Onshaunjit, J.; Ooppakaew, W.; Samseemoung, G. & Srinonchat, J. (2025). Hybrid CNN and Transformer-Based Sequential Learning Techniques for Plant Disease Classification. *IEEE Access*, 13, 122876-122887. <https://doi.org/10.1109/ACCESS.2025.3586285>
- Raju, R. R.; Naidu, S. N.; Moulali, U. & Basha, S. R. (2025). Hardwood Classification using ResNet18 and Macroscopic Image Analysis. *2025 4th International Conference on Innovative Mechanisms for Industry Applications (ICIMIA)*, Tirupur, India, 1920-1927. <https://doi.org/10.1109/ICIMIA67127.2025.11200564>
- Ravindran, P. & Wiedenhoeft, A. C. (2022). Caveat emptor: On the Need for Baseline Quality Standards in Computer Vision Wood Identification. *Forests*, 13(4), pp. 1-19. <https://doi.org/10.3390/f13040632>
- Riesco Muñoz, G.; Imaña Encinas, J. & De Paula, J. E. (2019). Densidad de la madera de 59 especies del orden Sapindales procedentes de bosques naturales brasileños. *Madera y Bosques*, 25(2), pp. 1-12. <https://doi.org/10.21829/myb.2019.2521817>
- Senthilvadivu, S. & David, A. (2025). Vision Transformers with Contrastive Learning for Robust Wood Species Identification. *2025 3rd International Conference on Self Sustainable Artificial Intelligence Systems (ICSSAS)*, Erode, India, 1085-1090. <https://doi.org/10.1109/ICSSAS66150.2025.11081278>
- Silva, J.; Bordalo, R.; Pissarra, J. & De Palacios, P. (2022). Computer Vision-Based Wood Identification: A Review. *Forests*, 13(12), pp. 1-26. <https://doi.org/10.3390/f13122041>
- Souza, D. V.; Santos, J. X.; Vieira, H. C.; Naide, T. L.; Nisgoski, S. & Oliveira, L. E. S. (2020). An automatic recognition system of Brazilian flora species based on textural features of macroscopic images of wood. *Wood Science and Technology*, 54(4), pp. 1065-1090. <https://doi.org/10.1007/s00226-020-01196-z>

- Srinivasan, S.; Prabin, S. M.; Mathivanan, S. K.; Rajadurai, H.; Kulandaivelu, S. & Shah, M. A. (2025). Sugarcane leaf disease classification using deep neural network approach. *BMC Plant Biology*, 25(1), pp. 1-20. <https://doi.org/10.1186/s12870-025-06289-0>
- Sugiarto, B.; Suaib, N. M.; Mohd Rahim, M. S.; Prakasa, E.; Fairros Ismail, N. A. & Albakri Mustafa Albakri, I. F. (2024). Wood Species Classification Based on Wood Porosity Distribution of Macroscopic Image. *2024 IEEE International Symposium on Consumer Technology (ISCT)*, Kuta, Bali, Indonesia, 230-235. <https://doi.org/10.1109/ISCT62336.2024.10791236>
- Tang, F.; Porle, R. R.; Tung Yew, H. & Wong, F. (2025). Identification of Maize Diseases Based on Dynamic Convolution and Tri-Attention Mechanism. *IEEE Access*, 13, 6834-6844. <https://doi.org/10.1109/ACCESS.2025.3525661>
- Venugopal, D.; Sandhiya, R.; Swetha, S.; Sredhar, R.; Rohit, N. & Finney Daniel, S. (2024). Machine Learning-based Algorithm for Type of Wood Identification. *2024 International Conference on Emerging Research in Computational Science (ICERCS)*, Coimbatore, India, 1-6. <https://doi.org/10.1109/ICERCS63125.2024.10895161>
- Wang, D. & Zhang, Z. (2025). A Comparison Study of Image Data Augmentation Techniques in Computer Vision. *2025 5th International Conference on Computer Vision, Application and Algorithm (CVAA)*, Ningbo, China, 410-414. <https://doi.org/10.1109/CVAA66438.2025.11193215>
- Wang, G.; Chen, J.; Mo, L.; Wu, P. & Yi, X. (2024). Border-Enhanced Triple Attention Mechanism for High-Resolution Remote Sensing Images and Application to Land Cover Classification. *Remote Sensing*, 16(15), pp. 1-21. <https://doi.org/10.3390/rs16152814>
- Xie, Y. & Ling, J. (2023). Wood defect classification based on lightweight convolutional neural networks. *BioResources*, 18(4), 7663-7680. <https://doi.org/10.15376/biores.18.4.7663-7680>
- Xie, Y.; Zheng, J.; Gou, A.; Sattar, F. & Liao, L. (2025). Log End Face Feature Extraction and Matching Method Based on Swin Transformer V2. *Forests*, 16(1), pp. 1-17. <https://doi.org/10.3390/f16010124>
- Zhang, Z.; Liu, T.; Gao, J.; Yang, M.; Luo, W. & Lin, F. (2025). TDR-Model: Tomato Disease Recognition Based on Image Dehazing and Improved MobileNetV3 Model. *IEEE Access*, 13, pp. 852-865. <https://doi.org/10.1109/ACCESS.2024.3522101>

Financiamiento

Este trabajo forma parte de los proyectos de investigación «Desarrollo de un marco de trabajo de Inteligencia Artificial para integrar y fortalecer las funciones sustantivas en la Universidad Nacional de Loja y su escalabilidad en las Universidades Públicas de Ecuador» (código de proyecto: 32-DI-FEIRNR-2025) y «Sistema para la identificación de maderas de Ecuador», financiados totalmente por la Universidad Nacional de Loja.

Agradecimientos

Extendemos nuestro más sincero reconocimiento a la Universidad Nacional de Loja (UNL) y, en particular, a la Carrera de Computación por su invaluable apoyo y los recursos proporcionados para la realización de esta investigación. Este artículo es el resultado de un esfuerzo académico desarrollado en el marco de la asignatura «Composición de Textos Científicos en Ingeniería», impartida durante el periodo académico comprendido entre septiembre de 2025 y febrero de 2026. Agradecemos la guía y el estímulo intelectual recibidos, que han sido fundamentales para la consecución de este trabajo y para nuestro crecimiento como investigadores en el campo de las ciencias de la computación.

De igual manera, expresamos nuestra gratitud a los técnicos responsables del Laboratorio Dendrocronología de la Carrera de Forestal de la UNL, cuyo respaldo y colaboración han contribuido significativamente al desarrollo de esta investigación.

Declaración de uso de herramientas de IA

Los autores declaran el uso de IA generativa en el proceso de investigación y redacción. Según la Taxonomía de Delegación de IA Generativa (GAIDeT, 2025), se delegaron las siguientes tareas a las herramientas de IA, bajo total supervisión humana: formular preguntas e hipótesis de investigación; redacción de la revisión de la literatura; evaluación de la novedad de la investigación e identificación de lagunas; diseño de investigación; generación de código; generación de texto; texto resumido; traducción; reformatear; evaluación de calidad; identificación de limitaciones.

Las herramientas utilizadas fueron: ChatGPTo4, NotebookLM, Gemini4, Claude (Sonet4.5). La responsabilidad del manuscrito final recae enteramente en los autores. Las herramientas GAI no figuran como autores y no son responsables de los resultados finales.

Nota adicional. NotebookLM: Revisión y sistematización de artículos científicos. Gemini: revisión de calidad, generación de texto. ChatGPT: búsqueda de sinónimos, revisión de calidad. Google IA Studio: mejora de la traducción español-inglés.

Declaración de posibles conflictos de intereses

Los autores no reportan ningún conflicto de intereses.

Declaración de disponibilidad de datos y materiales

Las versiones originales y en alta resolución de las figuras presentadas en este artículo se encuentran disponibles en el repositorio abierto Zenodo (Figuras 1-12), con el propósito de facilitar su consulta, reproducción y adecuada visualización. El conjunto de materiales gráficos puede consultarse en el siguiente registro de búsqueda de Zenodo asociado al trabajo:

https://zenodo.org/search?q=metadata.creators.person_or_org.name%3A%22Alburqueque%2C%20Daniel%22&l=list&p=1&s=10&sort=bestmatch

La documentación audiovisual del desarrollo, implementación y pruebas del modelo se encuentra disponible en una lista de reproducción de YouTube, que reúne los videos correspondientes al proceso experimental y a las pruebas realizadas durante el desarrollo del trabajo:

<https://www.youtube.com/playlist?list=PLEAWdbRe4WpwOWMbVbT4Xuv2qdZooxo-l>

Asimismo, el código fuente desarrollado e implementado durante el proceso experimental se encuentra disponible en un repositorio público de GitHub, lo que permite consultar la implementación del modelo de clasificación de especies maderables, así como favorecer su inspección, reutilización y reproducción:

<https://github.com/Daniel21004/modelo-clasificacion-especies-maderables>

Los materiales gráficos, audiovisuales y de código depositados en estos repositorios constituyen recursos complementarios del trabajo y se ponen a disposición de la comunidad científica para favorecer la transparencia, trazabilidad, reproducibilidad y adecuada documentación de los resultados. En conjunto, estos recursos permiten acceder a las evidencias asociadas con las diferentes etapas del desarrollo experimental, incluyendo las figuras, la implementación computacional del modelo y la documentación audiovisual de su desarrollo, implementación y pruebas.

Rol de cada autor en la investigación según la clasificación (CRediT)

- **Jorge Daniel Ortega Alburquerque:** Conceptualización, curación de datos, investigación, análisis formal, metodología, software, validación, escritura-borrador original, escritura-revisión y edición.
- **Luis Antonio Chamba Eras:** Supervisión, validación, administración de proyecto, escritura-revisión y edición.

Jorge Daniel Ortega Alburquerque

Ingeniero en Ciencias de la Computación por la Universidad Nacional de Loja, Ecuador. Sus líneas de interés incluyen Inteligencia Artificial, aprendizaje automático, ciencia y analítica de datos, con énfasis en el desarrollo de soluciones tecnológicas aplicadas a la identificación de especies, conservación ambiental y biodiversidad.

Correo: jorge.d.ortega@unl.edu.ec

Luis Antonio Chamba Eras

Doctor en Ingeniería Informática, profesor titular de la Universidad Nacional de Loja (Ecuador), investigador acreditado en la SENESCYT (Ecuador). Director del Grupo de Investigación GITIC. Sus líneas de investigación incluyen Inteligencia Artificial aplicada a la educación, sistemas inteligentes, computación social y tecnologías para el aprendizaje, con especial interés reciente en la integración de la IA en la educación superior.

Correo: lachamba@unl.edu.ec

Revista Kawsaypacha: Sociedad y Medio Ambiente.

N° 18 julio – diciembre 2026. E-ISSN: 2709 – 3689

Cómo citar: Ortega Alburquerque, J. D., & Chamba Eras, L. A. (2026). Inteligencia artificial para la conservación forestal: identificación de especies maderables mediante MobileNetV3 y mecanismos de atención en Ecuador. *Revista Kawsaypacha: Sociedad Y Medio Ambiente*, (18), A014. <https://doi.org/10.18800/kawsaypacha.202602.A014>

