

Implementación de tecnologías de inteligencia artificial para optimizar la identificación de especies vegetales

Sergio Arturo Parra¹, Katherine Cárdenas Iriarte², Juan J. Lozano Carvajal³,
Blanca Cecilia López-Ramírez^{4,*}, Michel Felipe Ortiz⁵

¹ Universidad de Cundinamarca,
Facultad de Ingeniería, Sede Fusagasugá,
Colombia

² Universidad de Cundinamarca,
Facultad de Ciencias Agropecuarias, Sede Fusagasugá,
Colombia

³ Universidad de Cundinamarca,
Facultad de Ingeniería, Sede Fusagasugá,
Colombia

⁴ Tecnológico Nacional de México/ I.T. en Roque,
Departamento de Sistemas y Computación,
Mexico

⁵ Universidad de Cundinamarca,
Facultad de Ciencias Agropecuarias, Sede Fusagasugá,
Colombia

blanca.lr@roque.tecnm.mx

Resumen. La pérdida acelerada de diversidad vegetal y las limitaciones de métodos tradicionales de identificación taxonómica demandan soluciones eficientes. Este estudio implementó un modelo de aprendizaje profundo basado en redes neuronales convolucionales con YOLOv8n, para optimizar la identificación automática de especies vegetales en la Unidad Agroambiental La Esperanza, Fusagasugá, Colombia. Se caracterizaron 34 especies en tres lotes mediante muestreo estratificado con transectos de 50m * 2m. Del total identificado, nueve especies cumplieron criterios de representatividad morfológica y frecuencia, conformando un *dataset* de 1607 imágenes digitales de estructuras vegetativas (Hojas, Flores y Frutos) capturadas bajo condiciones controladas. El modelo fue entrenado durante 100 épocas utilizando una arquitectura YOLOv8n optimizada, con división de datos de 70% entrenamiento, 15% validación y 15% prueba. El modelo alcanzó métricas de desempeño sobresalientes, con una precisión (P) promedio de 0.92–1.00, recuperación (R) entre 0.88 y 0.93, F1-score de 0.93 y mAP@50 de 0.974, evidenciando una alta capacidad de detección y clasificación automática. Las especies con mayor número de imágenes (*Elingamita*

johnsonii y *Commelina erecta*) mostraron el mejor rendimiento, mientras que aquellas con menor representatividad presentaron leves descensos en *recall* sin afectar la estabilidad global del modelo. Los resultados demuestran la viabilidad de aplicar redes neuronales convolucionales para la identificación morfológica de flora local, construyendo un avance en la digitalización del conocimiento botánico y una herramienta potencial para la docencia, la investigación y el monitoreo ecológico en entornos agroambientales universitarios.

Palabras clave. Redes neuronales convolucionales, aprendizaje profundo, clasificación botánica.

Implementation of Artificial Intelligence Technologies for Optimization of Plant Species Identification

Abstract. The accelerated loss of plant diversity and the limitations of traditional taxonomic identification methods

demand efficient solutions. This study implemented a deep learning model based on convolutional neural networks using YOLOv8n to optimize the automatic identification of plant species at the "La Esperanza" Agro-environmental Unit in Fusagasugá, Colombia. Thirty-four species were characterized across three plots using stratified sampling with 50m×2m transects. Of the total identified, nine species met the criteria for morphological representativeness and frequency, forming a dataset of 1,607 digital images of vegetative structures (leaves, flowers, and fruits) captured under controlled conditions. The model was trained for 100 epochs using an optimized YOLOv8n architecture, with a data split of 70% for training, 15% for validation, and 15% for testing. The model achieved outstanding performance metrics, with an average Precision (P) of 0.92–1.00, Recall (R) between 0.88 and 0.93, an F1-score of 0.93, and an mAP@50 of 0.974, demonstrating a high capacity for automatic detection and classification. Species with the largest number of images (*Elingamita johnsonii* and *Commelina erecta*) showed the best performance, while those with lower representativeness showed slight decreases in recall without affecting the overall stability of the model. These results demonstrate the feasibility of applying convolutional neural networks for the morphological identification of local flora, representing an advancement in the digitalization of botanical knowledge and a potential tool for teaching, research, and ecological monitoring in university agro-environmental settings.

Keywords: Convolutional neural networks, deep learning, botanical classification.

1. Introducción

La pérdida acelerada de biodiversidad vegetal, impulsada por factores como la expansión agrícola, el cambio climático y la degradación de los ecosistemas, demanda mecanismos eficientes que faciliten la identificación y el monitoreo de especies, como base para la conservación y la gestión ambiental sostenible (Carvalho et al., 2018; Rolnick et al., 2022). Tradicionalmente, la caracterización taxonómica ha dependido de expertos y métodos manuales que, aunque precisos, presentan limitaciones en términos de tiempo, subjetividad y necesidad de personal especializado, especialmente en contextos rurales y académicos donde la disponibilidad de expertos es limitada (Rolnick et al., 2023). Frente a estas restricciones, los avances en inteligencia artificial

(IA), particularmente en el campo de las redes neuronales convolucionales (CNN), han demostrado altos niveles de precisión en la clasificación automática de especies vegetales a partir de imágenes morfológicas, superando significativamente los enfoques tradicionales (Lu et al., 2021; Carvalho et al., 2018).

El desarrollo de aplicaciones basadas en visión por computador ha fortalecido la democratización de la identificación botánica, como lo demuestra la aplicación *Pl@ntNet*, que utiliza redes profundas para permitir la identificación de especies mediante la contribución ciudadana y el procesamiento visual distribuido (Joly et al., 2014). En América Latina, investigaciones recientes han validado el uso de CNN y estrategias de aprendizaje por transferencia para la clasificación de productos agrobiológicos como frutas y hortalizas, alcanzando métricas de precisión competitivas y demostrando la viabilidad de estos modelos en ecosistemas tropicales (Álvarez Canchila et al., 2020; Sejillas et al., 2019).

Asimismo, estudios desarrollados en contextos andinos han evidenciado que la aplicación de IA en el reconocimiento morfológico de especies contribuye al desarrollo de sistemas de monitoreo y bases de datos botánicas como insumo para la investigación aplicada (Lozada Portilla et al., 2021; García-Amaro et al., 2024; López-Ramírez et al., 2024). Sin embargo, persiste una brecha relacionada con la implementación de soluciones adaptadas a microecosistemas concretos, donde factores como iluminación, fenología y variabilidad morfológica influyen directamente en el desempeño de los modelos.

En este sentido, se planteó que el entrenamiento de un modelo de aprendizaje profundo con imágenes estandarizadas de estructuras vegetales clave (hojas, flores, frutos y tallos) provenientes de la Unidad Agroambiental La Esperanza podría optimizar la identificación taxonómica en este ecosistema semiconfinado, reduciendo tiempos de clasificación y aportando un soporte fiable a docentes, investigadores y estudiantes. Esta premisa se fundamentó en la evidencia previa de la eficacia de las CNN en la extracción automática de rasgos visuales complejos, tales como venación foliar, textura y morfología estructural, los cuales son

determinantes en los procesos de clasificación botánica (Lu et al., 2021).

En el presente estudio se diseñó y entrenó un modelo basado en redes neuronales convolucionales utilizando un conjunto de imágenes morfológicas recolectadas en los lotes 3, 4 y 5 de la Unidad Agroambiental La Esperanza, complementado con una base de datos curada y un proceso de preprocesamiento controlado. El modelo alcanzó métricas de desempeño que evidencian una alta precisión en la clasificación automática de especies, lo que sugiere un potencial significativo para su implementación como herramienta de apoyo en procesos de monitoreo de biodiversidad y formación académica. Si bien su aplicabilidad práctica requiere fases posteriores de validación en escenarios naturales más diversos y con variabilidad fenológica, los resultados obtenidos permiten establecer una base científica y tecnológica sólida para futuras implementaciones en entornos agroambientales locales y regionales.

2. Materiales y métodos

2.1. Área de estudio

El estudio se desarrolló en la *Unidad Agroambiental La Esperanza* de la Universidad de Cundinamarca, ubicada en la vereda Guavio Bajo del municipio de Fusagasugá (Cundinamarca, Colombia), el área se sitúa aproximadamente en las coordenadas 4.276072N; -74.386612W a una altitud promedio de 1,530 m s⁻¹ n m (Moreno Sandoval et al., 2022).

Este territorio constituye un agroecosistema de transición interandino, caracterizado por la coexistencia de zonas agrícolas, parches de vegetación secundaria y áreas de conservación, en concordancia con la estructura ecológica reportada para los Andes centrales colombianos (Franco et al., 2016). Estos paisajes de uso mixto son reconocidos por su importancia en la conservación de la biodiversidad y el sostenimiento de prácticas agrícolas sostenibles, al integrar especies nativas y sistemas productivos (Fonseca Carreño et al., 2019).

Para el desarrollo del estudio se seleccionaron los lotes de producción agrícola 3, 4 y 5, que

representan distintos estados de cobertura vegetal: el lote 3 presenta predominancia herbácea con cultivos de ciclo corto; el lote 4 se encuentra en transición sucesional con presencia de arbustos; y el lote 5 corresponde a un espacio de conservación con especies leñosas. Los suelos predominantes son de textura arcillo-limosa, con alto contenido de materia orgánica, similares a los descritos para agroecosistemas andinos de Cundinamarca (Fonseca Carreño et al., 2019).

2.2. Diseño de muestreo y selección de especies

El levantamiento florístico se realizó en la Unidad Agroambiental La Esperanza (Fusagasugá, Cundinamarca) mediante ocho jornadas de campo orientadas a registrar información visual, morfológica y taxonómica con el fin de documentar la diversidad fenotípica disponible para construir un repositorio de imágenes destinado al entrenamiento de un modelo de clasificación basado en redes neuronales convolucionales (CNN). Este enfoque metodológico se sustenta en el uso de CNN para la identificación de especies a partir de imágenes, como evidencian estudios aplicados en reconocimiento de frutos (Olguín Rojas et al., 2022) y clasificación visual automatizada (Montiel González et al., 2022). El muestreo correspondió a un diseño dirigido por representatividad, priorizando especies con alta presencia espacial y rasgos morfológicos diferenciables, lo cual es adecuado cuando el objetivo no es estimar parámetros poblacionales sino capturar variabilidad intra e interespecífica, condición clave para fortalecer la capacidad discriminativa de modelos de aprendizaje profundo (Otzen y Manterola, 2017; Cruz Cruz, 2024; Choque Tarqui et al., 2024) (Reyes-Peralta et al., 2024). Las observaciones de campo se realizaron mediante transectos de tipo *walk-through* (*transect walks*), una estrategia de muestreo recomendable para estudios exploratorios en áreas extensas o heterogéneas, donde la irregularidad topográfica o la variabilidad estructural de la vegetación limita el uso de parcelas permanentes. Este diseño ha sido respaldado en protocolos oficiales de muestreo de vegetación, donde se destaca su utilidad para capturar diversidad general sin necesidad de

estimar densidad o cobertura (USDA Natural Resources Conservation Service., 1999). Asimismo, estudios florísticos que emplean transectos para caracterizar comunidades vegetales refuerzan su pertinencia en entornos con heterogeneidad espacial (Dagne y Birhanu, 2023).

La selección del material vegetal se realizó con base en criterios taxonómicos, ecológicos y morfofuncionales, priorizando especies frecuentes en los lotes y con rasgos diagnósticos claramente distinguibles. La decisión final respondió a tres dimensiones principales: (1) representatividad ecológica, evaluada por su recurrencia y disponibilidad visual; (2) abundancia relativa, para asegurar réplicas suficientes y minimizar sesgos en la construcción del *dataset*; y (3) distintividad morfológica, fundamentales para la discriminación computacional. Este enfoque multidimensional se sustenta en estudios que resaltan la utilidad de los rasgos funcionales en la selección de especies y el análisis comparativo de atributos vegetales (Cogollo Calderón et al., 2020; Muñoz et al., 2022).

La identificación taxonómica se realizó a partir del análisis de las fotografías obtenidas en campo, las cuales fueron evaluadas por un especialista en determinación botánica. Para garantizar precisión en la clasificación, el proceso se apoyó en claves florísticas regionales, literatura botánica primaria y la consulta en bases de datos reconocidas como Tropicos® y Plants of the World Online, complementando la verificación mediante revisión comparativa de rasgos morfológicos. Este procedimiento se ajusta a las buenas prácticas en identificación taxonómica, que recomiendan integrar evaluación experta, revisión documental y fuentes digitales para minimizar errores y asegurar la fiabilidad del registro (Rodríguez et al., 2021; Jiménez Barrios et al., 2020).

2.3. Adquisición y estandarización de datos morfológicos

Se obtuvieron 1 607 imágenes digitales correspondientes a estructuras vegetativas clave (hojas -haz y envés-, flores y frutos), utilizando cámaras digitales de 12 megapíxeles y dispositivos móviles de gama media-alta con sensores equivalentes. La captura se realizó bajo condiciones estandarizadas de luz natural difusa,

empleando fondos neutros (blanco o negro) y una distancia aproximada de 30 cm, siguiendo protocolos de adquisición de imágenes para reconocimiento vegetal asistido por inteligencia artificial (Álvarez Canchila et al., 2020; Castro Tigua et al., 2023; Ayala Niño y González Camacho, 2024).

Las imágenes fueron posteriormente etiquetadas mediante la herramienta LabelImg, incorporando metadatos estructurados que incluyeron: nombre científico y común preliminar, lote de origen, tipo de estructura morfológica, fecha de captura, estado fenológico y coordenadas GPS. Este proceso se ajusta a prácticas estandarizadas en monitoreo ecológico y clasificación digital, donde la anotación precisa de metadatos es fundamental para la reproducibilidad y análisis posterior (Mandujano y Morteo Montiel, 2018). La correcta asignación de clases permitió la conformación de un conjunto de datos balanceado y apto para el entrenamiento de modelos de aprendizaje profundo orientados a la identificación automática de especies vegetales.

2.4. Recursos computacionales y software empleado

El procesamiento de datos y el entrenamiento del modelo se realizaron en un entorno computacional de alto rendimiento equipado con un procesador AMD Ryzen 7 5700G, una GPU NVIDIA GeForce RTX 4060 con 8 GB de VRAM y 32 GB de memoria RAM DDR4. El desarrollo se ejecutó en Python 3.10, utilizando las bibliotecas OpenCV y PIL para el preprocesamiento y manipulación de imágenes, mientras que PyTorch se empleó como backend principal para la construcción y entrenamiento del modelo basado en la arquitectura YOLOv8n, en su implementación oficial proporcionada por Ultralytics. La interfaz web para la interacción con el sistema de clasificación se desarrolló utilizando Gradio, siguiendo enfoques similares a los descritos en aplicaciones de detección vegetal en contextos tropicales (Ramcharan et al., 2017). Esta integración de hardware especializado y herramientas de aprendizaje profundo proporcionó una plataforma robusta y reproducible para la implementación del sistema de identificación automática de especies.

Tabla 1. Dispositivos utilizados en la adquisición de imágenes

Dispositivo	Sistema Operativo	Cámara Principal	Apertura	Resolución de Video	Cámara Frontal
Xiaomi Redmi Note 13	Android 13 (MIUI/HyperOS)	108 MP, sensor gran angular	f/1.7	1080p @ 30 fps	16 MP
Xiaomi Redmi Note 13 Pro	Android 13 (HyperOS)	200 MP, sensor gran angular	f/1.65	4K @ 30 fps / 1080p @ 60 fps	16 MP
iPhone 15	iOS 17	48 MP, gran angular (principal) + 12 MP ultra gran angular	f/1.6 (principal)	4K @ 24/30/60 fps (HDR, Dolby Vision)	12 MP
Honor X7b	Android 13 (MagicOS)	108 MP, sensor gran angular	f/1.75	1080p @ 30 fps	8 MP

Para construir el *dataset* se utilizaron varios teléfonos móviles equipados con cámaras avanzadas.

Esta decisión metodológica buscaba capturar imágenes bajo distintas condiciones de iluminación, distancias variables y niveles de enfoque diferenciados, con el objetivo de mejorar la capacidad de generalización del modelo. Los dispositivos empleados incluyeron un Xiaomi Redmi Note 13, un Xiaomi Redmi Note 13 Pro, un iPhone 15 y un Honor X7b (ver Tabla 1).

Estos equipos integran sensores fotográficos con características técnicas relevantes: estabilización electrónica de imagen, modo HDR, aperturas luminosas y resoluciones que superan los 48 megapíxeles.

La variabilidad introducida por estas diferentes configuraciones ópticas permitió generar un *dataset* más heterogéneo y representativo de las condiciones reales de captura, siguiendo las recomendaciones de la literatura especializada en visión por computador aplicada al sector agrícola.

2.5. Arquitectura del modelo y proceso de entrenamiento

Para la clasificación automatizada de especies vegetales se empleó el modelo YOLOv8n (You Only Look Once, versión nano), una arquitectura de detección basada en redes neuronales convolucionales optimizada para tareas de reconocimiento en tiempo real, derivada del

enfoque original propuesto por Redmon et al. (2016).

La variante “nano” fue seleccionada debido a su equilibrio entre rendimiento y eficiencia computacional, lo que la convierte en una opción adecuada para entornos con recursos limitados.

Estudios han validado la capacidad de YOLOv8 en contextos ecológicos y de monitoreo ambiental. Por ejemplo, Ortenzi et al. (2024) demostraron un desempeño de 0,98 de precisión en la detección de especies marinas a partir de 337 escaneos de video, con tiempos de inferencia promedio de 0,31 s por imagen.

El entrenamiento del modelo se realizó utilizando el conjunto de datos etiquetado, dividido en 70 % para entrenamiento, 15 % para validación y 15 % para prueba, siguiendo buenas prácticas para prevenir el sobreajuste (Jeri y Syarif Hidayat, 2024).

El modelo fue entrenado durante 100 épocas, también llamados ciclos iterativos de aprendizaje, con un tamaño de lote de 32 imágenes, una tasa de aprendizaje de 1×10^{-3} y el optimizador Adam, configuraciones documentadas como estables y eficientes para este tipo de arquitecturas (Jeri y Syarif Hidayat, 2024).

La función de pérdida integrada incluyó los componentes estándar para detección de objetos en YOLOv8: box loss, objectness loss y classification loss, conforme al esquema reportado por Guncay Saldaña et al. (2025).

Tabla 2. Familias botánicas y especies vegetales que conformaron la caracterización inicial

Nombre científico	Nombre común	Familia botánica
<i>Luma Apiculata</i>	Arrayan	Myrtaceae
<i>Ageratum Conyzoides</i>	Botón Morado	Asteraceae
<i>Coffea arabica</i>	Café Variedad Maragojipe	Rubiaceae
<i>Coffea arabica</i>	Café Variedad Colombia	Rubiaceae
<i>Coffea Arabica</i>	Café Variedad Cenicafe	Rubiaceae
<i>Emilia fosbergii</i>	Clavelillo Africano	Asteraceae
<i>Clinopodium chinense</i>	menta china	Lamiaceae
<i>Cyperuz luzuleae</i>	Coquito	Cypereaceae
<i>Inga edulis</i>	Guamo	Fabaceae
<i>Psidium guajava</i>	Guayabo	Myrtaceae
<i>Calyptocarpus Vialis</i>	Hierba de Caballo	Asteraceae
<i>Leonotis nepetifolia</i>	Molinillo	Lamiaceae
<i>Musa paradisiaca</i>	Plátano	Musaceae
<i>Senna spectabilis</i>	Candelillo	Fabaceae
<i>Commelina erecta</i>	Canutillo	Commelinaceae
<i>Elingamita johnsonii</i>	Caucho	Primulaceae
<i>Tephrosia vogelii</i>	Falso Guandul	Fabaceae
<i>Pteridium arachnoideum</i>	Helecho Macho	Dennstaedtiaceae
<i>Bridelia micrantha</i>	Hoja Dorada Costera	Phyllanthaceae
<i>Citrus Reticulada</i>	Limon Mandarinino	Rutaceae
<i>Macadamia integrifolia</i>	Macadamia	Proteaceae
<i>Mangifera Indica</i>	Mango	Anacardiaceae
<i>Arachis pintoii</i>	Maní Forrajero	Fabaceae
<i>Samanea saman</i>	Arbol de lluvia	Fabaceae
<i>Handroanthus chrysanthus</i>	Guayacán amarillo	Zygophyllaceae
<i>Leucaena leucocephala</i>	Leucaena	Fabaceae
<i>Euphorbia heterophylla</i>	Manto Rojo	Euphorbiaceae
<i>Megaskepasma erythrochlamys</i>	Manto rojo (ornamental)	Acanthaceae
<i>Leucaena leucocephala</i>	Vainillo	Fabaceae
<i>Jacaranda mimosifolia</i>	Gualanday	Bignoniaceae
<i>Clinopodium chinense</i>	Clinopodio	Lamiaceae
<i>Brachiaria brizantha</i>	Pasto Brachiaria	Poaceae
<i>Baccharis latifolia</i>	Romerillo	Asteraceae
<i>Oreopanax floribundus</i>	Mano de Oso	Araliaceae

2.6. Evaluación y métricas de desempeño

El desempeño del modelo fue evaluado mediante métricas comúnmente aceptadas en detección y clasificación de imágenes basadas en aprendizaje profundo, incluyendo: precisión (*precision*), que representa la proporción de predicciones positivas correctas; exhaustividad o sensibilidad (*recall*), que mide la capacidad del modelo para identificar correctamente todas las

instancias reales; F1-score, calculado como la media armónica entre precisión y exhaustividad; y mean Average Precision (mAP@50), que estima el rendimiento general considerando un umbral de intersección sobre unión (IoU) del 50 % (Padilla et al., 2020). Estas métricas han demostrado ser efectivas para validar la exactitud y estabilidad de modelos de detección en diversos dominios, como lo evidencian aplicaciones en imágenes médicas (Astudillo Delgado & Revelo Luna, 2022) y

Tabla 3. Validación taxonómica preliminar del dataset

Nombre científico	Nombre común	Familia botánica	Morfología incluida (H/F/T/Fr)	Nº de imágenes (INSTANCIAS)	Rango de confianza (≥60%)
<i>Coffea arabica</i> var. <i>Café Colombia</i> <i>Cenicafé</i>	Café Colombia y Cenicafé	Rubiaceae	H, F, Fr	303	>90 %
<i>Mangifera indica</i>	Mango	Anacardiaceae	H, F, Fr	213	>90 %
<i>Musa paradisiaca</i>	Plátano	Musaceae	H, Fr	43	85–90 %
<i>Leucaena leucocephala</i>	Vainillo	Fabaceae	H, Fr (vaina)	38	85–90 %
<i>Handroanthus chrysanthus</i>	Guayacán amarillo	Bignoniaceae	H, F, Fr	680	>90 %
<i>Jacaranda mimosifolia</i>	Gualanday	Bignoniaceae	H	87	75–85 %
<i>Elingamita johnsonii</i>	Caucho	(Primulaceae)*	H, F	1591	70–80 %
<i>Commelina erecta</i>	Canutillo	Commelinaceae	H, F	1280	80–90 %
<i>Megaskepasma erythrochlamys</i>	Manto rojo	Acanthaceae	H	6	85–90 %

Nota. H: hoja; F: flor; Fr: fruto. Los rangos de confianza corresponden a estimaciones preliminares derivadas de la frecuencia morfológica observada durante la fase de clasificación inicial.

comparaciones de arquitecturas en visión por computador (Niño Rondón et al., 2024).

Para un análisis detallado del comportamiento del modelo, se generó una matriz de confusión, lo cual permitió evaluar los aciertos y errores por categoría, en concordancia con las recomendaciones para medición de precisión temática propuestas por Ariza López et al. (2018). Asimismo, se monitorizaron las curvas de pérdida (*loss*) durante las fases de entrenamiento y validación, con el fin de verificar la convergencia y estabilidad del proceso de aprendizaje, siguiendo criterios metodológicos planteados por Sánchez et al. (2020). Esta combinación de métricas permitió una evaluación rigurosa y comparativa del rendimiento del modelo en la identificación automática de especies vegetales.

2.7. Análisis estadístico

Se realizó un análisis estadístico descriptivo para evaluar el comportamiento del modelo y determinar la variabilidad de su desempeño entre

clases. Para ello, se calcularon valores medios, desviación estándar e intervalos de confianza al 95 % de las métricas de clasificación, lo que permitió identificar posibles sesgos asociados a diferencias en la representación morfológica de las especies. El procesamiento y visualización de los datos se efectuó utilizando las bibliotecas NumPy, Pandas y Matplotlib en Python, siguiendo enfoques similares a los aplicados en estudios de sistematización y análisis de datos ecológicos (Flórez Martínez et al., 2020). Asimismo, la revisión de posibles sesgos interclase se realizó considerando criterios de validación para modelos de reconocimiento de patrones en contextos vegetales, como los propuestos por Morales et al. (2024).

2.8. Consideraciones éticas y reproducibilidad

La investigación cumplió con los principios éticos institucionales establecidos por la Universidad de Cundinamarca, garantizando que la recolección de material vegetal no implicara




Fig. 1. Distribución porcentual estimada de las especies seleccionadas en el dataset final

Nota. Los porcentajes corresponden a una estimación basada en la frecuencia relativa observada durante la captura visual preliminar en campo.




Fig. 2. Curvas de pérdida (loss) en fases de entrenamiento y validación durante 100 épocas

Nota. Se observa una disminución progresiva en las métricas Box Loss, CIs Loss y DFL Loss, lo que indica la convergencia del modelo sin indicios de sobreajuste.

extracción destructiva ni afectación de especies protegidas. Todas las imágenes fueron tomadas sin alterar el entorno natural ni comprometer el estado fisiológico de los individuos.

3. Resultados

3.1. Caracterización florística y conformación del dataset

Durante la caracterización inicial, se identificaron 34 especies vegetales (ver Tabla 2) distribuidas en los lotes 3, 4 y 5 de la Unidad Agroambiental La Esperanza, correspondientes a diferentes familias botánicas representativas de agroecosistemas interandinos. No obstante, luego de aplicar criterios de disponibilidad morfológica, frecuencia de aparición y viabilidad para el entrenamiento del modelo, solo 9 especies cumplieron los criterios mínimos de incorporación, incluyendo la presencia clara de estructuras como hojas, flores y frutos, así como disponibilidad adecuada de registros fotográficos. Estas especies conformaron el dataset final utilizado en el desarrollo del modelo de identificación automática (ver Tabla 3).

La distribución de representatividad visual dentro del conjunto de datos evidenció un marcado desbalance entre las especies registradas. Las de mayor recurrencia fueron *Elingamita johnsonii* (37,5 %) y *Commelina erecta* (30,2 %), seguidas por *Handroanthus chrysanthus* (16,0 %) y las variedades de *Coffea arabica* (7,1 %). En menor proporción se encontraron especies como *Mangifera indica* (5,0 %), *Musa paradisiaca* (1,0 %), *Leucaena leucocephala* (0,9 %), *Jacaranda mimosifolia* (2,0 %) y *Megaskepasma erythrochlamys* (0,1 %). Esta distribución porcentual, representada en la Figura 1, confirma la predominancia de especies con mayor disponibilidad morfológica y densidad vegetal, así como la necesidad de incrementar las muestras correspondientes a especies minoritarias para equilibrar el dataset en futuras fases del proyecto.

El análisis de representatividad por especie evidenció que aquellas con mayor disponibilidad de estructuras morfológicas diversas (por ejemplo, hojas, flores y frutos simultáneamente) aportaron una cantidad más robusta de datos visuales, lo cual es coherente con criterios de eficiencia para la clasificación mediante aprendizaje profundo.

Esto coincide con hallazgos previos que resaltan que la variabilidad morfológica amplía el espectro de patrones durante el entrenamiento y mejora la capacidad del modelo para generalizar

correctamente en escenarios reales (Mulugeta et al., 2024).

3.2. Convergencia del modelo durante el entrenamiento

El modelo YOLOv8n fue entrenado utilizando los registros visuales procesados del *dataset* final, monitorizando la evolución de las funciones de pérdida asociadas a localización (*Box Loss*), clasificación (*Cls Loss*) y estimación de bordes (*DFL Loss*). Durante las primeras épocas, las curvas de entrenamiento registraron valores relativamente altos, característicos de una fase inicial de ajuste. No obstante, conforme avanzó el proceso, se observó una disminución progresiva y sostenida en todas las métricas de pérdida, lo que evidenció una convergencia adecuada del modelo hacia un punto de estabilidad.

En la etapa inicial, la *Box Loss* (*train*) presentó un valor aproximado de 0,045, reduciéndose hasta alcanzar 0,013 en las últimas iteraciones. De manera similar, la *Cls Loss* (*train*) disminuyó de aproximadamente 0,060 a 0,021, mientras que la *DFL Loss* (*train*) pasó de 0,032 a alrededor de 0,010. Las pérdidas registradas en la fase de validación siguieron una tendencia semejante, con valores finales cercanos a 0,016 para *Box Loss* (*val*), 0,027 para *Cls Loss* (*val*) y 0,012 para *DFL Loss* (*val*), lo cual indica que no se evidenció un sobreajuste significativo durante el proceso de entrenamiento (ver Figura 2).

Estos resultados reflejan un comportamiento de aprendizaje estable, con una convergencia progresiva y sin oscilaciones abruptas entre las curvas de entrenamiento y validación. La consistencia entre ambas fases sugiere una adecuada selección de hiperparámetros, así como una correcta representación de las clases en el conjunto de datos. Asimismo, la ausencia de divergencias importantes entre las pérdidas de entrenamiento y validación indica que el modelo alcanzó un equilibrio adecuado entre capacidad de ajuste y generalización.

3.3. Desempeño global del modelo en el conjunto de prueba

Una vez completado el proceso de entrenamiento, el modelo fue evaluado utilizando




Fig. 4. Comparación del F1-score y mAP@50 por especie vegetal incluidas en el modelo

Nota. Se observa mayor rendimiento en especies con estructuras morfológicas reproductivas diferenciables.




Fig. 5. Distribución de frecuencias de las clases de especies en el dataset final

Nota. Los valores representan el número de instancias registradas por clase de especie en el conjunto de datos final. La distribución muestra la frecuencia relativa de cada clase utilizada para el entrenamiento del modelo, con base en los registros fotográficos obtenidos durante la fase de muestreo en campo.

el conjunto de prueba independiente con el propósito de determinar su capacidad de generalización en la clasificación automática de especies vegetales.

Los resultados evidenciaron un rendimiento adecuado en tareas de identificación multiclase, alcanzando valores de precisión y exhaustividad superiores al umbral mínimo esperado para modelos de clasificación en entornos naturales.

Tabla 4. Métricas globales de desempeño del modelo en el conjunto de prueba

Métrica	Valor	Interpretación
Precisión (P)	0.92–1.00	Alta capacidad para evitar falsos positivos.
Recuperación (R)	0.88–0.93	Detecta la mayoría de las instancias reales.
F1-score	0.93	Excelente equilibrio entre precisión y recuperación.
mAP@50	0.974	Exactitud global sobresaliente.
mAP@50–95	0.80	Buen rendimiento incluso con umbrales estrictos.

Nota. P: Precisión; R: Exhaustividad; F1: F1-score; mAP@50: mean Average Precision con umbral de IoU del 50 %; mAP@50–95: promedio de precisión considerando umbrales de IoU entre 50 % y 95 %.




Fig. 3. Matriz de confusión del modelo YOLOv8n aplicado al conjunto de prueba final

Nota. Los recuadros en diagonal representan aciertos por clase; los valores fuera de la diagonal ilustran los casos de clasificación errónea.

Tabla 5. Métricas de desempeño por especie en el conjunto de prueba

Nº	Especie (clase)	Precisión (P)	Recuperación (R)	F1-Score	mAP@50	Interpretación
1	Coffea arabica var. Cenicafé y Colombia	0.979	0.982	0.981	0.995	Alta confiabilidad en detección y clasificación; especies más representadas en el dataset.
2	Mangifera indica	0.978	0.974	0.976	0.995	Desempeño sobresaliente, sin falsos positivos significativos.
3	Musa paradisiaca	0.995	0.975	0.985	0.995	Excelente precisión en frutos y hojas; buena generalización.
4	Leucaena leucocephala	0.962	0.995	0.978	0.995	Alta sensibilidad pese a baja frecuencia de imágenes.
5	Handroanthus chrysanthus	0.980	0.989	0.985	0.994	Buen equilibrio entre precisión y recall; rendimiento estable.
6	Jacaranda mimosifolia	0.995	0.995	0.995	0.995	Clase con excelente consistencia y sin errores de clasificación.
7	Elingamita johnsonii	0.852	0.936	0.891	0.936	Precisión moderada; variabilidad morfológica afectó el desempeño.
8	Commelina erecta	0.977	0.995	0.986	0.995	Muy alta eficiencia; especies con buena representatividad.
9	Megaskepasma erythrochlamys	0.995	0.995	0.995	0.995	Clase sencilla de reconocer por sus características distintivas.

Nota. P: Precisión; R: Exhaustividad; F1: F1-score; mAP@50: mean Average Precision al 50 % de umbral de IoU.

En términos globales, el modelo registró una Precisión (P) promedio superior al 80 %, mientras que la Exhaustividad (recall) se mantuvo en rangos semejantes, lo que permitió obtener un F1-score aceptable dentro de los estándares de desempeño en clasificación vegetal asistida por visión artificial. Adicionalmente, el modelo logró un valor de mAP@50 próximo al 90 %, y un mAP@50-95 ligeramente inferior, como es característico en tareas que exigen mayor precisión espacial (ver Tabla 4).

La matriz de confusión generada evidenció una clasificación mayormente acertada en especies

como *Coffea arabica*, *Mangifera indica* y *Musa paradisiaca*, mientras que se observaron mayores niveles de confusión en especies visualmente relacionadas o con menor número de muestras, tales como *Elingamita johnsonii* y *Arachis pintoi* (ver Figura 3).

La que más detecta la red es la *Elingamita johnsonii* con 1591 instancias, seguida por la *Commelina erecta* con 1280 instancias y por último la *Coffea arabica* con 1152 instancias.

Estos resultados sugieren que el modelo presenta una adecuada capacidad de discriminación entre especies con estructuras




Fig. 6. Frecuencia relativa estimada de imágenes por especie y estructura morfológica en el dataset

Nota. Los valores corresponden a frecuencias relativas de imágenes por estructura morfológica (hoja, flor y fruto) en las especies más representativas del conjunto de datos, obtenidas a partir de la captura visual preliminar en campo.




Fig. 7. Extracto del archivo CSV resultante del análisis por lotes implementado.

morfológicas distintivas, especialmente aquellas con floraciones y frutos notorios.

No obstante, las leves fluctuaciones en precisión entre clases sugieren la necesidad de ajustes adicionales en muestras con menor representatividad visual o con mayor similitud morfológica interclase.

3.4. Rendimiento por clase

Con el fin de evaluar el comportamiento diferencial del modelo frente a cada una de las especies vegetales incluidas en el dataset final, se analizaron los indicadores de desempeño por clase considerando las métricas de Precisión (P),



Fig. 8. Detección automatizada de inflorescencia y racimo en plátano común.



Fig. 9. Identificación simultánea de múltiples frutos de limón en condiciones de campo.

Exhaustividad (recall), F1-score y el mAP@50. En términos generales, se observó un rendimiento favorable en especies con alta disponibilidad de imágenes y estructuras morfológicas bien definidas, como *Coffea arabica* (var. Cenicafe y Café Colombia), *Mangifera indica* y *Musa paradisiaca*, las cuales registraron valores superiores al 85 % en F1-score y mAP@50 (ver Tabla 5).

Por otro lado, especies con menor frecuencia de aparición, o en las que la morfología visual presenta similitudes con especies cercanas (por ejemplo, *Arachis pintoii* o *Elingamita johnsonii*), mostraron ligeras disminuciones en los valores de recall, lo cual indica cierta dificultad del modelo para capturar correctamente todos los casos positivos en estas clases. Sin embargo, estas reducciones no representaron una afectación crítica del desempeño global.

La representación gráfica del rendimiento por clase evidenció que, aunque existen diferencias entre especies, los valores de desempeño se mantuvieron dentro de un rango aceptable,

sugiriendo que el modelo generaliza adecuadamente incluso en especies con representaciones visuales moderadamente limitadas (ver Figura 4).

En conjunto, estos resultados confirman que la representatividad visual y la claridad morfológica de cada especie condicionan el rendimiento específico por clase, lo cual deberá considerarse para futuras optimizaciones del dataset mediante balanceo de clases o estrategias de aumento de datos.

3.5. Evaluación de la distribución y calidad del dataset

Asimismo, se verificó la calidad técnica de las imágenes, considerando aspectos como nitidez, iluminación uniforme, contraste morfológico y estabilidad en el encuadre. La mayoría de los registros cumplió con los criterios de captura establecidos, observándose una adecuada distinción de características estructurales como venación foliar, forma del limbo, disposición floral

y textura del tallo. No obstante, algunas imágenes correspondientes a órganos reproductivos en especies con baja floración durante el periodo de muestreo presentaron variabilidad fenológica limitada, lo que podría afectar su diferenciación frente a clases taxonómicamente cercanas (Álvarez Canchila et al., 2020).

El conjunto de datos final utilizado para el entrenamiento del modelo estuvo conformado por 1607 imágenes, distribuidas en 34 especies vegetales. Cada imagen fue validada según su estructura morfológica y etiquetada de manera uniforme para garantizar consistencia taxonómica.

La distribución de frecuencias de las clases se muestra en la Figura 5, donde se evidencia una concentración en un subconjunto de especies con mayor número de registros, mientras otras presentan menor representación. Este patrón es común en estudios de clasificación vegetal y se asocia a la abundancia relativa y accesibilidad visual de las especies dominantes durante el muestreo (Lu et al., 2021; Dourado Filho et al., 2022).

En términos morfológicos, la Figura 6 ilustra la frecuencia relativa de imágenes por especie y tipo de estructura vegetal (hojas, flores y frutos). Se observó un predominio de imágenes foliares, particularmente en *Jacaranda mimosifolia* y *Megaskepasma erythrochlamys*, atribuible a su mayor disponibilidad y accesibilidad en campo. Las estructuras reproductivas (flores y frutos) tuvieron menor representación debido a factores fenológicos y logísticos de muestreo.

Este comportamiento coincide con lo descrito por Álvarez Canchila et al. (2020) y Castro Tigua et al. (2023), quienes destacan la necesidad de integrar estrategias de captura equilibradas para evitar sesgos en los conjuntos de entrenamiento de modelos basados en visión por computadora.

En conjunto, estas distribuciones sugieren que el dataset presenta una cobertura adecuada en diversidad de especies y estructuras, aunque con predominancia de elementos vegetativos. Esto respalda su utilidad para entrenar redes neuronales convolucionales en tareas de reconocimiento morfológico, garantizando representatividad taxonómica y variabilidad visual suficiente para la generalización del modelo.

3.6. Resultados del proceso de detección automatizada mediante análisis por lotes

El sistema habilitó la ejecución de análisis por lotes sobre conjuntos extensos de material fotográfico, produciendo de manera automatizada un documento en formato CSV que centraliza información exhaustiva respecto a cada elemento botánico identificado.

Este registro documental incorpora variables tales como: denominación del archivo de imagen, taxonomía completa de la clase detectada, taxonomía simplificada, grado de certeza en la predicción, así como las coordenadas normalizadas que delimitan espacialmente cada región de interés (bounding box).

La Figura 7 expone una sección representativa del documento reporte_detecciones.csv, donde se constata la precisión taxonómica y la exactitud espacial en la identificación de órganos vegetales tales como estructuras reproductivas (frutos y flores) y órganos fotosintéticos (hojas). Los valores de confianza registrados, que consistentemente superan el umbral de 0.80, constituyen un indicador directo del rendimiento sobresaliente alcanzado por el modelo implementado.

4. Reconocimiento individual de estructuras reproductivas

El desempeño del modelo fue sometido a prueba mediante la evaluación de imágenes que presentaban configuraciones morfológicas más complejas, específicamente inflorescencias completas de *Musa paradisiaca*. En la Figura 8 se documenta la correcta identificación del racimo fructífero junto con su bráctea floral asociada, delimitados mediante un marco geométrico que se ajusta adecuadamente a la arquitectura tridimensional del objeto detectado.

Este resultado demuestra la aptitud del sistema para procesar y reconocer estructuras vegetales de forma elongada y organización espacial compleja, manteniéndose estable frente a variaciones en las condiciones de sombreado y heterogeneidad del fondo visual. La detección precisa de este tipo de estructuras representa un logro significativo, dado que las inflorescencias de musáceas presentan particularidades

morfológicas que suelen representar desafíos para algoritmos de visión computacional convencionales.

5. Detección simultánea de múltiples instancias frutales

En la fase final de evaluación, se condujeron pruebas sobre material fotográfico caracterizado por alta densidad de objetos de interés, particularmente árboles que exhibían abundante carga frutal distribuida a través del dosel vegetal. El modelo YOLOv8n demostró su capacidad para identificar de forma concurrente múltiples frutos dispersos entre el follaje, registrando entre 5 y 12 detecciones por imagen según la cantidad de estructuras visibles y su grado de oclusión parcial.

La Figura 9 presenta un caso representativo de detección múltiple aplicada a frutos de cítricos en una única composición fotográfica. Este resultado pone de manifiesto la aptitud del sistema para gestionar escenarios de complejidad elevada, donde la superposición parcial de elementos, las variaciones lumínicas localizadas y la densidad de follaje pudieran comprometer el rendimiento de arquitecturas menos sofisticadas. La capacidad para registrar múltiples instancias pertenecientes a una misma clase taxonómica de manera simultánea constituye un atributo fundamental para aplicaciones orientadas al monitoreo fenológico, estimación de rendimiento productivo y caracterización cuantitativa de cultivos.

6. Análisis complementario del rendimiento operacional

Los resultados obtenidos en estas distintas modalidades de evaluación confirman la versatilidad operacional del sistema, evidenciando su capacidad para mantener niveles de precisión consistentes tanto en detecciones unitarias como en análisis masivos por lotes. La arquitectura YOLOv8n empleada ha demostrado un equilibrio favorable entre velocidad de procesamiento y exactitud predictiva, características deseables para implementaciones tanto en contextos de laboratorio como en aplicaciones de campo con requerimientos de respuesta en tiempo real.

La generación automatizada de registros estructurados en formato CSV (ver Figura 7) facilita la trazabilidad de resultados y su posterior análisis estadístico, permitiendo la construcción de bases de datos robustas para estudios longitudinales o comparativos entre diferentes especies, fenologías o condiciones ambientales. Asimismo, la consistencia observada en los niveles de confianza sugiere que el modelo ha alcanzado un grado de generalización adecuado, minimizando tanto falsos positivos como negativos en el rango de especies evaluadas.

7. Discusión

7.1 Interpretación de la riqueza y representatividad florística

La identificación de 34 especies vegetales en los lotes muestreados de la Unidad Agroambiental La Esperanza evidencia la complejidad estructural propia de los agroecosistemas de transición interandinos, caracterizados por una alta heterogeneidad florística y mosaicos de uso mixto que combinan zonas agrícolas con relictos de vegetación secundaria (Fonseca Carreño et al., 2019). Este patrón coincide con lo descrito por Ruiz Marín et al. (2024), quienes destacan que los fragmentos de vegetación secundaria dentro de paisajes agrícolas favorecen la coexistencia de especies nativas y cultivadas, incrementando la diversidad funcional y la estabilidad ecológica del sistema. Sin embargo, la predominancia de especies cultivadas como *Coffea arabica*, *Musa paradisiaca* y *Mangifera indica* refleja una presión antrópica significativa sobre la composición florística, consistente con lo observado por Franco et al. (2016) en agroecosistemas andinos sometidos a intensificación productiva.

Estos resultados reafirman la hipótesis de que la dinámica agrícola condiciona la estructura y diversidad de la vegetación local, configurando un gradiente ecológico entre los lotes agrícolas, de sucesión intermedia y de conservación. Sepúlveda Gómez y Flórez Matamoros (2020) reportaron patrones similares en sistemas agrícolas del centro del país, donde identificaron 90 especies, de las cuales 46 presentaban potencial agrícola, lo que evidencia la riqueza botánica y

multifuncionalidad de estos paisajes de transición. En este contexto, la selección de las nueve especies más representativas para la etapa de modelado responde a criterios metodológicos de equilibrio y suficiencia muestral, ampliamente reconocidos en el desarrollo de modelos de clasificación morfológica basados en inteligencia artificial (Lu et al., 2021). Esta decisión asegura un número adecuado de imágenes por clase y contribuye a mejorar la precisión y capacidad de generalización del modelo durante el entrenamiento.

7.2 Influencia de la distribución de datos y morfología en la precisión del modelo

La distribución heterogénea del número de imágenes por especie influyó directamente en el rendimiento del modelo de clasificación. Las especies con mayor representación y rasgos morfológicos distintivos, como *Coffea arabica* y *Mangifera indica*, alcanzaron valores de F1-score superiores al 85 %, evidenciando una mejor capacidad de identificación. En contraste, las especies con menor número de registros o con morfologías vegetativas más conservadas presentaron leves reducciones en el recall, reflejando una menor sensibilidad del modelo frente a clases subrepresentadas. Este comportamiento ha sido ampliamente documentado en aplicaciones de visión por computadora orientadas a la identificación vegetal, donde la disponibilidad de estructuras reproductivas visibles mejora la precisión del reconocimiento automático (Castro Tigua et al., 2023).

De manera complementaria, Ayala Niño y González Camacho (2024) demostraron que la diferenciación de patrones de nerviación foliar y la variabilidad cromática son factores determinantes en el éxito de las CNN aplicadas a tareas de clasificación botánica. En concordancia, Dourado Filho y Calumby (2022) resaltan que la heterogeneidad de las clases dentro del dataset no solo condiciona la capacidad de aprendizaje del modelo, sino también su generalización interclase. Los resultados obtenidos en este estudio confirman dicha tendencia y sugieren la necesidad de incorporar estrategias específicas de data aumentación para especies con baja

representación, a fin de mitigar sesgos y equilibrar el rendimiento global del modelo.

La distribución heterogénea de las imágenes afectó significativamente el rendimiento del modelo, con especies que tienen más registros y características morfológicas distintivas logrando una mayor precisión de clasificación. Específicamente, especies como *Coffea arabica* demostraron puntuaciones F1 por encima del 85 %, mientras que las especies menos representadas mostraron un recuerdo reducido.

Este fenómeno se alinea con investigaciones anteriores que muestran que la disponibilidad visual de las estructuras reproductivas y las características de las hojas influyen críticamente en la precisión de la clasificación de las plantas Ayala Niño y González Camacho (2024). La distribución del conjunto de datos no solo afectó el aprendizaje del modelo, sino también su capacidad de generalización en diferentes especies Dourado Filho y Calumby (2022).

Los hallazgos sugieren la necesidad de técnicas de aumento de datos específicas, particularmente para especies minoritarias, para mejorar el rendimiento general del modelo y reducir las disparidades de clasificación entre diferentes tipos de plantas.

7.3 Desempeño del modelo y comparación con investigaciones similares

La tasa de convergencia observada en el modelo YOLOv8n fue consistente con los reportes recientes sobre detección automática de especies biológicas en tiempo real, donde se prioriza la eficiencia computacional sin comprometer la precisión (Ortenzi et al., 2024). Durante el entrenamiento, el modelo alcanzó una estabilización progresiva de las funciones de pérdida y una mejora sostenida en las métricas de validación, lo que evidencia una adecuada capacidad de ajuste y generalización. Estos resultados coinciden con estudios que han documentado el alto desempeño del YOLOv8n en contextos ecológicos diversos: Félix Jiménez et al. (2025) reportaron valores de mAP@50 superiores al 90 % en la clasificación de aves tropicales, mientras que Chamorro et al. (2024) validaron su

eficacia en la detección de mamíferos mediante cámaras trampa en entornos de vida silvestre. De forma complementaria, F. da Silva et al. (2024) confirmaron la utilidad de esta arquitectura en el reconocimiento de especies forestales, destacando su equilibrio entre velocidad de inferencia y precisión.

La coincidencia de estos hallazgos con los resultados del presente estudio para las especies mejor representadas refuerza la robustez del modelo y su potencial para aplicaciones botánicas. La naturaleza ligera de la arquitectura YOLOv8n la hace especialmente adecuada para entornos académicos y rurales donde los recursos computacionales son limitados, sin comprometer la calidad de las predicciones. En consecuencia, el modelo se perfila como una herramienta versátil y escalable para la identificación vegetal tanto en campo como en laboratorios de docencia, facilitando la integración de tecnologías de inteligencia artificial en procesos de monitoreo y educación ambiental.

7.4 Implicaciones ecológicas, tecnológicas y educativas

La implementación de un modelo automatizado de identificación vegetal representa un avance significativo tanto para los procesos de monitoreo ecológico como para la formación académica en ciencias de la vida. Desde el punto de vista ecológico, estas herramientas permiten optimizar los inventarios de biodiversidad y reducir la dependencia de la identificación manual, una tarea que tradicionalmente exige tiempo, personal especializado y amplios recursos logísticos (Serafin Higuera et al., 2022; Rubiales Jiménez et al., 2023). En contextos agrícolas y de transición ecológica, su aplicación facilita la obtención de datos morfológicos confiables en menor tiempo, mejorando la capacidad de respuesta ante procesos de cambio ambiental.

En el ámbito educativo, la integración de sistemas de inteligencia artificial en entornos universitarios promueve el aprendizaje activo, la experimentación y el desarrollo de competencias digitales esenciales en carreras agroambientales (Berrones Yaulema y Salgado Oviedo, 2023; González Hernández et al., 2025). Estas tecnologías no solo modernizan la enseñanza

botánica tradicional, sino que fomentan la autonomía del estudiante y la apropiación del conocimiento a través de la interacción con escenarios reales, como la Unidad Agroambiental La Esperanza. Según Criollo Sangoquiza (2025), la utilización de plataformas inteligentes en el aula permite experiencias de aprendizaje personalizadas y participativas, fortaleciendo la relación entre teoría, práctica y sostenibilidad.

En conjunto, la incorporación de modelos automatizados de identificación vegetal constituye una estrategia innovadora que impulsa tanto la investigación aplicada como la formación científica en el marco de la transición hacia una educación superior digital y ambientalmente pertinente.

7.5 Limitaciones y oportunidades de mejora

Si bien el modelo presentó resultados prometedores, se identificaron limitaciones asociadas al desbalance de clases y a la escasez de imágenes correspondientes a estados fenológicos reproductivos en ciertas especies. Esta situación generó confusiones entre categorías con estructuras morfológicas similares, un fenómeno previamente documentado en redes neuronales convolucionales aplicadas a plantas con arquitectura foliar semejante (Zhao et al., 2017). Dichas limitaciones reflejan la necesidad de optimizar el equilibrio de datos y mejorar la diversidad visual en los conjuntos de entrenamiento, aspectos críticos para garantizar la generalización del modelo y su precisión en entornos naturales.

Para mitigar estos efectos, se recomienda incorporar estrategias avanzadas de data augmentation, como rotaciones, escalados, ajustes de brillo y generación sintética de imágenes, las cuales han demostrado eficacia en la reducción de sesgos de clase y mejora del aprendizaje en CNN (Dourado Filho y Calumby, 2022). Además, la aplicación de técnicas de aprendizaje por transferencia mediante arquitecturas más robustas, como los Vision Transformers (ViT), ha mostrado resultados sobresalientes en la clasificación de especies vegetales, alcanzando precisiones superiores al 95 % en estudios recientes (Li et al., 2023; Lee et al., 2023). En paralelo, la integración de metadatos ambientales, como altitud, humedad relativa y

condiciones de crecimiento, puede aportar contexto ecológico adicional para fortalecer la identificación taxonómica (Javed et al., 2025).

La combinación de estas estrategias permitirá superar los desafíos derivados de la similitud morfológica entre especies y la limitada disponibilidad de imágenes fenológicas, mejorando la capacidad predictiva y la contextualización ecológica de los modelos automatizados de identificación vegetal.

7.6 Proyecciones futuras

El modelo desarrollado requiere ser validado en condiciones reales de campo mediante imágenes capturadas en tiempo real, incorporando la variabilidad ambiental asociada a factores como la iluminación, el ángulo de toma y el ruido de fondo. Este proceso permitirá evaluar la robustez del sistema frente a escenarios no controlados, aspecto esencial para su implementación práctica en entornos rurales y educativos. Se proyecta, además, la ampliación progresiva del dataset hacia un mayor número de especies locales, con el propósito de fortalecer la representatividad ecológica y taxonómica del modelo.

En una segunda fase, se prevé la integración del sistema en una aplicación móvil de acceso comunitario, orientada a apoyar estrategias de conservación y educación ambiental. Experiencias previas, como las documentadas por Contreras Chinchilla et al. (2023), evidencian el potencial de las aplicaciones móviles basadas en visión artificial para promover el aprendizaje interactivo, la apropiación del conocimiento botánico y el turismo ecológico responsable. De manera complementaria, los precedentes de Sánchez Huamán (2021) y Martínez Comesaña et al. (2023) resaltan el valor de la inteligencia artificial como mediadora en procesos educativos, al fomentar el aprendizaje autónomo y la participación del usuario.

Finalmente, la incorporación de módulos de retroalimentación dentro de la plataforma permitirá vincular a los estudiantes en procesos de aprendizaje activo y validación de datos, consolidando una herramienta pedagógica sustentada en inteligencia artificial con impactos potenciales en la docencia universitaria, la

investigación aplicada y la conservación ambiental participativa.

8. Conclusiones

El estudio permitió documentar la riqueza florística presente en los lotes de la Unidad Agroambiental La Esperanza, registrando 34 especies vegetales que reflejan la diversidad propia de agroecosistemas de transición interandinos, confirmando la importancia de estos espacios como escenarios de conservación y formación científica.

La caracterización morfológica obtenida mediante un protocolo estandarizado de captura generó una base de datos visual estructurada, constituyendo un insumo confiable para el desarrollo de sistemas de identificación automatizada. La implementación del modelo YOLOv8n demostró un desempeño robusto en términos de precisión, exhaustividad y mAP@50, con especial efectividad en especies con rasgos morfológicos distintivos y adecuada disponibilidad de imágenes.

Aunque se identificaron ligeras reducciones en el desempeño en clases con menor representatividad o similitud visual interclase, ello resalta la necesidad de optimizaciones futuras mediante balanceo del dataset y estrategias avanzadas de data augmentation. El uso de una arquitectura ligera permitió garantizar una relación costo-eficiencia favorable, lo que facilita su implementación en contextos académicos con recursos tecnológicos limitados.

De manera preliminar, se evidencia que la herramienta posee potencial para su aplicación en monitoreo ecológico, procesos de restauración vegetal y apoyo a la educación universitaria en botánica y ciencias agroambientales. Se concluye que la integración de inteligencia artificial representa una estrategia viable para fortalecer la identificación taxonómica, optimizar procesos de monitoreo de biodiversidad y promover la apropiación tecnológica en entornos agroecológicos de formación e investigación.

No obstante, su aplicación práctica requiere validación en escenarios reales de campo y expansión del conjunto de datos antes de su

despliegue definitivo en plataformas interactivas o aplicaciones móviles de uso comunitario.

Agradecimientos

Se agradece a la Universidad de Cundinamarca y a la Unidad Agroambiental La Esperanza por el apoyo institucional y logístico que hicieron posible el desarrollo de este estudio. De igual manera, se reconoce la orientación académica y el acompañamiento brindado por los docentes asesores Cárdenas, K. y Lozano, J., quienes contribuyeron significativamente en la consolidación metodológica y el análisis de resultados. Este trabajo contó con el respaldo financiero de la Universidad de Cundinamarca a través de sus programas internos de fomento a la investigación. Un reconocimiento especial a Milena Samantha Pesantes Arica y a Julián Medina.

Referencias

1. **Álvarez Canchila, O. I., Arroyo Pérez, D. E., Patiño Saucedo, A., Rostro González, H., Patiño Vanegas, A. (2020).** Colombian fruit and vegetables recognition using convolutional neural networks and transfer learning. *Journal of Physics: Conference Series*, Vol. 1547, No. 1, 012020. doi: 10.1088/1742-6596/1547/1/012020.
2. **Ariza López, F. J., Rodríguez-Avi, J., Alba Fernández, V. (2018).** Control estricto de matrices de confusión por medio de distribuciones multinomiales. *GeoFocus Revista Internacional de Ciencia y Tecnología de La Información Geográfica*, pp. 215–226. doi: 10.21138/GF.591.
3. **Astudillo Delgado, V. M., Revelo Luna, D. A. (2022).** Apoyo al diagnóstico de neumonía y detección de opacidades pulmonares usando segmentación e instancias semánticas en imágenes de rayos X de tórax. *Ingeniería y Desarrollo*, Vol. 39, No. 02, pp. 259–274. doi: 10.14482/inde.39.2.621.367.
4. **Ayala Niño, D., González Camacho, J. M. (2024).** Algoritmos de aprendizaje automático para identificar variedades de durazno con base en descriptores cromáticos y morfológicos. *Revista Fitotecnia Mexicana*, Vol. 47, No. 1, pp. 62. doi: 10.35196/rfm.2024.1.62.
5. **Berrones Yaulema, L. P., Salgado Oviedo, S. A. (2023).** La aplicación de la inteligencia artificial para mejorar la enseñanza y el aprendizaje en el ámbito educativo. *Esprint Investigación*, Vol. 2, No. 1, pp. 52–60. doi: 10.61347/ei.v2i1.52.
6. **Carvalho, L. F., Abrão, T., Mendes, L. de S., Proença, M. L. (2018).** An ecosystem for anomaly detection and mitigation in software-defined networking. *Expert Systems with Applications*, Vol. 104, pp. 121–133. doi: 10.1016/j.eswa.2018.03.027.
7. **Castro Tigua, M. F., Sócola Riofrío, J. A., González Sanango, H. (2023).** Desarrollo de Aplicación Móvil con la Identificación Morfológica de Especies Vegetales. *Revista Científica Multidisciplinar G-Nerando*, Vol. 4, No. 2. doi: 10.60100/rcmg.v4i2.176.
8. **Chamorro, D., Benítez, D., Pérez-Pérez, N., Riofrío, D., Grijalva, F., Baldeon-Calisto, M. (2024).** On the Use of YOLOv8 for Detection and Classification of Mammals Species in Wildlife Environments in the Ecuadorian Amazon. *IEEE Biennial Congress of Argentina (ARGENCON)*, pp. 1–8. doi: 10.1109/ARGENCON62399.2024.10735921.
9. **Choque Tarqui, C. E., Gutiérrez Hurtado, M., Ticona Quispe, C. (2024).** Índices de calidad de suelo en Sistemas Convencional y Agroforestal de la Estación Experimental Sapecho. *Revista Ingeniería*, Vol. 8, No. 20, pp. 49–59. doi: 10.33996/revistaingenieria.v8i20.117.
10. **Cogollo Calderón, A. M., Velasco Linares, P., Manosalva, L. (2020).** Caracterización funcional de plantas y su utilidad en la selección de especies para la restauración ecológica de ecosistemas altoandinos. *Biota Colombiana*, Vol. 21, No. 1. doi: 10.21068/c2020.v21n01a01.
11. **Contreras Chinchilla, L. del C., Tafur Rangel, E., Jacome Lindarte, J. M. (2023).** Desarrollo de una solución móvil bajo la tecnología emergente visión artificial para la enseñanza aprendizaje de la fauna. *revista colombiana de tecnologías de avanzada*

- (RCTA), Vol. 2, No. 42, pp. 73–79. doi: 10.24054/rcta.v2i42.2671.
12. **Criollo Sangoquiza, V. A. (2025).** La inteligencia artificial y su incidencia en el aprendizaje de biología. Código Científico Revista de Investigación, Vol. 6, No. E1, pp. 2671–2687. doi: 10.55813/gaea/ccri/v6/nE1/850.
 13. **Cruz Cruz, L. D. (2024).** Ensamble híbrido de métodos para la clasificación morfotaxonomica explicable de macroinvertebrados de agua dulce. pp. 1–12. doi: 10.26507/paper.3565.
 14. **Dagne, Y., Birhanu, L. (2023).** Floristic composition and plant community distribution along environmental gradients in Guard dry Afromontane forest of Northwestern Ethiopia. BMC Ecology and Evolution, Vol. 23, No. 1, 43. doi: 10.1186/s12862-023-02154-6.
 15. **Dourado Filho, L. A., Calumby, R. T. (2022).** Data Augmentation policies and heuristics effects over dataset imbalance for developing plant identification systems based on Deep Learning: A case study. Revista Brasileira de Computação Aplicada, Vol. 14, No. 2, pp. 85–94. doi: 10.5335/rbca.v14i2.13487.
 16. **F. da Silva, A. J., Spancerski, J. S., Schenatto, K., Nisgoski, S., Paula Filho, P. L. de. (2024).** Reconhecimento de espécies florestais Amazônicas utilizando imagens de superfícies transversais. Anais Do XXI Congresso Latino-Americano de Software Livre e Tecnologias Abertas (Latinoware 2024), pp. 250–256. doi: 10.5753/latinoware.2024.245540.
 17. **Félix Jiménez, A. F., Sánchez Lee, V. S., Acuña Cid, H. A., Ibarra Belmonte, I., Arredondo Morales, E., Ahumada Tello, E. (2025).** Integration of YOLOv8 Small and MobileNet V3 Large for Efficient Bird Detection and Classification on Mobile Devices. AI, Vol. 6, No. 3, pp. 57. doi: 10.3390/ai6030057.
 18. **Flórez Martínez, A., Vargas Flórez, J. O., Perez Waltero, H. E., Quintana Fuentes, L. F. (2020).** Análisis de componentes principales utilizando python para identificar clúster asociados a muestras de cacao seco sano e infectado con monilia en Norte de Santander. AiBi Revista de Investigación, Administración e Ingeniería, Vol. 8, No. 2, pp. 16–22. Vol. 10.15649/2346030X.712.
 19. **Fonseca Carreño, N. E., Hernández Baéz, M. A., Moreno Suazo, B. (2019).** Caracterización de Agroecosistemas campesinos en el municipio de Cabrera en la Provincia del Sumapaz-Cundinamarca. Pensamiento Udecino, Vol. 3, No. 1, pp. 49–60. doi: 10.36436/23824905.157.
 20. **Franco, W., Peñafiel, M., Cerón, C., Freire, E. (2016).** Biodiversidad productiva y asociada en el Valle Interandino Norte del Ecuador. Bioagro, Vol. 28, No. 3.
 21. **García-Amaro, E., Cervantes-Canales, J., García-Lamont, F., Lara-Viveros, F.M., Ruiz-Castilla, J. S., Espejel Cabrera, J. (2024).** Use of Computer Vision Techniques for Recognition of Diseases and Pests in Tomato Plants. Computación y Sistemas, Vol. 28, No. 2, pp. 709–723. doi: 10.13053/cys-28-2-3927.
 22. **González Hernández, L., Rudas Murga, C. R., Flores Seefoó, C., Salazar Soplapuco, J. L. (2025).** Inteligencia artificial: Beneficios y desafíos en el ámbito educativo en nivel superior. Revista Tribunal, Vol. 5, No. 10, pp. 253–270. doi: 10.59659/revistatribunal.5i10.114.
 23. **Guncay Saldaña, B. S., Guevara Pando, B. S., Mazón Olivo, B. E., Rivas Asanza, W. B. (2025).** Diagnóstico de enfermedades bucales en imágenes basado en machine learning. Revista Científica Arbitrada Multidisciplinaria PENTACIENCIAS, Vol. 7, No. 3, pp. 176–195. doi: 10.59169/pentaciencias.v7i3.1484.
 24. **Javed, H., Fahad, L. G., Tahir, S. F., Hassan, M., Alquhayz, H. (2025).** Enhanced Plant Species Identification through Metadata Fusion and Vision Transformer Integration. Computers, Materials & Continua, pp. 1–10. doi: 10.32604/cmc.2025.064359.
 25. **Jeri, J., Syarif Hidayat, Z. (2024).** Penentuan Ukuran Batch Optimal Untuk Pelatihan Yolov8 Dalam Pendeteksian Objek Pada Kendaraan Otonom. Networking Engineering Research Operation, Vol. 9, No. 1, pp. 35–48. doi: 10.21107/nero.v9i1.27462.

26. Jiménez Barrios, J., González González, Z., Salazar López, L., Eufragio Blanco, A., Hernández Ruano, B. (2020). Evaluación de una clave taxonómica, para la identificación de los géneros de helechos (Monilophyta), en Guatemala. *Revista Científica*, Vol. 29, No. 2, pp. 31–39. doi: 10.54495/Rev.Cientifica.v29i2.37.
27. Joly, A., Goëau, H., Bonnet, P., Bakić, V., Barbe, J., Selmi, S., Yahiaoui, I., Carré, J., Mouysset, E., Molino, J.-F., Boujemaa, N., Barthélémy, D. (2014). Interactive plant identification based on social image data. *Ecological Informatics*, Vol. 23, pp. 22–34. doi: 10.1016/j.ecoinf.2013.07.006.
28. Lee, C. P., Lim, K. M., Song, Y. X., Alqahtani, A. (2023). Plant-CNN-ViT: Plant Classification with Ensemble of Convolutional Neural Networks and Vision Transformer. *Plants*, Vol. 12, No. 14, 2642. doi: 10.3390/plants12142642.
29. Li, G., Wang, Y., Zhao, Q., Yuan, P., Chang, B. (2023). PMVT: a lightweight vision transformer for plant disease identification on mobile devices. *Frontiers in Plant Science*, Vol. 14. doi: 10.3389/fpls.2023.1256773.
30. López-Ramírez, B. C., Vázquez-Hernández, M. C., Gámez-Vázquez, A. J., Gámez-Vázquez, F. P., Núñez-Prado, C. J. (2025). Multivariate Data Analysis of Growth and Fertilization Response in Jamaica Genotypes (*Hibiscus Sabdariffa* L.). *International Journal of Combinatorial Optimization Problems and Informatics*, Vol. 16, No. 2, pp. 183–190. doi: 10.61467/2007.1558.2025.v16i2.1072.
31. Lozada Portilla, W. A., Suarez Barón, M. J., Avendaño Fernández, E. (2021). Aplicación de redes neuronales convolucionales para la detección del tizón tardío *Phytophthora infestans* en papa *Solanum tuberosum*. *Revista U.D.C.A Actualidad & Divulgación Científica*, Vol. 24, No. 2. doi: 10.31910/rudca.v24.n2.2021.1917.
32. Lu, J., Tan, L., Jiang, H. (2021). Review on Convolutional Neural Network (CNN) Applied to Plant Leaf Disease Classification. *Agriculture*, Vol. 11, No. 8, pp. 707. doi: 10.3390/agriculture11080707.
33. Mandujano, S., Morteo Montiel, O. (2018). Sugerencias para organizar, administrar y exportar datos de foto-trampeo con el programa. *Revista Mexicana de Mastozoología*, Vol. 1, No. 2, pp. 31. doi: 10.22201/ie.20074484e.2018.1.2.263.
34. Martínez Comesaña, M., Rigueira Díaz, X., Larrañaga Janeiro, A., Martínez Torres, J., Ocarranza Prado, I., Kreibel, D. (2023). Impacto de la inteligencia artificial en los métodos de evaluación en la educación primaria y secundaria: revisión sistemática de la literatura. *Revista de Psicodidáctica*, Vol. 28, No. 2, pp. 93–103. doi: 10.1016/j.psicod.2023.06.001.
35. Montesdeoca Espinoza, L. J., Zambrano Rojas, S. J., Pinargote Bravo, V. J., Cedeño Valarezo, L. C. (2025). Balanceo de Conjuntos de Datos Basados en Redes Generativas Aplicado a Imágenes del Sector Agrícola. *Informática y Sistemas*, Vol. 9, No. 2, pp. 164–170. doi: 10.33936/isrtic.v9i2.7782.
36. Montiel González, R., Bolaños González, M. A., Macedo Cruz, A., Rodríguez González, A., López Pérez, A. (2022). Clasificación de uso del suelo y vegetación con redes neuronales convolucionales. *Revista Mexicana de Ciencias Forestales*, Vol. 13, No. 74, pp. 97–119. doi: 10.29298/rmcf.v13i74.1269.
37. Morales, M., Araúz, J., Abrego, J., Guevara, N., Trujillo, J., Bruner-Montero, G., Romero, E. E., Añino, Y. (2024). Identificación taxonómica mediante estadística multivariada de la morfometría en murciélagos panameños *Carollia* (Chiroptera: Phyllostomidae). *Revista de Biología Tropical*, Vol. 72, No. 1, e59197. doi: 10.15517/rev.biol.trop.v72i1.59197.
38. Moreno Sandoval, J. A., Bernal Ovalle, M. C., Acosta Urrego, L. M., Riveros Estepa, D. A. (2022). Evaluation of Biols in Star Grass (*Cynodon nlemfluensis*) for the Livestock Subsector. *Fusagasugá-Colombia Case*. *Revista Ciencias Técnicas Agropecuarias*, Vol. 31, No. 4.
39. Mulugeta, T., Ilomo, M., Mueke, A., Onyango, C., Matsaunyane, L., Kritzinger,

- Q., Alexandersson, E. (2024).** Smallholder farmers' knowledge, attitudes, and practices (KAP) regarding agricultural inputs with a focus on agricultural biologicals. *Heliyon*, Vol. 10, No. 4, e26719. doi: 10.1016/j.heliyon.2024.e26719.
- 40. Muñoz, J., Cuenca, H., Muñoz-Chamba, L., Aguirre, Z. (2022).** Identificación de tipos funcionales de plantas en el bosque andino del Parque Universitario Francisco Vivar Castro. *Bosques Latitud Cero*, Vol. 12, No. 2, 1–12. doi: 10.54753/blc.v12i2.1618.
- 41. Niño Rondón, C. V., Castro Casadiego, S. A., Díaz García, C. Z. (2024).** Evaluación comparativa del rendimiento de modelos de detección de residuos en entornos urbanos. *Revista ambiental agua, aire y suelo*, Vol. 15, No. 1, pp. 122–131. doi: 10.24054/raaas.v15i1.2922.
- 42. Olguín Rojas, J. C., Vasquez Gomez, J. I., López Canteñs, G. de J., Herrera Lozada, J. C. (2022).** Clasificación de manzanas con redes neuronales convolucionales. *Revista Fitotecnica Mexicana*, Vol. 45, No. 3, pp. 369. doi: 10.35196/rfm.2022.3.369.
- 43. Ortenzi, L., Aguzzi, J., Costa, C., Marini, S., D'Agostino, D., Thomsen, L., De Leo, F. C., Correa, P. V., Chatzievangelou, D. (2024).** Automated species classification and counting by deep-sea mobile crawler platforms using YOLO. *Ecological Informatics*, Vol. 82, 102788. doi: 10.1016/j.ecoinf.2024.102788.
- 44. Otzen, T., Manterola, C. (2017).** Técnicas de Muestreo sobre una Población a Estudio. *International Journal of Morphology*, Vol. 35, No. 1, pp. 227–232. doi: 10.4067/S0717-95022017000100037.
- 45. Padilla, R., Netto, S. L., da Silva, E. A. B. (2020).** A Survey on Performance Metrics for Object-Detection Algorithms. 2020 International Conference on Systems, Signals and Image Processing (IWSSIP), pp. 237–242. doi: 10.1109/IWSSIP48289.2020.9145130.
- 46. Ramcharan, A., Baranowski, K., McCloskey, P., Ahmed, B., Legg, J., Hughes, D. P. (2017).** Deep Learning for Image-Based Cassava Disease Detection. *Frontiers in Plant Science*, Vol. 8. doi: 10.3389/fpls.2017.01852.
- 47. Redmon, J., Divvala, S., Girshick, R., Farhadi, A. (2016).** You Only Look Once: Unified, Real-Time Object Detection. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 779–788. doi: 10.1109/CVPR.2016.91.
- 48. Reyes-Peralta, A. E., Pinto-Avendaño, D. E., López-Cortés, F. J., Cerino-Jiménez, R., Padilla-L., Abidán, E., Vilariño-Ayala, D. (2024).** Development of a Customized Image Set for Object Detection in a Materials Synthesis Lab Using Convolutional Neural Networks. *Computación y Sistemas*, Vol. 28, No. 4, pp. 2363–2368. doi: 10.13053/cys-28-4-5359.
- 49. Rodríguez, J. R., Díaz de Arends, M., Wingfield†, R. (2021).** Revisión del género Agave en Venezuela: Variación de la diversidad. *Agroecología Global. Revista Electrónica de Ciencias Del Agro y Mar*, Vol. 3, No. 5, pp. 16. doi: 10.35381/a.g.v3i5.1657.
- 50. Rolnick, D., Donti, P. L., Kaack, L. H., Kochanski, K., Lacoste, A., Sankaran, K., Ross, A. S., Milojevic-Dupont, N., Jaques, N., Waldman-Brown, A., Luccioni, A. S., Maharaj, T., Sherwin, E. D., Mukkavilli, S. K., Kording, K. P., Gomes, C. P., Ng, A. Y., Hassabis, D., Platt, J. C., ... Bengio, Y. (2023).** Tackling Climate Change with Machine Learning. *ACM Computing Surveys*, Vol. 55, No. 2, pp. 1–96. doi: 10.1145/3485128.
- 51. Rubiales Jiménez, J. M., García Álvarez, S., Morales del Molino, C., García-Amorena Gómez del Moral, I., Cepeda Espinosa, J. C., Mairal Pisa, M. (2023).** Aprendizaje botánico mediante el mapeo e identificación de observaciones de plantas con iNaturalist, una plataforma en línea de ciencia ciudadana - [Botanical learning through mapping and identification of plant observations with iNaturalist, an online citizen science platform]. *Innovación Educativa En Los Tiempos de La Inteligencia Artificial*. doi: 10.26754/CINAIC.2023.0075.
- 52. Ruiz Marín, E., Peña, A., Hernández Abril, S. A., Pachón Blanco, L. M., Vargas Ríos,**

- O., Rodríguez Eraso, N. (2024).** Escenarios y alternativas de restauración ecológica en paisajes andinos degradados: el caso de la cuenca alta del río Bogotá (Suesca, Cundinamarca). *Revista de La Academia Colombiana de Ciencias Exactas, Físicas y Naturales*. doi: 10.18257/raccefyn.2671.
53. **Sánchez Huamán, L. G. (2021).** Monitoreo basado en visión computacional de aves en peligro de extinción de la reserva Pantanos de Villa. pp. 212–213. doi: 10.26439/ciis2021.5640.
 54. **Sanchez, S. A., Romero, H. J., Morales, A. D. (2020).** A review: Comparison of performance metrics of pretrained models for object detection using the TensorFlow framework. *IOP Conference Series: Materials Science and Engineering*, Vol. 844, 012024. doi: 10.1088/1757-899X/844/1/012024.
 55. **Seijas, C., Montilla, G., Frassato, L. (2019).** Identificación de especies de roedores usando aprendizaje profundo. *Computación y Sistemas*, Vol. 23, No. 1, pp. 257–266. doi: 10.13053/cys-23-1-2906.
 56. **Sepúlveda Gómez, D. M., Flórez Matamoros, C. (2020).** Oferta Floral con Uso Potencial en Apicultura Durante el Segundo y Tercer Trimestre del Año en la Unidad Agroambiental la Esperanza de la Universidad de Cundinamarca. Universidad de Cundinamarca.
 57. **Higuera, S., Bautista, A., Benavides, A., Mendoza, A. (2022).** Morfología de *Dasyllirion cedrosanum* y su correlación con imágenes en localidades del Sureste de Coahuila. *Ecosistemas y Recursos Agropecuarios*, Vol. 9, No. 1. doi: 10.19136/era.a9n1.3198.
 58. **USDA Natural Resources Conservation Service. (1999).** Sampling Vegetation Attributes Interagency Technical Reference. Technical reference. USDA-NRCS.
 59. **Zhao, Z., Zhang, S., Xu, Z., Bellisario, K., Dai, N., Omrani, H., Pijanowski, B. C. (2017).** Automated bird acoustic event detection and robust species classification. *Ecological Informatics*, Vol. 39, pp. 99–108. doi: 10.1016/j.ecoinf.2017.04.003.

Article received on 04/06/2025; accepted on 11/09/2025.

**Corresponding author is Blanca Cecilia López-Ramírez.*