

WILDEYE: SISTEMA DE RECONOCIMIENTO Y RESCATE DE ANIMALES EN PELIGRO DE EXTINCIÓN MEDIANTE APRENDIZAJE PROFUNDO

WILDEYE: SYSTEM FOR RECOGNIZING AND RESCUING ENDANGERED ANIMALS USING DEEP LEARNING



¹Alejandro José Corro Sabino

¹ Universidad Simón Bolívar

Cómo cita: Corro Sabino, A. (2026). WildEye: Sistema de reconocimiento y rescate de animales en peligro de extinción mediante aprendizaje profundo. Publicaciones E Investigación, 20(1). <https://doi.org/10.22490/25394088.10444>

Recibido 14 Septiembre 2025, Aprobado 10 Octubre 2025

RESUMEN

WildEye propone una plataforma web que integra un clasificador de imágenes, basado en redes neuronales *convolucionales* (CNN, por sus siglas en inglés, Convolutional Neural Networks) con un flujo de gestión de reportes para facilitar la identificación y el rescate de animales potencialmente en peligro de extinción. El sistema permite a los usuarios subir imágenes, obtener la ubicación geográfica de la imagen a partir de metadatos, clasificar el ejemplar y asignar el reporte a las autoridades o corporaciones responsables del departamento y país correspondiente. El modelo se implementó con TensorFlow/Keras y se entrenó con un conjunto de más de 5000 imágenes, distribuidas en 90 categorías. Con este sistema se alcanzó una precisión reportada del 99 % en entrenamiento y del 90 % en pruebas tras 35 épocas (pérdida menor al 1 %).

El artículo presenta la metodología de recolección y preprocesamiento, describe el procedimiento de entrenamiento y las métricas de evaluación, analiza limitaciones (por ejemplo, falta de etiquetado explícito de especies en peligro en el conjunto de datos) y propone líneas de trabajo futuras (ampliación del conjunto con etiquetas de estatus de conservación, validación en campo y adopción de modelos de detección o segmentación para fortalecer la identificación). Los resultados muestran el potencial de integrar aprendizaje profundo y plataformas colaborativas para acelerar la respuesta ante avistamientos y respaldar acciones de conservación.

Palabras clave: aprendizaje profundo; redes neuronales convolucionales; reconocimiento de especies; rescate de fauna; plataforma colaborativa.

ABSTRACT

WildEye proposes a web platform that integrates an image classifier based on convolutional neural networks (CNN) with a reporting management workflow to facilitate the identification and rescue of potentially endangered animals. The system allows users to upload images, retrieves the geographic location of the image from metadata, classifies the specimen, and assigns the report to the authorities or corporations responsible for the corresponding department and country. The model was implemented with TensorFlow/Keras and trained with a dataset of more than 5,000 images distributed across 90 categories, achieving a reported accuracy of ~99 % in training and ~90 % in testing after 35 epochs (loss of 1 %).

The article presents the methodology for data collection and preprocessing, the training procedure and the evaluation metrics, discusses limitations (e.g., lack of explicit endangered species labeling in the dataset) and proposes future lines of work (expansion of the dataset with conservation status labels, field validation, and adoption of detection/segmentation models to strengthen identification). The results highlight the potential of integrating deep learning and collaborative platforms to accelerate responses to sightings and support conservation efforts.

Keywords: *deep learning; convolutional neural networks; species recognition; wildlife rescue; collaborative platform.*



1. INTRODUCCIÓN

La pérdida de biodiversidad es una de las crisis ambientales más relevantes del presente, que se evidencia en evaluaciones científicas en las que se señalan que una fracción significativa de especies está en riesgo. Estimaciones recientes e informes intergubernamentales indican descensos generalizados en la abundancia y que cientos de miles de especies están amenazadas.

La identificación rápida y fiable de ejemplares en riesgo es crítica para la respuesta de las autoridades y la coordinación de rescates. Aunque existen aplicaciones y soluciones de identificación de especies —como ciencia ciudadana (*citizen science*) y iNaturalist, entre otras—, muchas se centran en la identificación y

educación, y no integran un flujo operativo para la notificación y asignación de rescates a las entidades responsables.

Este trabajo presenta WildEye, una solución que combina dos elementos: 1) un clasificador de imágenes basado en CNN para identificar animales a partir de fotografías y 2) una plataforma web que gestiona reportes y asigna la intervención a corporaciones y administradores en la jurisdicción correspondiente. A continuación, se describen los resultados experimentales y la implementación. Las cifras presentadas proceden del póster expuesto en Expotech 2025.

2. MATERIALES Y MÉTODOS

2.1 Fuentes de datos

Se empleó como conjunto de datos principal el Animal Image Dataset (90 Different Animals) Bannerjee (2019), que se complementa con un conjunto adicional de imágenes recopiladas y curadas por el equipo de investigación. En total, el corpus incluyó más de 5000 imágenes distribuidas en 90 categorías (aproximadamente 5400 imágenes según la fuente original). Las imágenes se dividieron en subconjuntos de entrenamiento, validación y prueba, de acuerdo con las buenas prácticas en aprendizaje automático, lo que garantizó la separación por categorías y la preservación de la distribución global.

2.2 Preprocesamiento


Las imágenes se convirtieron a formatos estándar (JPEG o PNG), con una dimensión de 224×224 píxeles, un valor consistente con arquitecturas CNN modernas como EfficientNet-B0. Posteriormente, se

normalizó la escala de intensidad de píxeles al rango (0,1). Para mitigar el sobreajuste, se aplicaron técnicas de aumento de datos, como rotación aleatoria, traslación, volteo horizontal, ajustes de brillo o contraste y supresión parcial aleatoria (random erasing). Estas técnicas incrementan la diversidad del conjunto de entrenamiento y mejoran la capacidad de generalización del modelo.

2.3 Arquitectura y entrenamiento del modelo

El conjunto de datos se dividió inicialmente con un 80 % de imágenes para entrenamiento y un 20 % para validación. El modelo se implementó en TensorFlow/Keras, utilizando como base EfficientNet-B0, una arquitectura ampliamente reconocida por su balance entre rendimiento y eficiencia computacional. El entrenamiento se realizó durante 35 épocas, empleando el optimizador Adam y una tasa de aprendizaje ajustada dinámicamente. Se alcanzó una precisión del 99 % en el conjunto de entrenamiento y del 90 % en el de prueba, con una pérdida inferior al 1 %.

Figura 1. Curvas de precisión y pérdida durante el entrenamiento del modelo EfficientNet-B0



Fuente: Elaboración propia.

3. DESARROLLO

3.1 Generalidades de la conservación asistida por inteligencia artificial

La incorporación de la inteligencia artificial (IA) en los procesos de conservación de la biodiversidad se ha consolidado como un campo emergente de gran relevancia. Diversos autores han documentado que el aprendizaje profundo permite superar las limitaciones de los métodos tradicionales de monitoreo, debido a la automatización de la identificación de las especies, lo que ha acelerado los procesos de análisis en campo (Christin et al., 2019; Norouzzadeh et al., 2018). Estas aproximaciones han establecido las bases para plataformas colaborativas que integran la ciencia ciudadana con sistemas inteligentes, trayendo consigo un nuevo paradigma en la conservación digital.

3.2 Corrientes de aplicación en el reconocimiento automatizado de la fauna

Existen múltiples líneas de aplicación que abordan la clasificación automática de especies. Algunas propuestas priorizan la eficiencia en entornos con baja capacidad computacional, utilizando arquitecturas ligeras como MobileNet o EfficientNet (Tan y Le, 2019). Otras se enfocan en maximizar la precisión mediante arquitecturas profundas como ResNet y DenseNet (He et al., 2016; Huang et al., 2017). La elección de la arquitectura depende del equilibrio entre los recursos disponibles y la necesidad de exactitud, lo que ha dado lugar a distintas estrategias para implementarlas en plataformas de conservación.

3.3 Comparación de teorías y modelos en plataformas colaborativas

Desde la perspectiva de la gestión de datos ambientales, se pueden contrastar dos grandes enfoques:

- Modelos centralizados de conservación: Concentran el control en instituciones académicas o gubernamentales (Macreadie et al., 2021);

- Modelos colaborativos de monitoreo: Permiten la participación ciudadana para ampliar la cobertura espacial y temporal (Pimm et al., 2015).

El sistema WildEye se adscribe a la segunda corriente, al integrar a los usuarios como actores activos en la captura de información, mientras que las corporaciones ambientales cumplen la función de validación y acción.

3.4 Casos de éxito y fracaso en proyectos similares

Plataformas como iNaturalist y eBird han demostrado la viabilidad del uso de ciencia ciudadana apoyada en herramientas tecnológicas, con la consolidación de bases de datos globales sobre biodiversidad (Sullivan et al., 2014; Sullivan et al., 2009). No obstante, experiencias en África y América Latina evidencian limitaciones asociadas a la calidad de las imágenes, la conectividad y la falta de estandarización en los metadatos (Steenweg et al., 2017). Estos hallazgos subrayan la importancia de integrar procedimientos robustos de validación y protocolos de interoperabilidad en sistemas emergentes como WildEye.

3.5 Evolución de la inteligencia artificial aplicada a la conservación

Esta se ha caracterizado por una transición desde modelos clásicos de visión por computadora hacia CNN y, más recientemente, arquitecturas basadas en transformers y aprendizaje multimodal (Dosovitskiy et al., 2021). Este progreso ha permitido mejorar la precisión, pero también ha planteado retos en términos de escalabilidad y explicabilidad de los modelos, factores críticos para la aceptación en contextos sociales y ambientales.

3.6 Factores de éxito para proyectos de adopción de Inteligencia Artificial en conservación de la fauna

El análisis derivado de la aplicación de instrumentos de comparación permite identificar diversos

factores determinantes para el éxito en proyectos de esta naturaleza:


- **calidad y diversidad del conjunto de datos:** Influye directamente en la capacidad de generalización del modelo;
- **interoperabilidad de la plataforma:** Asegura la integración en sistemas institucionales y redes internacionales de conservación;
- **participación ciudadana activa:** Amplía la cobertura espacial y fortalece la conciencia ambiental;
- **capacidades técnicas y financieras de las corporaciones:** Necesarias para mantener el sistema y escalar sus funcionalidades.

Estos factores se alinean con hallazgos de literatura reciente sobre la implementación de herramientas de IA en sectores críticos (Rolnick et al., 2023; McMillan et al., 2021), reforzando la importancia de combinar robustez tecnológica con apropiación social.

4. RESULTADOS

El modelo de clasificación implementado en WildEye alcanzó un desempeño consistente a lo largo de las fases de entrenamiento y validación. Tras 35 épocas de entrenamiento con un conjunto de aproximadamente 5400 imágenes distribuidas en 90 categorías, se obtuvo una precisión cercana al 99 % en el conjunto de entrenamiento y del 90 % en el conjunto de prueba, con una pérdida inferior al 1 %. Estos valores evidencian la capacidad del modelo EfficientNet-B0 para generalizar adecuadamente pese a la limitación en el tamaño del conjunto de datos, lo que garantiza un nivel aceptable de confiabilidad para su integración en la plataforma web. Además, la implementación permitió comprobar el correcto funcionamiento del flujo de reportes, en el que las imágenes cargadas por los usuarios fueron clasificadas automáticamente y geolocalizadas mediante metadatos, asignando la información a la corporación ambiental correspondiente según el país y el departamento.

Figura 2. Rendimiento del modelo basado en EfficientNet-B0 a lo largo de 35 épocas de entrenamiento y validación.



Fuente: Elaboración propia.

5. DISCUSIÓN

El análisis comparativo entre distintas corrientes de pensamiento, aplicaciones previas y la experiencia de WildEye permite observar que la IA aplicada a la conservación ofrece oportunidades significativas, pero también enfrenta desafíos estructurales. Entre los beneficios destacan la aceleración en la identificación de especies y la posibilidad de articular actores ciudadanos e institucionales en un mismo ecosistema digital. Asimismo, la literatura revisada resalta que la transición hacia modelos colaborativos de conservación digital ha permitido ampliar la cobertura espacial y temporal de los registros de biodiversidad, creando una base más sólida para la toma de decisiones ambientales.

No obstante, el proyecto presenta limitaciones específicas que condicionan su alcance. En primer lugar, el conjunto de datos empleado para entrenar el modelo es limitado, lo que restringe la capacidad de generalización y puede comprometer la precisión en la identificación de ciertas especies. En segundo lugar, la necesidad de que los usuarios complementen la identificación de las especies introduce un margen de error asociado a la interpretación individual, lo que podría generar inconsistencias en los registros si no se establecen mecanismos de validación.

La literatura consultada (aproximadamente 20 referencias) muestra que la evolución de la conservación digital está marcada por el tránsito hacia modelos colaborativos potenciados por IA, cuya implementación exitosa depende de la integración social, tecnológica e institucional. En este contexto, WildEye constituye una aportación innovadora que ofrece la posibilidad de fortalecer capacidades compartidas para la protección de fauna en peligro de extinción, siempre que se atiendan las limitaciones señaladas mediante estrategias de expansión progresiva del conjunto de datos y la adopción de protocolos que reduzcan la subjetividad en la identificación ciudadana.

6. CONCLUSIONES

La evolución de la IA aplicada a la conservación evidencia un tránsito progresivo desde enfoques centralizados hacia modelos colaborativos, en los que la ciencia ciudadana se convierte en un pilar fundamental para la recolección de datos. WildEye se inscribe en esta tendencia aportando una herramienta que combina un modelo de aprendizaje profundo con la participación de los usuarios y la validación institucional.

Si bien persisten limitaciones asociadas al tamaño del conjunto de datos y a la necesidad de identificación inicial por parte de los usuarios, estos aspectos reflejan retos estructurales del campo más que debilidades intrínsecas del sistema. Su relevancia resulta notoria en contextos donde los recursos para monitoreo son limitados, proporcionando una alternativa práctica para ampliar la cobertura espacial y fortalecer la capacidad de respuesta ante la pérdida de biodiversidad.

Así, el proyecto no solo ilustra la evolución en la literatura científica, sino que también establece un marco aplicable al contexto local de gestión ambiental, puesto que facilitan insumos que pueden ser utilizados por corporaciones y comunidades para la toma de decisiones sobre la conservación de especies en peligro de extinción.

REFERENCIAS

- Banerjee, S. (2019). Animal Image Dataset (90 Different Animals). Kaggle. <https://www.kaggle.com/datasets/iamsouravbanerjee/animal-image-dataset-90-different-animals>
- Christin, S., Hervet, É., & Lecomte, N. (2019). Applications for deep learning in ecology. *Methods in Ecology and Evolution*, 10(10), 1632-1644. <https://doi.org/10.1111/2041-210X.13256>
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., & Houlsby, N. (2021). An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale (Versión 2). arXiv.scale. International Conference on Learning Representations (ICLR). <https://doi.org/10.48550/ARXIV.2010.11929>

- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778. <https://doi.org/10.1109/CVPR.2016.90>
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely Connected Convolutional Networks. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2261-2269. <https://doi.org/10.1109/CVPR.2017.243>
- Macreadie, P. I., Costa, M. D. P., Atwood, T. B., Friess, D. A., Kelleway, J. J., Kennedy, H., Lovelock, C. E., Serrano, O., & Duarte, C. M. (2021). Blue carbon as a natural climate solution. *Nature Reviews Earth & Environment*, 2(12), 826-839. <https://doi.org/10.1038/s43017-021-00224-1>
- McMillan, N. A., Fuhlendorf, S. D., Luttbeg, B., Goodman, L. E., Davis, C. A., Allred, B. W., & Hamilton, R. G. (2021). Are bison movements dependent on season and time of day? Investigating movement across two complex grasslands. *Ecosphere*, 12(1), e03317. <https://doi.org/10.1002/ecs2.3317>
- Norouzzadeh, M. S., Nguyen, A., Kosmala, M., Swanson, A., Palmer, M. S., Packer, C., & Clune, J. (2018). Automatically identifying, counting, and describing wild animals in camera-trap images with deep learning. *Proceedings of the National Academy of Sciences*, 115(25). <https://doi.org/10.1073/pnas.1719367115>
- Pimm, S. L., Alibhai, S., Bergl, R., Dehgan, A., Giri, C., Jewell, Z., Joppa, L., Kays, R., & Loarie, S. (2015). Emerging Technologies to Conserve Biodiversity. *Trends in Ecology & Evolution*, 30(11), 685-696. <https://doi.org/10.1016/j.tree.2015.08.008>
- 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*, 55(2), 1-96. <https://doi.org/10.1145/3485128>
- Steenweg, R., Hebblewhite, M., Kays, R., Ahumada, J., Fisher, J. T., Burton, C., Townsend, S. E., Carbone, C., Rowcliffe, J. M., Whittington, J., Brodie, J., Royle, J. A., Switalski, A., Clevenger, A. P., Heim, N., & Rich, L. N. (2017). Scaling-up camera traps: Monitoring the planet's biodiversity with networks of remote sensors. *Frontiers in Ecology and the Environment*, 15(1), 26-34. <https://doi.org/10.1002/fee.1448>
- Sullivan, B. L., Aycrigg, J. L., Barry, J. H., Bonney, R. E., Bruns, N., Cooper, C. B., Damoulas, T., Dhondt, A. A., Dietterich, T., Farnsworth, A., Fink, D., Fitzpatrick, J. W., Fredericks, T., Gerbracht, J., Gomes, C., Hochachka, W. M., Iliff, M. J., Lagoze, C., La Sorte, F. A., ... Kelling, S. (2014). The eBird enterprise: An integrated approach to development and application of citizen science. *Biological Conservation*, 169, 31-40. <https://doi.org/10.1016/j.biocon.2013.11.003>
- Sullivan, B. L., Wood, C. L., Iliff, M. J., Bonney, R. E., Fink, D., & Kelling, S. (2009). eBird: A citizen-based bird observation network in biological sciences. *Biological Conservation*, 142(10), 2282-2292. <https://doi.org/10.1016/j.biocon.2009.05.006>
- Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. <https://doi.org/10.48550/ARXIV.1905.11946>