



UNIVERSIDAD MICHOACANA DE SAN NICOLÁS DE HIDALGO

Instituto de Investigaciones sobre los Recursos Naturales

MONITOREO DE PERROS FERALES A TRAVÉS DE FOTOTRAMPEO Y ANÁLISIS INFORMÁTICO EN EL PARQUE NACIONAL BARRANCA DEL CUPATITZIO EN URUPAN, MICHOACÁN, MÉXICO

TESIS

Que presenta

Ing. Enil Perales Calderón
Correo: 2330384j@umich.mx
Matrícula: 2330384J

**Como requisito para obtener el título de
Maestro en Ciencias en Ecología Integrativa**

Tutor de Tesis:

Dr. Eduardo Mendoza Ramírez
Correo: eduardo.mendoza@umich.mx

Morelia Michoacán. Junio de 2025.



Agradecimientos

A la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI) por el apoyo brindado a través de la beca, durante mis estudios y trabajo de investigación de posgrado.

A la Universidad Michoacana de San Nicolás de Hidalgo (UMSNH) y al Instituto de Investigaciones sobre los Recursos Naturales (INIRENA), por brindarme un espacio de desarrollo y aprendizaje. Al Laboratorio de Análisis para la Conservación de la Biodiversidad (LACB) por darme la oportunidad de adentrarme en el mundo de la ecología, por la apertura y amabilidad con la que me trataron. A la Comisión Nacional de Áreas Naturales Protegidas (CONANP) por proporcionarme las facilidades y las herramientas necesarias para el desarrollo de mi investigación, en particular al sr. Alfredo Graciarreal por compartir sus conocimientos de la zona y siempre procurar nuestra seguridad. Agradezco profundamente al Comité de Vigilancia y Monitoreo Comunitario del Programa para la Protección y Restauración de Ecosistemas y Especies Prioritarias (PROREST) por su valioso apoyo y compromiso durante el desarrollo de este trabajo.

Al Dr. Eduardo Mendoza Ramírez, mi asesor, por confiar en mí, por brindarme la oportunidad de adentrarme en un mundo que siempre soñé explorar, y por su paciencia y apertura para compartir e investigar temas de tecnología aplicada a la ecología.

A los miembros de mi comité sinodal, la Dra. Isela Edith Zermeño Hernández, el Dr. Rafael Hernández Guzmán, el Dr. Luis Felipe Mendoza Cuenca y el Dr. Javier Salgado Ortiz, por sus valiosos comentarios, observaciones y enseñanzas, que contribuyeron de manera significativa al fortalecimiento y mejora de este trabajo.

A mis compañeros, maestros y amigos que siempre encontraron la forma de hacer un buen chiste, aun en los días difíciles. A la comunidad de estudiantes e investigadores que me invitaron a participar en sus viajes de campo y con los que tuve la fortuna de convivir. A mi novia, por inspirarme constantemente, por impulsarme a descubrir la naturaleza con ojos nuevos y por enseñarme a maravillarme con la belleza del mundo, por tu luz en este camino.

Con profunda gratitud, a Franceli Macedo, María Lourdes Barriga Carbajal, Gonzalo Alejandro Hernández Ayala y Jonatan Torres Pérez Coeto, por haber compartido conmigo su conocimiento, guía y generosidad, que dejaron una huella invaluable en mi formación.

A mis padres, por la vida que me han dado, por enseñarme con su ejemplo los valores que me guían y por ser el pilar inquebrantable que me sostuvo en cada paso. Hoy, al estudiar la vida con mayor profundidad, comprendo aún más el inmenso amor y sacrificio detrás de cada gesto suyo. Gracias por todo, con todo mi corazón. A mi hermano por siempre ser un apoyo incondicional y siempre velar por mi seguridad.

Gracias a mis amigos cercanos Jesús, Julio, Thalía y Edgar, que, a pesar de no entender mis decisiones, siguen estando a mi lado, dándome consejos e impulsándome a seguir adelante.

Gracias a mi banda de rock VL, por animarme a seguir viendo la vida como una canción, por los momentos compartidos y los eventos donde hemos participado

¡Gracias totales!

ÍNDICE DE CONTENIDO

I. Resumen general.....	7
II. General abstract.....	8
III. Introducción general.....	10
IV. Objetivo General.....	13
V. Objetivos Específicos.....	14
VI. Hipótesis.....	14
VII. Predicciones.....	15
VIII. Justificación.....	15
IX. Referencias.....	17
X. Capítulo I.....	19
Abstract.....	20
Introduction.....	20
Materials and Methods.....	23
Results.....	27
Discussion.....	33
References.....	37
Supplementary material.....	43
XI. Capítulo II.....	49
Introducción.....	50
Objetivos.....	60
Materiales y Métodos.....	60
Resultados.....	64

Discusión.....	73
Referencias	78
Material suplementario	81
XII. Discusión general.....	84
XIII. Referencias	86

ÍNDICE DE FIGURAS

Capítulo I

Figure 1. The location of the Barranca del Cupatitzio National Park in Michoacán, western México, and the camera-trapping design used to record focal carnivorous mammal species.....	21
Figure 2. Focal species recorded by camera traps in the protected area Barranca del Cupatitzio National Park, located in the municipality of Uruapan, Michoacán, western México.....	25
Figure 3. Relative recording frequency of camera-trapping events.....	25
Figure 4. Daily activity levels.....	26
Figure 5. Patterns of daily activity.....	28
Figure 6. Comparison of temporal (daily activity) and spatial overlap.....	29
Figure S1. Individual activity patterns.....	40
Figure S2. Number of records per camera of the specie: Dog (<i>Canis lupus familiaris</i>).....	42
Figure S3. Number of records per camera of the specie: Coyote (<i>Canis latrans</i>).....	43
Figure S4. Number of records per camera of the specie: Gray Fox (<i>Urocyon cinereoargenteus</i>).....	44
Figure S5. Number of records per camera of the specie: Bobcat (<i>Lynx rufus</i>).....	45

Capítulo II

Figura 1. Proceso de entrenamiento de una red neuronal convolucional.....	48
Figura 2. Proceso de creación de un modelo personalizado para la detección de objetos.....	51
Figura 3. Etiquetado en la plataforma © RoboFlow.....	52
Figura 4. Ejemplos de imágenes de fototrampeo.....	53
Figura 5. Representación de la inferencia para la ubicación de un objeto dentro de una imagen.....	55
Figura 6. Curvas de parámetros de precisión y pérdida.....	56
Figura 7. Ejemplo de un lote de 16 imágenes utilizado durante el entrenamiento.....	60
Figura 8. Efectividad del Modelo 1 y el Modelo yolov8s.pt.....	63
Figura 9. Ejemplos de detecciones realizadas por el Modelo 1.....	64
Figura 10. Efectividad del Modelo 2.....	67
Figura 11. Ejemplos de detecciones correctas del Modelo 2.....	69
Figura S1. Distribución de las cámaras trampa utilizadas.....	78
Figura S2. Curvas de pérdida (loss) y precisión del entrenamiento del Modelo 1.....	79
Figura S3. Curva F1 de confianza, curva Precision-Recall Modelo 1.....	80
Figura S4. Curvas de pérdida (loss) y precisión del Modelo 2.....	80
Figura S5. Curva F1 de confianza, curva Precision-Recall Modelo 2.....	81

ÍNDICE DE TABLAS

Capítulo I

Table 1. Comparison of daily activity patterns of focal mammal species.....	27
Table 2. Jaccard index level of spatial coincidence of focal mammal species	28
Table S1a. Activity levels of species.....	40
Table S1b. Comparison of activity levels between the species.....	41

Capítulo II

Tabla 1. Error y métricas de validación del entrenamiento de un modelo.....	55
Tabla 2. Características de los modelos utilizados en este estudio	59
Tabla 3. Detecciones del Modelo 1 en primer filtrado vacías y con objetos.....	65
Tabla 4. Detecciones del Modelo Pre-entrenado filtrado personas y vehículos	65
Tabla 5. Detecciones del Modelo 2 para el análisis de vida silvestre de forma automatizada	68
Tabla 6. Comparación del tiempo clasificación manual y clasificación automatizada	70

I. Resumen general

Las áreas naturales protegidas ANPs tienen como objetivo preservar los procesos ecológicos y la biodiversidad. Sin embargo, las especies que habitan las ANPs están amenazadas por distintos efectos derivados de las actividades humanas o tienen un rol clave en sus ecosistemas. Una amenaza en particular que afecta a las especies nativas de las ANPs es la introducción de especies invasoras. Un ejemplo son los impactos asociados con la presencia de perros (*Canis lupus familiaris*). Esta tesis está dividida en dos partes. En la primera, se evaluó el potencial que tienen para interactuar los perros y tres especies de mesocarnívoros nativos: coyote (*Canis latrans*), Lince rojo (*Lynx rufus*) y zorra gris (*Urocyon cinereoargenteus*), en el Parque Nacional Barranca del Cupatitzio (PNBC) en Uruapan, Michoacán, México. Se colocaron cámaras trampa de enero del 2023 a marzo del 2024 en 10-11 estaciones repartidas en el parque y separadas entre sí en promedio por 1.5 km. Con la información obtenida evalué el grado de actividad diaria de cada especie y su traslape (Δ), entre pares. Además, evalué el grado de traslape espacial (Índice de Jaccard = IJ), entre las especies focales. En la segunda parte de la tesis, desarrollé una propuesta metodológica para el análisis automatizado de imágenes de fototrampeo con el fin de distinguir entre a) imágenes vacías e imágenes donde se registraba algún objeto (animal) y b) imágenes de perros, coyotes y zorra gris. Para este fin, utilicé la biblioteca de código abierto “YOLOV8” © Ultralytics para entrenar dos modelos de visión por computadora basados en MobileNetSSDv2 (MobileNet Single Shot Detector) para el filtrado y clasificación de especies en registros de fototrampeo (imágenes y videos). Se obtuvieron 1,139 registros (imágenes y videos) de las cuatro especies focales (455 cuando se agruparon en intervalos de 24 horas) en 3,633 días de cámara trampa. La especie con la frecuencia de registro más alta fue *U. cinereoargenteus* ($n = 253$), y la más baja fue *L. rufus* ($n = 25$). La

especie más activa durante el día fue *C. lupus familiaris* (61%) y la menos activa fue *U. cinereoargenteus* (24%). Las especies que mayor traslape tuvieron en su actividad diaria fueron *C. latrans* y *C. lupus familiaris* ($\Delta = 0.81$) y las que menos fueron *C. lupus familiaris* y *L. rufus* ($\Delta = 0.58$). Las especies con mayor coincidencia espacial fueron *C. latrans* y *U. cinereoargenteus* (IJ = 0.84), y las especies con menor coincidencia fueron *L. rufus* con *C. latrans* (IJ = 0.28). Por su parte los modelos de visión por computadora permitieron clasificar correctamente al 90% de las imágenes vacías y el 88% de las imágenes con objetos, por una parte, y por otra identificaron correctamente imágenes con perros en el 60% de los casos, en 65% en el caso de los zorros y 57% de los coyotes. Los hallazgos de esta tesis ponen en evidencia la alta posibilidad de interacciones entre mesodepredadores del PNBC y los perros, dando paso a los efectos que estos provocan sobre la biodiversidad del parque y también la aplicabilidad de la visión por computadora como herramienta de apoyo en proyectos de fototrampeo.

Palabras clave: aprendizaje automático, especies exóticas, interacciones antagónicas, mesopredadores, visión por computadora.

II. General abstract

Protected Natural Areas (PNAs) aim to preserve ecological processes and biodiversity. However, the species that inhabit PNAs are threatened by various effects derived from human activities or have a key role in their ecosystems. One particular threat to native species in PNAs is the introduction of invasive species. An example is the impact associated with the presence of dogs (*Canis lupus familiaris*). This thesis is divided into two parts. In the first part, I evaluated the potential for interaction between dogs and three

native mesocarnivore species: coyote (*Canis latrans*), bobcat (*Lynx rufus*), and gray fox (*Urocyon cinereoargenteus*), in the Barranca del Cupatitzio National Park (BCNP) in Uruapan, Michoacán, Mexico. Camera traps were placed from January 2023 to March 2024 at 10-11 stations distributed throughout the park, with an average separation of 1.5 km between them. Based on the collected data, I assessed the daily activity patterns of each species and the degree of temporal overlap (Δ), between species pairs. Additionally, I evaluated the degree of spatial overlap among species (Jaccard Index = JI). In the second part of the thesis, I developed a methodological proposal for the automated analysis of camera trap images in order to distinguish between a) empty images and those containing an object (animal), and b) images of dogs, coyotes, and gray foxes. For this purpose, I used the open-source library “YOLOv8” © Ultralytics to train two computer vision models based on MobileNetSSDv2 (MobileNet Single Shot Detector) for classifying species in camera trap records (images and videos). A total of 1,139 records (images and videos), we obtain of the four focal species (455 when grouped at 24-hour intervals) on 3,633 camera-trap days. The species with the highest recording frequency was *U. cinereoargenteus* (n=253), and the lowest was *L. rufus* (n=25). The most active species during the day was *C. lupus familiaris* (61%), and the least active *U. cinereoargenteus* (24%). The species most overlapping in their daily activity were *C. latrans* and *C. lupus familiaris* ($\Delta= 0.81$), and the least were *C. lupus familiaris* and *L. rufus* ($\Delta= 0.58$). The species with the highest spatial coincidence were *C. latrans* and *U. cinereoargenteus* (JI = 0.84), and the species with the least were *L. rufus* and *C. latrans* (JI = 0.28). The computer vision models: Model 1 correctly classified 90% of empty images and 88% of images containing objects. Model 2 correctly identified 60% of dog records, 65% of fox records, and 57% of coyote records. This thesis provides evidence of a significant potential for interactions between

mesopredators in BCNP and domestic dogs, highlighting their possible impacts on the park's biodiversity, as well as the applicability of computer vision, as a supporting tool in cámara trap research projects.

Keywords: antagonistic interactions, computer vision, exotic species, machine learning, mesopredators.

III. Introducción general

Las áreas naturales protegidas (ANPs), son una de las principales estrategias para preservar la integridad de la biodiversidad y los servicios ecosistémicos (Figuerola et al., 2011). De esta manera, las ANPs son fundamentales para mantener servicios ecológicos como la polinización o el ciclo de nutrientes que permiten la subsistencia de la vida en el planeta (Martínez et al., 2021). Sin embargo, la viabilidad de las ANPs está comprometida por una variedad de amenazas como la pérdida y fragmentación del hábitat, sobreexplotación de recursos naturales, contaminación y propagación de especies exóticas invasoras (Pourmajidian et al., 2014; Godínez-Gómez et al., 2020). El impacto que estas amenazas tienen sobre las ANPs depende del contexto social, político y económico en el que operan, así como de su manejo, infraestructura, personal y financiamiento. Debido a la limitación de recursos, las ANPs muchas veces se ven forzadas a identificar prioridades en términos de los ecosistemas y especies que pueden proteger y las presiones humanas más urgentes de mitigar (Rogers et al., 2010).

Entre las amenazas que cada vez afectan más a las ANP's están las especies invasoras (Carneiro et al., 2024). Sin embargo, en muchos casos la falta de información detallada sobre el impacto que estas especies tienen sobre la biodiversidad impide la toma de

decisiones para mitigar sus efectos (Carneiro et al., 2024). Un depredador introducido que afecta a muchas especies nativas es el perro doméstico (*Canis lupus familiaris*) sin embargo, ha recibido menos atención que otras especies introducidas como los gatos (*Felis catus*) o las ratas (*Rattus rattus*) (Doherty et al., 2017). En un análisis sobre el impacto de los depredadores mamíferos invasores Doherty et al. (2017) identificaron 156 especies de vertebrados vulnerables o en peligro de extinción que son afectadas negativamente por los perros domésticos. Los perros pueden afectar negativamente a la fauna silvestre a través de la depredación, inducción de cambios de comportamiento (e.g., por evasión), competencia, hibridación y transmisión de enfermedades (Ritchie et al., 2013; Banks y Bryant, 2007; Zapata-Ríos y Branch, 2016).

La evaluación constante de la capacidad de las ANPs para afrontar los efectos de especies invasoras como los perros es fundamental para determinar su integridad ecológica (Figuroa et al., 2011). Se han desarrollado diversos métodos de muestreo de la fauna silvestre en el campo como la búsqueda de huellas, excretas o madrigueras, el conteo de animales mediante observación directa, la captura utilizando diferentes tipos de trampas, o el seguimiento mediante el uso de collares satelitales y el fototrampeo (Hernández, 2023). Entre estas, el fototrampeo es el método que más aceptación ha adquirido con el tiempo ya que no es invasivo y causa un mínimo de perturbación a las especies, además, reduce considerablemente el arduo trabajo de campo en comparación con los otros métodos antes mencionados. Los costos asociados a este tipo de muestreos se han vuelto más accesibles y permiten de forma sencilla obtener grandes volúmenes de registros (imágenes o videos) de fauna silvestre (Mandujano y Morteo-Montiel, 2018). De esta manera, el fototrampeo es ampliamente utilizado en estudios de ecología y conservación, principalmente de mamíferos, para realizar inventarios de la diversidad, distribución de especies, patrones de

actividad, así como para estimar su abundancia, densidad poblacional y registrar especies en zonas donde su presencia era previamente desconocida (Hernández, 2023). No obstante, este método requiere de herramientas para organizar la información (Mandujano y Morteo-Montiel, 2018).

Los avances en herramientas y tecnología para el monitoreo de fauna silvestre a través de fototrampeo han permitido la recopilación y el almacenamiento de grandes cantidades de imágenes y videos. Si bien, esto es una situación altamente deseable, en muchos casos se ha convertido en un problema, por la complejidad que implica manejar eficientemente tales volúmenes de información. Cuando el ritmo de generación de información de fototrampeo excede la capacidad de procesamiento de la misma (clasificación y organización de archivos) de los investigadores, se pueden producir retrasos para obtener conclusiones ecológicas significativas (Leorna y Brinkman, 2022). Se han desarrollado distintas propuestas para abordar el problema de la organización y clasificación de grandes volúmenes de archivos de fototrampeo (Fegraus et al., 2011; Niedballa et al., 2016). En general estas propuestas buscan facilitar la administración y procesamiento de grandes cantidades de archivos provenientes de cámaras de fototrampeo con interfaces que permitan a los usuarios extraer automáticamente información de metadatos (exif) y permitir el etiquetado de las imágenes con el nombre de las especies que aparecen en las mismas y la exportación de los datos en formatos estandarizados para bases de datos. El amplio desarrollo de herramientas basadas en la Inteligencia artificial (IA) como la visión por computadora y redes neuronales convolucionales está permitiendo abordar el problema del manejo de grandes volúmenes de imágenes y videos de fototrampeo desde una nueva perspectiva (Fennell et al., 2022). Un ejemplo es el caso de WILD id © Red de Evaluación y Monitoreo de Ecología Tropical (TEAM, por sus siglas en ingles) que comenzó como un

programa que se instalaba en un ordenador y que permitía al usuario etiquetar sus imágenes (Mandujano y Morteo-Montiel, 2018). Este programa ha evolucionado y ahora es una página web que suma las funciones de clasificación automatizada de especies con IA (<http://www.teamnetwork.org>). Otras plataformas han surgido en la misma rama y han creado una gama de opciones (con sus ventajas como: el filtrado integrado de imágenes vacías, análisis estadísticos automatizados y desventajas como: la necesidad de utilizar modelos muy especializados para especies particulares y el requerimiento, en algunos casos, de pagar para acceder al servicio). Por otra parte, la identificación de especies aún es un problema sin resolver completamente, lo cual no permite automatizar por completo el proceso y hace todavía necesaria la revisión humana (Villa, 2017). Es por esta razón que resulta de utilidad explorar distintas opciones que utilicen librerías de código gratuito para desarrollar modelos propios que sean eficientes para identificar especies en proyectos de fototrampeo locales.

Como punto de partida para este trabajo de tesis se evalúan aspectos básicos de la ecología de la interacción entre los perros y tres especies de mesodepredadores nativos (zorra gris, coyote y gato montés) en el Parque Nacional Barranca del Cupatitzio (PNBC) en Uruapan, Michoacán, México, a partir del fototrampeo (Capítulo I). Posteriormente, se desarrolla y evalúa una metodología para facilitar el procesamiento de imágenes de fototrampeo y el poder distinguir entre imágenes de perros, zorra gris y coyotes a partir del uso de inteligencia artificial, redes neuronales convolucionales y la visión por computadora (Capítulo II).

IV. Objetivo General

Analizar los patrones de actividad espacial y temporal de perros (*Canis lupus familiaris*) y tres carnívoros nativos: el coyote (*Canis latrans*), zorra gris (*Urocyon cinereoargenteus*) y

lince rojo (*Lynx rufus*) para evaluar su potencial de interacción en el Parque Nacional Barranca del Cupatitzio, Uruapan, Michoacán, México y proponer una metodología que sirva para identificación y clasificación de archivos de fototrampeo a través del uso de inteligencia artificial con redes neuronales convolucionales y visión por computadora.

V. Objetivos Específicos

1. Determinar los niveles de actividad diaria (el porcentaje de actividad durante el día) del perro doméstico (*Canis lupus familiaris*), coyote (*Canis latrans*), zorra gris (*Urocyon cinereoargenteus*) y lince rojo (*Lynx rufus*).
2. Evaluar en qué medida se superponen los patrones de actividad diaria de estas cuatro especies.
3. Evaluar el grado en el que coincide la actividad espacial de estas cuatro especies.
4. Hacer uso de herramientas de aprendizaje automático y visión por computadora para separar imágenes y videos de fototrampeo vacías de las que tienen algún animal (mamífero).
5. Hacer uso de herramientas de aprendizaje automático y visión por computadora para distinguir de manera automática entre imágenes y videos de fototrampeo con perros, coyotes y zorros en proyectos de fototrampeo.

VI. Hipótesis

Los perros y los mesocarnívoros silvestres comparten características ecológicas (e.g., tallas corporales y dieta) que favorecen la coincidencia de sus patrones de actividad espacial y temporal. Para reducir las interacciones antagónicas estas especies hacen un uso diferencial del tiempo o del espacio.

VII. Predicciones

1. Se espera que haya traslape de la actividad espacial y temporal de los perros se y mesocarnívoros nativos del PNBC pero que hay diferenciación en sus picos de actividad temporal y/o concentración de actividad espacial.
2. Se espera que los modelos de visión por computadora, clasifiquen correctamente los registros de: coyote (*Canis latrans*), perro doméstico (*Canis lupus familiaris*), zorro gris (*Urocyon cinereoargenteus*) y lince rojo (*Lynx rufus*) en las imágenes y videos del fototrampeo.

VIII. Justificación

Las ciudades a menudo se establecen en zonas de alta biodiversidad y disponibilidad de recursos por lo que pueden entrar en conflicto con las Áreas Naturales Protegidas. Esta expansión de los asentamientos humanos y sus especies asociadas como el perro (*Canis lupus familiaris*) han generado un creciente impacto en la fauna silvestre (Campbell, 2017). El PNBC, por su cercanía a la zona urbana de la ciudad de Uruapan, es vulnerable a la presencia de perros. La presencia de perros puede influir en el comportamiento y distribución de especies nativas de mesocarnívoros como: el coyote (*Canis latrans*), el zorro gris (*Urocyon cinereoargenteus*) y el lince rojo (*Lynx rufus*), ya sea por competencia, depredación o intimidación. El evaluar el grado en el que las interacciones entre estas especies son posibles resulta de gran importancia para el diseño de estrategias de conservación en el PNBC y otras ANPs ubicadas en la periferia de las ciudades.

Por otra parte, el contar con una herramienta de apoyo para la organización de grandes volúmenes de archivos (imágenes o videos) a través de visión por computadora e inteligencia artificial es de gran importancia para facilitar los estudios basados en

fototrampeo

(Fennell,

2022).

IX. Referencias

- Banks P.B., Bryant J.V. (2007). Four-legged friend or foe? Dog walking displaces native birds from natural areas. *Biology Letters* 3, 611 – 613. <https://doi.org/10.1098/rsbl.2007.0374>
- Baliali H., Strassner C. & Ben Hassen T. (2021). Sustainable agri-food systems: environment, economy, society, and policy. *Sustainability*, 13(11), 6260. <https://doi.org/10.3390/su13116260>
- Boucher T. M., Spalding M. & Revenga C. (2013). Role and trends of protected areas in conservation. *Life Sciences*. <https://doi.org/10.1016/B978-0-12-384719-5.00348-8>
- Campbell M. O. N. (2017). Biological conservation in the 21st century: A conservation biology of large wildlife. *New York, Nova Science Publishers*. ISBN: 978-1-53-612-092-9.
- Carneiro L., Miiller N. O., Cuthbert R. N. & Vitule J. R. (2024). Biological invasions negatively impact global protected areas. *Science of The Total Environment*, 948, 174823. <https://doi.org/10.1016/j.scitotenv.2024.174823>
- Doherty T. S., Dickman C. R., Glen A. S., Newsome T. M., Nimmo D. G., Ritchie E. G., Vanak A. T. & Wirsing A. J. (2017). The global impacts of domestic dogs on threatened vertebrates. *Biological Conservation*, 210, 56–59. <https://doi.org/10.1016/j.biocon.2017.04.007>
- Fegraus E. H., Lin K., Ahumada J. A., Baru C., Chandra S. & Youn C. (2011). Data acquisition and management software for camera trap data: A case study from the TEAM Network. *Ecological Informatics*, 6(6), 345-353. DOI: 10.1016/j.ecoinf.2011.06.003
- Fennell M., Beirne C. & Burton A. C. (2022). Use of object detection in camera trap image identification: Assessing a method to rapidly and accurately classify human and animal detections for research and application in recreation ecology. *Global Ecology and Conservation*, 35, e02104. <https://doi.org/10.1016/j.gecco.2022.e02104>
- Figueroa F., Sánchez-Cordero V., Illoldi-Rangel P. & Linaje M. (2011). Evaluación de la efectividad de las áreas protegidas para contener procesos de cambio en el uso del suelo y la vegetación. ¿Un índice es suficiente? *Revista mexicana de biodiversidad*, 82(3), 951-963. <https://doi.org/10.22201/ib.20078706e.2011.3.768>
- Godínez-Gómez O., Schank C., Mas J. F. & Mendoza E. (2020). An integrative analysis of threats affecting protected areas in a biodiversity stronghold in Southeast Mexico. *Global Ecology and Conservation*, 24. <https://doi.org/10.1016/j.gecco.2020.e01297>
- Hernández H. J. C. (2023). La tecnología y la conservación de especies: el poder de las cámaras-trampa. *Revista Digital Universitaria (rdu)*, 24(4). <http://doi.org/10.22201/cuaieed.16076079e.2023.24.4.3>
- Leorna S. & Brinkman T. (2022). Human vs. machine: Detecting wildlife in camera trap images. *Ecological Informatics*, 72, 101876.

- <https://doi.org/10.1016/j.ecoinf.2022.101876>
- Mandujano S. & Morteo-Montiel O. (2018). Sugerencias para organizar, administrar y exportar datos de foto-trampeo con el programa WILD. ID. *Revista Mexicana de Mastozoología (nueva época)*, 8(2), 31-39. <https://doi.org/10.22201/ie.20074484e.2018.1.2.263>
- Martínez M. E., Parra Acosta H. & Porrás Flores D. A. (2021). Biodiversidad desde la bioética y sustentabilidad. *Ruiiec*. <http://ru.iiec.unam.mx/id/eprint/5463>
- Niedballa J., Sollmann R., Courtiol A. & Wilting A. (2016). camtrapR: an R package for efficient camera trap data management. *Methods in Ecology and Evolution*, 7(12), 1457-1462. <https://doi.org/10.1111/2041-210X.12600>
- Pourmajidian M., Yousefi-Valikchali M. & Darvishi L. (2014). Protected Areas in the Face of Environmental Challenges. *Proceedings of the Iranian National Conference on Environment and Energy, Shiraz, Iran* (Vol. 11). https://www.researchgate.net/publication/265377143_Protected_Areas_in_the_Face_of_Environmental_Challenges
- Ritchie E. G., Dickman C. R., Letnic M., Vanak A. T. & Gommper M. (2013). Dogs as predators and trophic regulators. *Free-ranging dogs and wildlife conservation*, 55-68. <https://doi.org/10.1093/acprof:osobl/9780199663217.003.0002>
- Rogers H. M., Glew L., Honzák M. & Hudson, M. D. (2010). Prioritizing key biodiversity areas in Madagascar by including data on human pressure and ecosystem services. *Landscape and Urban Planning*, 96(1), 48-56. <https://doi.org/10.1016/j.landurbplan.2010.02.002>
- Villa A. G., Salazar A. & Vargas, F. (2017). Towards automatic wild animal monitoring: Identification of animal species in camera-trap images using very deep convolutional neural networks. *Ecological informatics*, 41, 24-32. <https://doi.org/10.1016/j.ecoinf.2017.07.004>
- Zapata-Ríos G. & Branch L. C. (2016). Altered activity patterns and reduced abundance of native mammals in sites with feral dogs in the high Andes. *Biological Conservation*, 193, 9-16. <https://doi.org/10.1016/j.biocon.2015.10.016>

x. Capítulo I

Potential for the interaction of free-ranging dogs with native mesocarnivores in a peri-urban protected area of Western Mexico

Enil Perales-Calderón^a, Jonatan Torres-Pérez-Coeto^a, Alfredo Graciarreal^b, Eduardo Mendoza^a

^a Instituto de Investigaciones sobre los Recursos Naturales, Universidad Michoacana de San Nicolás de Hidalgo, Morelia, Michoacán, México.

^b Comisión Nacional de Áreas Naturales Protegidas, Primera privada de Paraguay, número 16, colonia Los Ángeles, CP 60160, Uruapan, Michoacán, México.

CONTACT ENIL. Correo electrónico: 2330384j@umich.mx, EP: <https://orcid.org/0009-0000-5194-1183>

CONTACT JONATÁN. Correo electrónico:

arturo.torres@umich.mx

CONTACT ALFREDO. Correo electrónico:

garciarreal@conanp.gob.mx

CONTACT EDUARDO. Correo electrónico: eduardo.mendoza@umich.mx, <https://orcid.org/0000-0001-6292-0>

Abstract

The growing presence of domestic dogs (*Canis lupus familiaris*) in protected natural areas (PAs), particularly in those located near cities, poses a threat to native fauna through disease transmission, antagonistic interactions, and hybridization. Mexico has one of the world's largest dog populations, and urbanization is threatening several of its protected areas (PAs) and their wildlife. To assess the potential for antagonistic interactions, we analyzed the spatial and temporal activity patterns of dogs and three native mesocarnivores—*Canis latrans*, *Lynx rufus*, and *Urocyon cinereoargenteus*—in the peri-urban National Park Barranca de Cupatitzio (NPBC) in western Mexico. From January 2023 to March 2024, we set up 10 camera traps throughout the NPBC to survey mammal activity. *Urocyon cinereoargenteus* had the highest recording frequency (n=253), and *L. rufus* (n=25) the lowest. *Canis latrans* and *C. lupus familiaris* had the greatest overlap in daily activity ($\Delta = 0.81$), while *C. lupus familiaris* and *L. rufus* had the least ($\Delta = 0.58$). The species with the highest spatial coincidence were *C. latrans* and *U. cinereoargenteus* (Jaccard index = 0.84), and the species with the least were *L. rufus* and *C. latrans* (Jaccard index = 0.28). There is a high potential for dogs to impact native fauna negatively.

KEY WORDS: Antagonist interactions, ecological segregation, exotic species, mesopredators, species interactions.

Introduction

The current population of dogs is likely to exceed one billion, making them the most common carnivorous mammal on the planet (Gompper 2014). Approximately 75% of this dog population is not permanently restrained or under human control, despite being owned (i.e., free roaming), which gives them ample opportunity to impact their environment (Hughes and Macdonald 2013). Domestic dogs have been implicated in the extinction of 11 species of vertebrates and are considered a threat to 188 endangered species worldwide (Doherty et al. 2017). The primary mechanisms through which they are causing a negative impact include predation, disturbance, disease transmission, competition, and hybridization (Doherty et al. 2017). A significant proportion of the canine population inhabits urban areas, yet they also frequently occur in rural settings (Gompper 2014). Dogs have become a ubiquitous species in several protected areas due to their widespread distribution, abundance, and freedom of movement (Lessa et al. 2016; Parsons et al., 2016). The protected areas most vulnerable to the presence of dogs are those located near cities (Yen et al. 2019).

Human-subsidized resources enable dogs to reach higher densities than native carnivores in protected areas, thereby increasing the likelihood of antagonistic interactions with native fauna (Gompper 2014). Antagonistic interactions between feral dogs and native mesocarnivores are particularly likely because they share resources, such as food and space (Coronel-Arellano et al. 2021). In the temperate forests of the central-western part of Mexico, coyotes (*Canis latrans*), gray foxes (*Urocyon cinereoargenteus*), and bobcats (*Lynx rufus*) coexist. These mammals are medium-sized carnivores with overlapping adult weights: gray foxes (3-7 kg), bobcats (6.4-18.3 kg), and coyotes (8-20 kg) (Bekoff 1977; Fritzell and Haroldson 1982; Larivière and Walton 1997). The diet of the bobcat is carnivorous and centered on mammals, with a preference for rabbits and rodents. In

comparison, the diet of the grey fox and the coyote includes not only rodents and rabbits but also a broad variety of vertebrates and invertebrates. Additionally, the gray fox and coyote supplement their diets with a substantial amount of fruit (Litvaitis and Harrison 1989; Larson et al. 2015; Neale and Sacks 2001). It has been observed that these three species tend to exhibit higher levels of activity during crepuscular and nocturnal periods of the day (Chamberlain et al. 1998; Elizalde-Arellano et al. 2012; Farías et al. 2012; Flores-Martínez et al. 2022). However, evidence suggests that they also engage in some degree of activity during daylight hours, as observed in the case of coyotes (Rodríguez-Luna et al. 2024). Free-roaming dogs, on the other hand, are characterized by their dietary plasticity, which includes a high proportion of plant material, such as fruit, as well as mammals, birds, reptiles, amphibians, and human-derived material (Ritchie et al. 2014). In protected areas, dogs' daily activity tends to concentrate on the diurnal period, having its primary peak around 7:00-9:00 in the morning and secondary peaks around dusk (De-Andrade-Silva et al. 2018; Yen et al. 2019; De-Cassia-Bianchi et al. 2020; Boller et al. 2023). Therefore, it is not unlikely that, when occurring together, dogs and bobcats, coyotes and gray foxes would have antagonistic interactions, either directly (e.g., interference competition) or indirectly (e.g., exploitative competition).

Gompper (2014) estimated the number of dogs in Mexico at 24,462,400, making it one of the six countries with the largest dog populations in the world. More recently, a survey conducted by the National Institute of Statistics, Geography and Informatics (Instituto Nacional de Estadística Geografía e Informática, INEGI) estimated that by the year 2022, the dog population in Mexico exceeded 43 million (<https://www.inegi.org.mx/app/saladeprensa/noticia/7021>). The large number of dogs in the country makes it urgent to assess their impact on the native fauna. Moreover, the fact

that the extent to which dogs affect native carnivores depends on several factors, such as the degree of freedom of movement of dogs, the presence of top predators, the abundance of prey, and the level of food, shelter and vaccination provided by humans makes relevant to assess the impacts of dogs on a broader variety of habitats and settings (Gompper 2014).

In this study, we focus on analyzing the spatial and temporal activity patterns of dogs, coyotes, gray foxes, and bobcats in the peri-urban protected area of Barranca del Cupatitzio National Park (BCNP), Michoacán, western Mexico. We address the following questions: a) How abundant are dogs in the BCNP? b) What are the daily activity levels (i.e., percentage of activity during the day) of these four focal species? c) How much do their daily activity patterns overlap? d) To what extent do their spatial activity coincide? We expect dog abundance to be high because human-derived resources and the proximity of human settlements to our study area subsidize this fauna. Due to the relatively high abundance of dogs and their ecological similarity to native mesocarnivores, we expect to find significant levels of overlap in their daily and spatial activity patterns, but also differences in their activity peaks, which will reduce the probability of antagonistic direct interactions.

Materials and Methods

Study area

The The protected area Barranca del Cupatitzio National Park (BCNP) is in the state of Michoacán, on the western coast of México (Fig. 1). The BCNP has an extent of 458.21 ha. Its extreme coordinates are 19° 25'11.28" - 19° 26'24.18" N and 102° 07'40.04" - 102° 04'20" W (CONANP and Aguirre-Paleo, 2006). The surface of the BCNP is partially

covered with rocky soil from volcanic eruptions; the highest elevations correspond to Loma Larga (2,075 m a.s.l.) and Cerro Chiquito (2,136 m a.s.l.) mountains. The natural vegetation of the BCNP is primarily composed of pine forests, pine-oak forests, and mountain cloud forests (Bello and Madrigal 1996). A total of 57 mammal species have been recorded in the BCNP (Orduña and Salas 1993, Chávez-León and Rivera 2009).

The BCNP is in the vicinity of the city of Uruapan (356,786 inhabitants) and the indigenous community of Nuevo San Juan Parangaricutiro (20,982 inhabitants) (Hernández-Salazar et al. 2020; Fig. 1). The region has experienced a significant increase in the establishment of avocado orchards in recent decades, which, along with human-caused fires, has negatively impacted the integrity of the forest cover, even within the BCNP (Barrera-Díaz 2021).

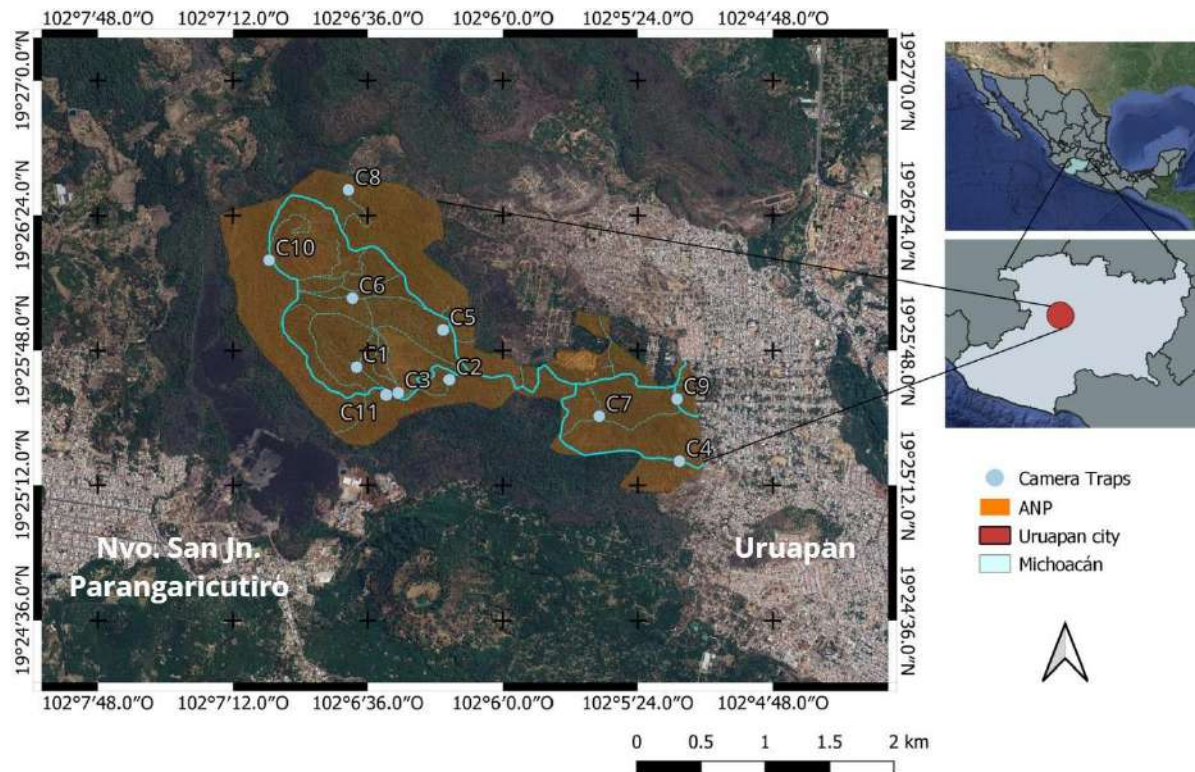


Figure 1. The location of the Barranca del Cupatitzio National Park in Michoacán, western Mexico, and the camera-trapping design used to record focal carnivorous mammal species.

Survey design

The camera trapping survey was conducted between January 2023 and March 2024. Ten camera traps were set up of the following brands and models: Bushnell (119932C), GardPro (T5NG), and Browning (BTC-5HD-850). They were attached to three trunks close to dirt roads, trails, and ravines, trying to cover most of the extent of the BCNP. Half of the cameras were set to photo mode, and the other half to video mode. The coordinates of the cameras were recorded using a © Garmin eTrex hand-held GPS. The average distance among cameras was 1.5 km. The cameras were checked every three months to download images and replace batteries.

Processing of camera trap

We used the software CamtrapR (Niedballa et al. 2024) and ©DigiKam to write and read image and video metadata, tag them with the species identity recorded, and create a database containing the following information: camera ID, dates, and species. We used local field guides to identify species (Herrejón et al. 2015).

Data analysis

Relative frequency of recording of the focal species

We calculated the relative recording frequency of focal species as a rough proxy for their representation. Before calculating this parameter, we grouped camera trap records of the same species/site within 24-hour intervals. By grouping detections of a species at each sampling site into a single record per day, we aimed to reduce the overestimation caused by repeatedly capturing the same individual in multiple images (Rovero et al. 2014). Grouped images/videos are referred to as events hereafter.

$$RF = \frac{\text{Events by species}}{\text{Total events}} \times 100$$

Comparison of species activity levels

We used the package Activity (Rowcliffe 2023) to estimate daily activity levels (i.e., the percentage of the day a species is active) for the four focal species. Moreover, we calculated their 95% confidence intervals and contrasted the activity estimates between species, applying a randomization test (Rowcliffe 2023). We used the non-aggregated camera trap records transformed into radians to conduct this analysis.

Comparison of species' daily activity patterns

We generated curves describing the daily activity patterns of the four focal species using the non-aggregated camera trap records, with time data transformed to radians and the package Overlap (Ridout and Linkie 2009). We used the same package to estimate the level of overlap in the daily activity between pairs of species and to calculate the corresponding 95% confidence intervals. The activity overlaps were measured using the overlap coefficient (Δ). This coefficient reaches 1 when activity curves completely overlap and 0 when the overlap is null. We used Δ_1 when the minimum number of species records in the compared pair was less than 50, and Δ_4 when it was more than 75 (Schmid and Schmidt 2006). We used the package Activity (Rowcliffe 2023) to conduct randomization tests to assess if activity curves could be assumed to come from the same statistical population.

Spatial coincidence

We used the package Basa (Mendoza et al. 2024) to calculate the Jaccard index to assess the level of species association measured based on their common occurrence (or not) in the camera traps. To calculate the Jaccard index, we built two-by-two tables for each species pair where presences corresponded to 1 and absences to 0. The Jaccard index was calculated as follows:

$$JI = \frac{n[a]}{n[a] + n[b] + n[c]}$$

Where $n[a]$ is the number of cameras in which both species in the analyzed pair occurred, $n[b]$ is the number of cameras in which only the first species was recorded, and $n[c]$ is the number of cameras in which only the second species was recorded. The Jaccard index takes values between 0 (no association) and 1 (complete association) (Kujala et al. 2018).

Results

Over 3,518 camera trap days, we obtained 1,139 records of the four focal species (Fig. 2), which were reduced to 455 when grouped into 24-hour intervals. The species with the highest recording frequency was *Urocyon cinereoargenteus*, followed by *Canis lupus familiaris* (Fig. 3). We identified 36 individuals of *C. lupus familiaris*, corresponding primarily to young individuals from large breeds. Of these, 31 were recorded in pairs or as part of packs, and five wandered alone. Of the 338 ungrouped dog records, 185 (54.7%) were for single dogs, and 153 (45.3%) were for dog pairs or packs. The maximum size of dog packs was five individuals. In contrast, most of the records of native mesocarnivores corresponded to single individuals.



Figure 2. Focal species recorded by camera traps in the protected area Barranca del Cupatitzio National Park, located in, Uruapan, Michoacán, western Mexico.

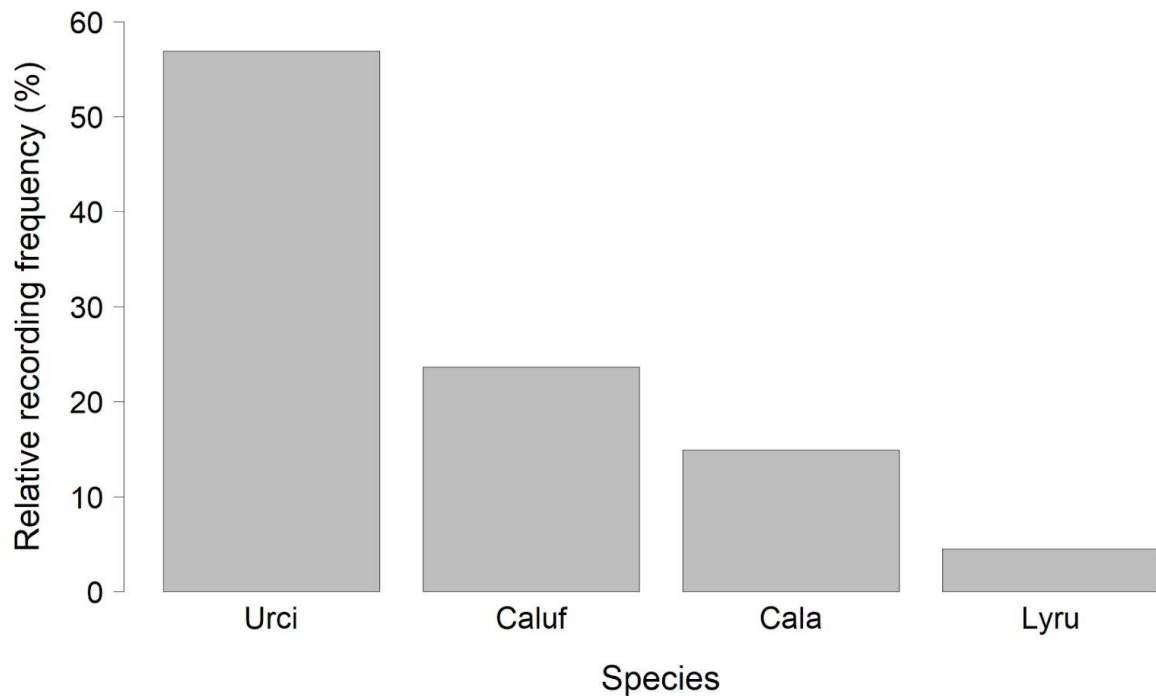


Figure 3. Relative recording frequency of camera-trapping events (picture records grouped within 24-hour intervals) of the four focal mammal species in the Barranca del Cupatitzio National Park, Uruapan,

Michoacán, Mexico. Urci = *Urocyon cinereoargenteus*, Caluf = *Canis lupus familiaris*, Cala = *Canis latrans*, Lyru = *Lynx rufus*.

Daily activity levels and patterns

The most active species were *C. lupus familiaris* (61%) and *C. latrans* (45%) (Fig. 4, Table S1a), which did not differ statistically (Fig. 4, Table S1b). The least active species was *U. cinereoargenteus* (24%) (Fig. 4, Table S1a).

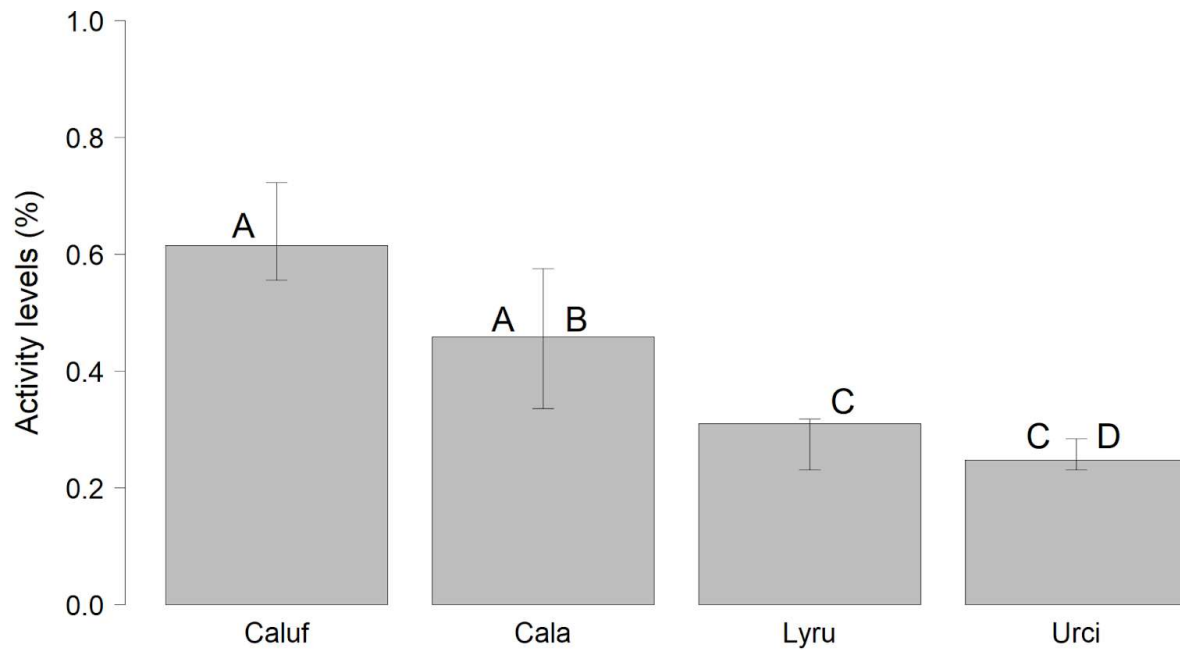


Figure 4. Daily activity levels (i.e., percentage of the day a species is active) of the four focal species in the Barranca del Cupatitzio National Park in Uruapan, Michoacán, Mexico. The error bars correspond to 95% confidence intervals. Urci = *Urocyon cinereoargenteus*, Caluf = *Canis lupus familiaris*, Cala = *Canis latrans*, Lyru = *Lynx rufus*.

Comparatively, the species with the less marked activity peaks were *C. lupus familiaris* and *C. latrans* (Figs. 5 and 1S). The highest activity peak of *C. lupus familiaris*

occurred around 9:00 h. In comparison, *C. latrans*, *U. cinereoargenteus*, and *L. rufus* consistently had their highest activity peaks around 20:00 and 21:00 h (Figs. 5 and 1S). Only *L. rufus* differed in having a second peak of activity of similar magnitude around 9:00 h (Fig. 1S). The largest coefficient of daily activity overlap corresponded to the pair *C. latrans* and *C. lupus familiaris* (Table 1, Fig. 5), and the least to *L. rufus* and *U. cinereoargenteus* (Table 1, Fig. 5). Although all species pairs had a Δ greater than 0.5, the activity patterns were statistically different in all cases (Table 1), likely due to differences in the relative magnitude of the activity peaks among species and the presence of different secondary activity peaks (Fig. 5).

Table 1. Comparison of daily activity patterns of focal mammal species in the Barranca del Cupatitzio National Park, Uruapan, Michoacán. Above the diagonal are the values of the overlap coefficients and their corresponding 95% confidence intervals, Δ_4 was used when the sample size was greater than 75, and Δ_1 when it was less than 50. Below the diagonal are the p-values from randomization tests comparing mammalian activity patterns. Urci = *Urocyon cinereoargenteus*, Caluf = *Canis lupus familiaris*, Cala = *Canis latrans*, Lyruf = *Lynx rufus*.

<i>Species</i>	Cala	Caluf	Lyruf	Urci
Cala	–	4 =0.81 0.7254-0.8982	1=0.66 0.5276-0.7678	4 =0.73 0.6476-0.7918
Caluf	< 0.001	–	1 =0.64 0.5050-0.7262	4 =0.62 0.5297-0.6577
Lyruf	< 0.001	< 0.001	–	1 = 0.51 0.3707-0.5841
Urci	< 0.001	< 0.001	< 0.001	–

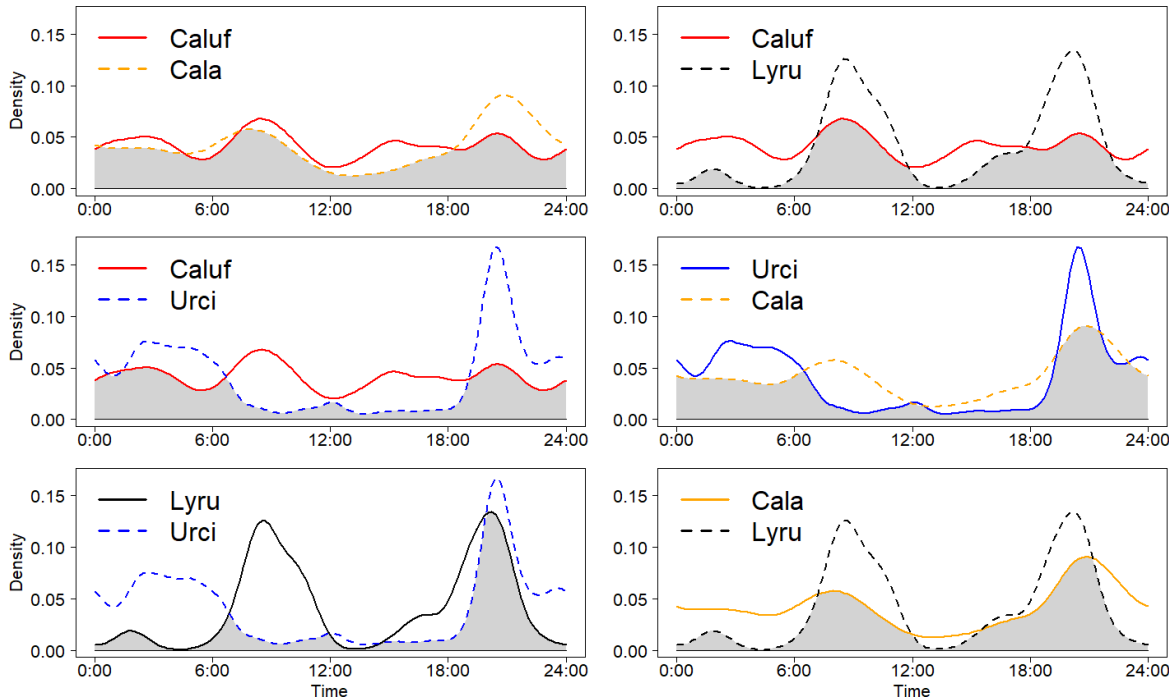


Figure 5. Patterns of daily activity of the focal mammal species in the Barranca del Cupatitzio National Park, Uruapan, Michoacán, Mexico. The scale on the y-axis (Density) measures the probability of recording the presence of the species. The shaded areas correspond to the overlap in the activity. *Urci* = *Urocyon cinereoargenteus*, *Caluf* = *Canis lupus familiaris*, *Cala* = *Canis latrans*, *Lyrus* = *Lynx rufus*.

Coincidence in spatial occurrence

The species *C. latrans* was recorded in 10 camera traps, *U. cinereoargenteus* in 9, *C. lupus familiaris* in 8, and *L. rufus* in 3 (Fig. 2S, 3S, 4S, 5S). The species pair having the highest spatial coincidence was *C. latrans* and *U. cinereoargenteus*, while the lowest coincidence observed was for the pair *L. rufus* and *C. latrans* (Fig. 6; Table 2).

Table 2. Jaccard index values measuring the level of spatial coincidence in the occurrence of focal mammal species in the Barranca del Cupatitzio National Park, Uruapan, Michoacán. *Urci* = *Urocyon cinereoargenteus*, *Caluf* = *Canis lupus familiaris*, *Cala* = *Canis latrans*, *Lyrus* = *Lynx rufus*.

Species pair	Mean	Median	95% Confidence intervals
--------------	------	--------	--------------------------

Cala - Urci	0.84	0.86	0.61 - 0.98
Cala - Caluf	0.76	0.77	0.49 - 0.94
Caluf - Urci	0.68	0.69	0.4 - 0.9
Caluf - Lyru	0.33	0.32	0.09 - 0.63
Lyru - Urci	0.31	0.29	0.08 - 0.59
Cala - Lyru	0.28	0.27	0.08 - 0.54




Figure 6. Comparison of temporal (daily activity) and spatial overlap of each pair of the focal mammal species in the Barranca del Cupatitzio National Park, Uruapan, Michoacán, Mexico. Error bars correspond to 95% confidence intervals. *Urci* = *Urocyon cinereoargenteus*, *Caluf* = *Canis lupus familiaris*, *Cala* = *Canis latrans*, *Lyru* = *Lynx rufus*.

When comparing temporal and spatial overlap among mammal species pairs, we found that *C. lupus*, *C. latrans*, and *U. cinereoargenteus* showed the highest degree of

overall coincidence (Fig. 6). In contrast, all cases with lower coincidence involved *L. rufus* (Fig. 6).

Discussion

Dogs are a prominent component of the mesocarnivore mammalian fauna in the BCNP, in the same manner as it happens in other peri-urban protected areas (Lessa et al. 2016). Based on the 36 individual dogs identified in this study and the BCNP's size (458.21 ha), we estimate a dog density of approximately 7.86 dogs/km². This is a rough estimate, as dogs are likely to move in and out of the BCNP constantly. However, it provides a valuable reference point for comparison with other protected areas. For example, in a protected area of 954 ha, twice the size of the BCNP, in the Atlantic Forest of Brazil, 32 dogs were identified for a density of 3.35 dogs/km² (Paschoal et al. 2012). In comparison, in the Yangmingshan National Park in Taiwan, the dog population density could reach up to 30 dogs/km² (Yen et al. 2019). The relatively high abundance of dogs in the BCNP is likely related to the food subsidies provided by human-derived resources (Gompper 2014). We do not have density estimations for the local populations of our focal native mesocarnivores. However, a review of some published data indicates that bobcat densities are typically less than one ind./km² (Lombardi et al. 2017; Lavariega et al. 2022; McTigue and DeGregorio 2023), while coyote and gray fox densities tend to be higher but rarely exceed 1.3 and 2.0 ind./km², respectively (Fritzell and Haroldson 1982; Lombardi et al. 2017; McTigue and DeGregorio 2023). In addition to being common, dogs in the BCNP tend to move in pairs or packs, which, combined with their relatively large body size, can give them a clear advantage in antagonistic encounters with native mesocarnivores. Our study area lacks top predators such as the puma (*Puma concolor*); however, the presence of this species has been

recorded in the nearby region of Tancitaro (unpublished data). Favoring the presence of pumas in the BCNP, by enhancing habitat connectivity, can be a factor contributing to deterring dogs, although some studies have found no effect of the presence of pumas on dog activity patterns (De-Cassia-Bianchi et al. 2020).

Only in two of the recorded dogs were we able to detect the use of collars, suggesting that most of them have a high degree of freedom of movement. Consistent with other studies, we found that the presence of dogs was not restricted to the periphery of the BCNP (Lessa et al. 2016). In fact, the camera trap with the highest number of dog records was in the approximate center of the BCNP, ~689 m away from the park boundary (Fig. S2). Other studies have reported that dogs can roam as far as 10 km from villages, making the negative impacts of dogs on native wildlife widespread (Yen et al. 2019). The possibility of dogs frequently moving in and out of the BCNP increases the risk of disease transmission to wild carnivores, as they are associated with more than 60 zoonotic diseases (Matter and Daniels 2000). The risk of disease transmission is particularly high in the BCNP, as recent studies have shown that canine distemper and parvovirus are more prevalent in small, protected areas than large ones (Curi et al. 2016).

Our results agree with other studies showing that dogs concentrate their activity in protected areas during the day. Likewise, their highest activity peak occurred close to 9:00 has documented in studies conducted in protected areas in Brazil (De-Cassia-Bianchi et al. 2020; Boller et al. 2023). In contrast, Yen et al. (2019) found that dogs are most active around dawn in the Yangmingshan National Park in Taiwan. Most of the studies of dogs in protected areas show a secondary peak of activity close to 18:00 h, like what was also found in the BCNP (Yen et al. 2019; De-Cassia-Bianchi et al. 2020; Boller et al. 2023).

We found that, overall, canids (native and introduced species) showed greater

similarity in their activity patterns than comparisons involving bobcats. Gray foxes and coyotes were the focal species with the broadest temporal and spatial overlap with dogs. Despite the relatively high ($\Delta > 0.5$) overlap in daily activity, the corresponding patterns were statistically different, most likely due to a mismatch in their activity peaks. The lack of coincidence in activity peaks can reduce direct antagonistic interactions between gray foxes and coyotes with dogs; however, it does not necessarily reduce exploitative competence. In the case of gray foxes, their tree-climbing adaptation may help them avoid direct antagonistic interactions with dogs, which, in turn, can favor their observed occurrence in all the camera traps (Fritzell and Haroldson 1982). A complementary analytical approach incorporating additional time variables (e.g., temporal co-occurrence and time to encounter) would be helpful to have a more comprehensive understanding of the potential interactions occurring between dogs and native mesocarnivores along the temporal niche axis (Watabe et al. 2022).

On the other hand, the marked spatial overlap in the activity of gray foxes, coyotes, and dogs does not necessarily imply true coexistence. Competition operates dynamically across multiple niche dimensions, and competitive exclusion can be a slow and persistent process (Yackulic 2017). Moreover, high spatial overlap increases the likelihood of disease transmission, even without frequent direct encounters, for example, by pathogens that can be spread through contaminated feces (Bryan et al. 2012).

Given the rampant growth of dog populations worldwide, especially in tropical regions with high wildlife diversity, and the increasing impact of human settlements on nearby protected areas, there is an urgent need to implement mitigation measures to reduce the negative impacts of this introduced species. A combination of approaches may have a better chance of success. For example, strengthening the boundaries of protected areas to

reduce the free movement of dogs in and out of protected areas, conducting regular dog vaccination and neutering campaigns, and reaching out to dog owners to raise awareness of their impact on wildlife are desirable alternatives (Plaza et al. 2019). Failing to implement effective measures to mitigate the impact of dogs on wildlife would further exacerbate the current defaunation crisis (Dirzo et al. 2019).

References

- Alanis-Hernández L. A., Sánchez-Rojas G., Hernández-Silva D. A. (2019). *Lynx rufus*, predador solitario. *Herreriana* (Vol. 1). <https://doi.org/10.29057/h.v1i1.4783>
- Angell T. (1969). A study of the ferruginous hawk: adult and brood behavior. *Living Birds* 8:225-241.
- Arias-Del-Razo I., Hernández L., Laundré J. W. & Myers O. (2011). Do predator and prey foraging activity patterns match? A study of coyotes (*Canis latrans*), and lagomorphs (*Lepus californicus* and *Sylvilagus audobonii*). *Journal of Arid Environments*, 75(2), 112-118. <https://doi.org/10.1016/j.jaridenv.2010.09.008>
- Arnaud G. & Acevedo M. (1990). Hábitos alimenticios de la zorra gris *Urocyon cinereoargenteus* (Carnivora: Canidae) en la región meridional de Baja California, México. *Revista de Biología Tropical*, 38(2B), 497-500. <https://revistas.ucr.ac.cr/index.php/rbt/article/view/25676>
- Baliali H., Strassner C. & Ben Hassen T. (2021). Sustainable agri-food systems: environment, economy, society, and policy. *Sustainability*, 13(11), 6260. <https://doi.org/10.3390/su13116260>
- Barrera-Díaz C. E. (2021). Vulneración de derechos humanos por el cambio de uso de suelo forestal. *Universidad Autónoma Del Estado De México*, 11(1), 7–20. <https://doi.org/10.36677/rpsicologia.v11i21.17466>
- Basa (2023). R (4.3.1): Estimation measure of similarity between spatial coincidence. R Foundation for Statistical Computing. `basa_0.7.1.tar`
- Bello M. & Madrigal X. (1996). Estudio florístico del campo experimental “Barranca del Cupatitzio”, Uruapan, Michoacán. *Folleto Científico*, 2.
- Bekoff M. (1977). *Canis latrans*. *Mammalian species*, (79), 1-9. <https://doi.org/10.2307/3503817>.
- Boller L., Pereira A. D., Fialek C. G. & Bazílio S. (2023). Activity and overlap pattern of medium to large sized mammals on Cachoeirinha Municipal ecological station in Southern Brazil. *Brazilian Journal of Mammalogy*, 92, e92202391. DOI:10.32673/bjm.vi92.91
- Bowkett A. E., Rovero F. & Marshall A. R. (2008). The use of camera-trap data to model habitat use by antelope species in the Udzungwa Mountain forests, Tanzania. *African Journal of Ecology*, 46(4), 479–487. <https://doi.org/10.1111/j.1365-2028.2007.00881.x>
- Bryan HM, Darimont CT, Paquet PC, Ellis JA, Goji N, Gouix M, Smits JE. Exposure to infectious agents in dogs in remote coastal British Columbia: Possible sentinels of diseases in wildlife and humans. *Can J Vet Res*. 2011 Jan;75(1):11-7. PMID: 21461190; PMCID: PMC3003557.
- Butler J., Linnell J., Marrant D. et al (2014) Dog eat dog, cat eat dog: social-ecological dimensions of dog predation by wild carnivores. In: Gompper ME (ed) *Free-ranging dogs and wildlife conservation*. Oxford University Press, pp 55–65.

- <https://doi.org/10.1093/acprof:osobl/9780199663217.003.0005>
- Caravaggi A., Banks P. B., Burton A. C., Finlay C. M. V., Haswell P. M., Hayward M. W., Rowcliffe M. J. & Wood M. D. (2017). A review of camera trapping for conservation behaviour research. In *Remote Sensing in Ecology and Conservation* (Vol. 3, Issue 3, pp. 109–122). Wiley-Blackwell. <https://doi.org/10.1002/rse2.48>
- Chamberlain M. J., Conner L. M., Leopold B. D., & Sullivan K. J. (1998). Diel activity patterns of adult bobcats in central Mississippi. In *Proceedings of the Annual Conference of the Southeastern Association of Fish and Wildlife Agencies* (Vol. 52, pp. 191-196). <https://seafwa.org/journal/1998/diel-activity-patterns-adult-bobcats-central-mississippi>
- Chávez-León G., & Rivera S. Z. (2009). Mammal richness from Barranca del Cupatitzio National Park, Michoacán, Mexico. ISSN 2007-8706 <https://www.scielo.org.mx/pdf/rmbiodiv/v80n1/v80n1a12.pdf>
- Chesness R. A., & Bremicker T. P.. (1974). Home range, territoriality, and sociability of coyotes in northcentral Minnesota. Paper presented, Coyote Research Workshop, Denver. <https://doi.org/10.2307/3807983>
- CONANP & Aguirre-Paleo S.. (2006). Plan Manejo Cupatitzio. *Diario Oficial de La Federación*, 1, 20–60. https://simec.conanp.gob.mx/pdf_libro_pm/3_libro_pm.pdf
- Coronel-Arellano H., Rocha-Ortega M., Gual-Sill F., Martínez-Meyer E., Ramos-Rendón A. K., González-Negrete M. & Zambrano L. (2021). Raining feral cats and dogs? Implications for the conservation of medium-sized wild mammals in an urban protected area. *Urban Ecosystems*, 24(1), 83-94. <https://doi.org/10.1007/s11252-020-00991-7>
- Curi N. H. D. A., Massara R. L., De-Oliveira-Paschoal A. M., Soriano-Araújo A., Lobato Z. I. P., Demétrio G. R. & Passamani M. (2016). Prevalence and risk factors for viral exposure in rural dogs around protected areas of the Atlantic forest. *BMC veterinary research*, 12, 1-10. <https://doi.org/10.1186/s12917-016-0646-3>
- De-Cassia-Bianchi R., Olifiers N., Riski L. L., Gouvea J. A., Cesário C. S., Fornitano L. & Gompper, M. E. (2020). Dog activity in protected areas: behavioral effects on mesocarnivores and the impacts of a top predator. *European journal of wildlife research*, 66(3), 36. <https://doi.org/10.1007/s10344-020-01376-z>
- De-Andrade-Silva K. V. K., Kenup C. F., Kreischer C., Fernandez F. A. & Pires, A. S. (2018). Who let the dogs out? Occurrence, population size and daily activity of domestic dogs in an urban Atlantic Forest reserve. *Perspectives in Ecology and Conservation*, 16(4), 228-233. DOI:10.1016/j.pecon.2018.09.001
- Doherty T. S., Dickman C. R., Glen A. S., Newsome T. M., Nimmo D. G., Ritchie E. G., Vanak A. T. & Wirsing A. J. (2017). The global impacts of domestic dogs on threatened vertebrates. *Biological Conservation*, 210, 56–59.

- <https://doi.org/10.1016/j.biocon.2017.04.007>
- Dirzo R., Young H. S., Galetti M., Ceballos G., Isaac N. J. & Collen B. (2014). Defaunation in the Anthropocene. *science*, 345(6195), 401-406. DOI:10.1126/science.1251817
- Elizalde-Arellano C., López-Vidal J. C., Hernández L., Laundré J. W., Cervantes F. A. & Alonso-Spilsbury M. (2012). Home range size and activity patterns of bobcats (*Lynx rufus*) in the southern part of their range in the Chihuahuan Desert, Mexico. *The American Midland Naturalist*, 168(2), 247-264. <https://doi.org/10.1674/0003-0031-168.2.247>
- Farías V., Fuller T. K. & Sauvajot R. M. (2012). Activity and distribution of gray foxes (*Urocyon cinereoargenteus*) in southern California. *The Southwestern Naturalist*, 57(2), 176-181. <https://doi.org/10.1894/0038-4909-57.2.176>
- Farris Z.J., Gerber B.D., Karpanty S. et al (2015) When carnivores roam: temporal patterns and overlap among Madagascar's native and exotic carnivores. *J Zool* 296:45 57. <https://doi.org/10.1111/jzo.12216>.
- Flores-Martínez J. J., Coates R., Sánchez-Cordero V., Ríos-Solís J. A., Luna-Olivera B. C., Ramírez-Ibáñez M., & Lavariega M. C. (2022). Spatiotemporal coexistence of mesopredators and their prey in a defaunated neotropical rainforest. *Tropical Conservation Science*, 15, 19400829221084261. <https://doi.org/10.1177/19400829221084261>
- Fritzell E. K. & Haroldson K. J. (1982). *Urocyon cinereoargenteus*. *Mammalian species*, (189), 1-8. <https://doi.org/10.2307/3503957>
- Gerber B.D., Karpanty S.M., Randrianantenaina J. (2012) Activity patterns of carnivores in the rain forests of Madagascar: implications for species coexistence. *J Mammal* 93:667–676. <https://doi.org/10.1644/11-MAMM-A-265.1>.
- Godínez-Gómez O., Schank C., Mas J. F. & Mendoza E. (2020). An integrative analysis of threats affecting protected areas in a biodiversity stronghold in Southeast Mexico. *Global Ecology and Conservation*, 24. <https://doi.org/10.1016/j.gecco.2020.e01297>
- Gompper M. E. (2014). Introduction: outlining the ecological influences of a subsidized, domesticated predator. *Free-ranging dogs and wildlife conservation*, 1-8. <https://doi.org/10.1093/acprof:osobl/9780199663217.001.0001>
- Hernández-Salazar J. (2020). Fichas población 2020. Implanuruapan, 1. <https://implanuruapan.gob.mx/wp-content/uploads/2021/06/Fichas-poblacion-2020-.pdf>
- Herrejón R. C., Castelán A., Concepción M. & Baltazar S. (2015). *Mamíferos silvestres de Michoacán guía de campo*. ISBN: 9786074245325
- Hidalgo-Mircea G., Cantú-Alazar L., González-Romero A., Historical and present distribution of coyote (*Canis latrans*) in Mexico and Central America (2004), *Journal of Biogeography* (Vol. 31, Issue 12). <https://doi.org/10.1111/j.1365-2699.2004.01163.x>

- Hughes J. & Macdonald D. W. (2013). A review of the interactions between free-roaming domestic dogs and wildlife. In *Biological Conservation* (Vol. 157, pp. 341–351). <https://doi.org/10.1016/j.biocon.2012.07.005>
- Korschgen L. (1957). Food habits of the coyote in Missouri. *Jour. Wildlife Mgt.* 21:424-435. <https://doi.org/10.2307/1375030>
- Kujala H., Moilanen A. & Gordon A. (2018). Spatial characteristics of species distributions as drivers in conservation prioritization. *Methods in Ecology and Evolution*, 9(4), 1121-1132. <https://doi.org/10.1111/2041-210X.12939>
- Larucea E. S., Brussard P. F., Jaeger M. M. & Barrett R. H. (2007). Cameras, coyotes, and the assumption of equal detectability. *The Journal of Wildlife Management*, 71(5), 1682-1689. <https://doi.org/10.2193/2006-407>
- Lacerda A. C. R, Marinho-Filho J. (2009) Domestic dogs as an edge effect in the Brasília National Park, Brazil: interactions with native mammals. *Anim Conserv* 12:477–487. <https://doi.org/10.1111/j.1469-1795.2009.00277.x>
- Larivière S. & Walton L. R. (1997). *Lynx rufus*. *Mammalian species*, (563), 1-8. <https://doi.org/10.2307/3504533>
- Larson R. N., Morin D. J., Wierzbowska I. A., & Crooks K. R. (2015). Food habits of coyotes, gray foxes, and bobcats in a coastal southern California urban landscape. *Western North American Naturalist*, 339-347. DOI:10.3398/064.075.0311
- Lavariega M. C., Briones-Salas M., Monroy-Gamboa A. G., & Ramos-Mendez D. (2022). Population density and daily activity patterns of bobcat in its southernmost continental distribution. *Animal Biodiversity and Conservation*, 45(2), 145-160. DOI:10.32800/abc.2022.45.0145
- Lessa I., Corrêa G., Godoy T., Cunha H. A. & Vieira M. E. (2016). Domestic dogs in protected areas: a threat to Brazilian mammals? In *Natureza e Conservacao* (Vol. 14, Issue 2, pp. 46–56). Elsevier B.V. <https://doi.org/10.1016/j.ncon.2016.05.001>
- Litvaitis J. A. & Harrison D. J. (1989). Bobcat–coyote niche relationships during a period of coyote population increase. *Canadian Journal of Zoology*, 67(5), 1180-1188.
- Lombardi J. V., Comer C. E., Scognamillo D. G., & Conway W. C. (2017). Coyote, fox, and bobcat response to anthropogenic and natural landscape features in a small urban area. *Urban Ecosystems*, 20, 1239-1248. DOI:10.1007/s11252-017-0676-z
- Matter H. C. & Daniels T. J. (2000). Dog ecology and population biology. En: Macpherson, C.N.L., Meslin, F.X., Wandeler, A.I. (Eds.), *Dogs, Zoonoses and Public Health*. CABI, Wallingford, UK. <https://doi.org/10.1079/9780851994369.0017>
- McTigue L. E., & DeGregorio B. A. (2023). Effects of land cover on mesocarnivore density and detection rate along an urban to rural gradient. *Global Ecology and Conservation*, 48, e02716. <https://doi.org/10.1016/j.gecco.2023.e02716>
- Mendoza M, Mendoza E & Gutiérrez-Peña E. (2024). Análisis estadístico de los índices de asociación de especies. *Revista de Ecología Tropical*.

doi:10.1017/S0266467424000105

- Morin D. J., Lesmeister D. B., Nielsen C. K. & Schauber E. M. (2022). Asymmetrical intraguild interactions with coyotes, red foxes, and domestic dogs may contribute to competitive exclusion of declining gray foxes. *Ecology and Evolution*, 12(7), e9074.
- Neale J. C. & Sacks B. N. (2001). Food habits and space use of gray foxes in relation to sympatric coyotes and bobcats. *Canadian Journal of Zoology*, 79(10), 1794-1800.
- Niedballa J. (2024). Package “camtrapR” Type Package Title Camera Trap Data Management and Preparation of Occupancy and Spatial Capture-Recapture Analyses. <https://doi.org/10.1111/2041-210X.1260>
- Orduña-Villaseñor M., Valenzuela-Galván D. & Schondube J. E. (2023). Your best friends can be your worst enemies: impact of domestic cats and dogs in megadiverse countries. *Revista Mexicana de Biodiversidad*, 94. <https://doi.org/10.22201/ib.20078706e.2023.94.4850>
- Orduña T. & Páez S. MA. (1993). Las Aves de la Sierra Purépecha del Estado de Michoacán. SARH, Instituto Nacional de Investigaciones Forestales y Agropecuarias, Centro de Investigación Pacífico Centro. *Boletín Divulgativo*, (79). CDD: F 598.2073 S1616a
- Ozoga J. J., & Harger E. M.. 1966. Winter activities and feeding habits of northern Michigan coyotes. *Jour. Wildlife Mgt.* 30:809-818. DOI: 10.2307/3798288
- Parsons A. W., Bland C., Forrester T., Baker-Whatton M. C., Schuttler S. G., McShea W. J. & Kays, R. (2016). The ecological impact of humans and dogs on wildlife in protected areas in eastern North America. *Biological Conservation*, 203, 75-88. <https://doi.org/10.1016/j.biocon.2016.09.001>
- Paschoal A. M. O., Massara R. L., Santos J. L. & Chiarello A. G. (2012). Is the domestic dog becoming an abundant species in the Atlantic Forest? A study case in southeastern Brazil. <https://doi.org/10.1515/mammalia-2012-0501>
- Plaza P. I., Speziale K. L., Zamora-Nasca L. B. & Lambertucci S. A. (2019). Dogs and cats put wildlife at risk. *The Journal of Wildlife Management*, 83(4), 767-768. DOI:10.1002/jwmg.21637
- Pollak E. M. (1951). Food habits of the bobcat in the New England States. *The Journal of Wildlife Management*, 15(2): 209-213. <https://doi.org/10.2307/3796612>
- R Core Team (2023). R (4.3.1): A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. <https://www.R-project.org>
- Ridout M. S. & Linkie M.. (2009). Estimating overlap of daily activity patterns from camera trap data. *Journal of Agricultural, Biological, and Environmental Statistics*, 14(3), 322–337. <https://doi.org/10.1198/jabes.2009.08038>.
- Ritchie E. G., Dickman C. R., Letnic M., Vanak A. T. & Gommper, M. (2014). Dogs as predators and trophic regulators. *Free-ranging dogs and wildlife conservation*, 55-68. :10.1093/acprof:osobl/9780199663217.003.0002

- Rodríguez-Luna C. R., Servín J., Valenzuela-Galván D. & List R. (2024). A matter of time not of co-occurrence: temporal partitioning facilitates coexistence between coyotes (*Canis latrans*) and gray foxes (*Urocyon cinereoargenteus*) in temperate forests of Mexico. *Mammalian Biology*, 104(4), 363-377. <https://doi.org/10.1007/s42991-024-00412-8>
- Rogers H. M., Glew L., Honzák M. & Hudson, M. D. (2010). Prioritizing key biodiversity areas in Madagascar by including data on human pressure and ecosystem services. *Landscape and Urban Planning*, 96(1), 48-56. <https://doi.org/10.1016/j.landurbplan.2010.02.002>
- Rovero F., Martin E., Rosa M., Ahumada J. A. & Spitalé D. (2014). Estimating species richness and modelling habitat preferences of tropical forest mammals from camera trap data. *PloS one*, 9(7), e103300. <https://doi.org/10.1371/journal.pone.0110971>
- Rowcliffe M. (2023). activity: Animal Activity Statistics. The Comprehensive R Archive Network <https://cran.r-project.org/web/packages/activity/index.html>
- Sánchez E. A. S. & Valdes J. (2013). La cuantificación del azar: una articulación de las definiciones subjetiva, frecuencial y clásica de probabilidad. *Probabilidad Condicionada: Revista de didáctica de la Estadística*, (1), 39-46. ISSN-e 2255-5854. <https://dialnet.unirioja.es/servlet/articulo?codigo=5487194>
- Schmid F. & Schmidt A. (2006). Nonparametric estimation of the coefficient of overlapping - Theory and empirical application. *Computational Statistics and Data Analysis*, 50(6), 1583–1596. <https://doi.org/10.1016/j.csda.2005.01.014>
- Servín J. & E. Chacón. (2005). Zorra gris (*Urocyon cinereoargenteus*). Los mamíferos silvestres de México (Ceballos, G., and G. Oliva, eds.). Fondo de Cultura Económica. Comisión Nacional para el Conocimiento y Uso de la Biodiversidad. México City, México. Pp. 354-355. https://doi.org/10.12933/therya_notes-24-147
- Vanak A.T., Gompper M.E. (2009). Dietary niche separation between sympatric free-ranging domestic dogs and Indian foxes in Central India. *J Mammal* 90:1058–1065. <https://doi.org/10.1644/09-MAMM-A-107.1>.
- Watabe R., Tsunoda H. & Saito M. U. (2022). Evaluating the temporal and spatio-temporal niche partitioning between carnivores by different analytical method in northeastern Japan. <https://doi.org/10.1038/s41598-022-16020-w>
- Wood J. E., Davis D. E. & Komarek E. V. (1958). The distribution of fox populations in relation to vegetation in southern Georgia. *Ecology*, 39:160-162. <https://doi.org/10.2307/1929984>
- Yackulic C. B. (2017). Competitive exclusion over broad spatial extents is a slow process: Evidence and implications for species distribution modeling. *Ecography*, 40(2), 305–313. <https://doi.org/10.1111/ecog.02836>
- Yen S. C., Ju Y. T., Shaner P. J. L. & Chen H. L. (2019). Spatial and temporal relationship between native mammals and free-roaming dogs in a protected area

surrounded by a metropolis. Scientific reports, 9(1), 8161. DOI: 10.1038/s41598-019-44474-y

Zapata-Ríos G., Branch L.C. (2016). Altered activity patterns and reduced abundance of native mammals in sites with feral dogs in the high Andes. Biol Conserv 193:916. <https://doi.org/10.1016/j.biocon.2015.10.016>

Supplementary material

Focal species activity levels and patterns

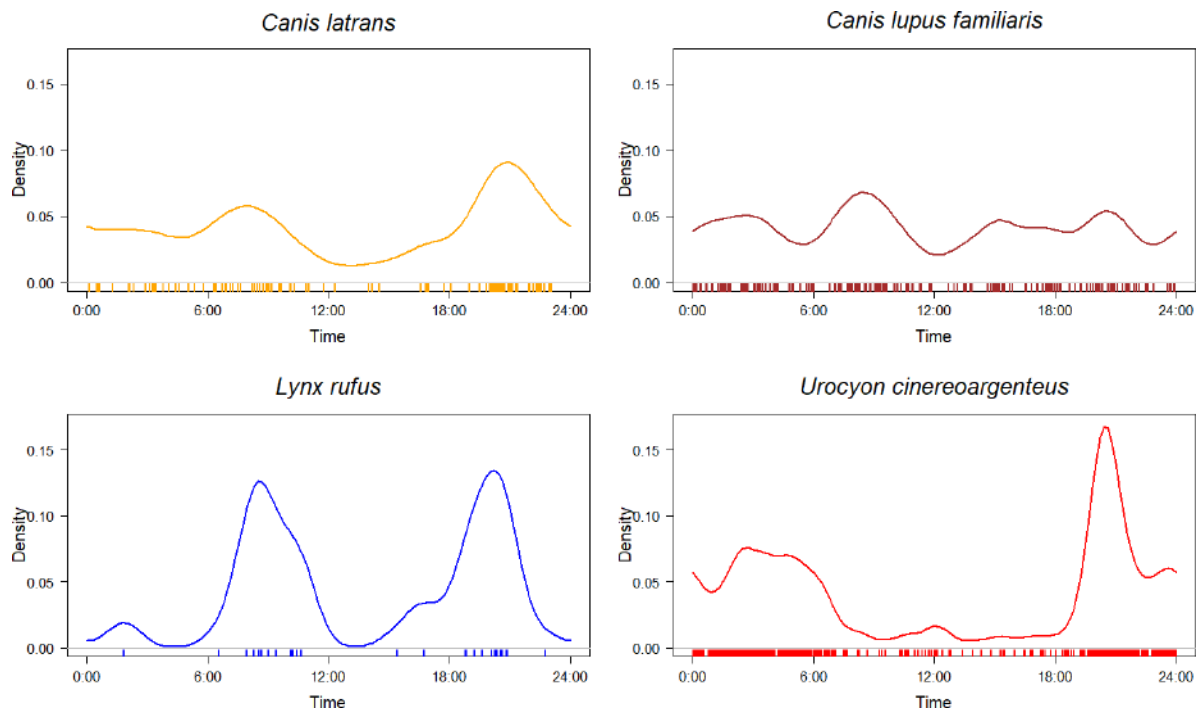


Figure S1. Daily activity patterns: *Canis latrans*, *Canis lupus familiaris*, *Lynx Rufus* and *Urocyon cinereoargenteus* from Barranca del Cupatitzio National Park in Uruapan, Michoacán, Mexico.

Table S1a. Activity levels of species: *Canis lupus familiaris*, *Urocyon cinereoargenteus*, *Canis latrans* and *Lynx rufus* in the National Park Barranca del Cupatitzio, Uruapan, Michoacán. *Urci* = *Urocyon cinereoargenteus*, *Caluf* = *Canis lupus familiaris*, *Cala* = *Canis latrans* and *Lyruf* = *Lynx rufus*, in the National Park Barranca del Cupatitzio, Uruapan, Michoacán, Mexico.

Species	% ativity	95% Confidence intervals
Caluf	0.6151	0.5101 - 0.7687
Cala	0.4584	0.3962 - 0.5183
Lyrú	0.3102	0.1939 - 0.3058
Urci	0.2482	0.2195 - 0.2950

Table S1b. Comparison of activity levels between the species *Canis lupus familiaris*, with the species: *Urocyon cinereoargenteus*, *Canis latrans*, *Lynx Rufus* in the National Park Barranca del Cupatitzio, Uruapan, Michoacán. Urci = *Urocyon cinereoargenteus*, Caluf = *Canis lupus familiaris*, Cala = *Canis latrans* and Lyrú = *Lynx rufus*.

Species	Difference	Valor de p
Cala - Caluf	0.1566	0.1117
Cala – Lyrú	0.1482	0.0153
Cala - Urci	0.2101	0.0001
Caluf - Lyrú	0.3048	0.0016
Caluf – Urci	0.3668	0.0001
Lyrú - Urci	0.0619	0.2125

Coincidence in spatial occurrence

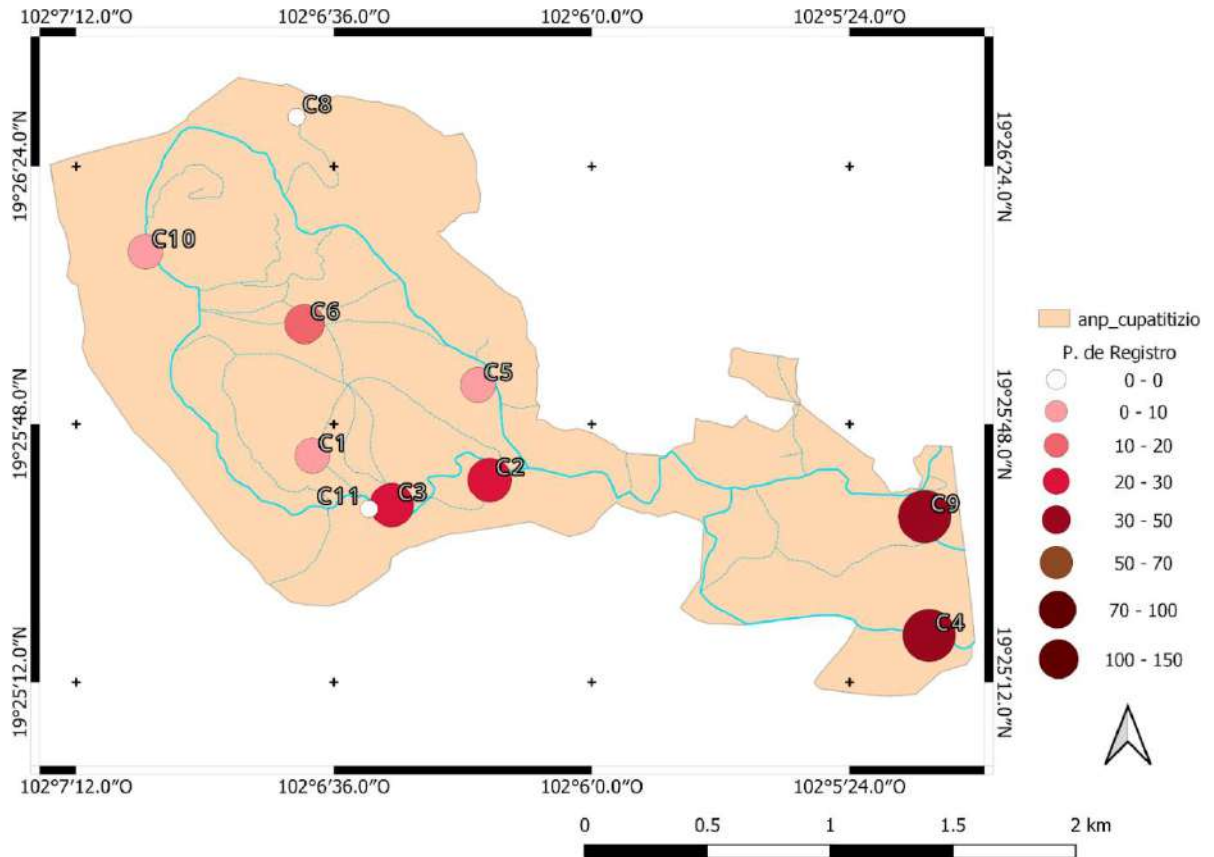


Figure S2. Number of dog (*Canis lupus familiaris*) records per camera trap in the Barranca del Cupatitzio National Park in Uruapan, Michoacán, Mexico.

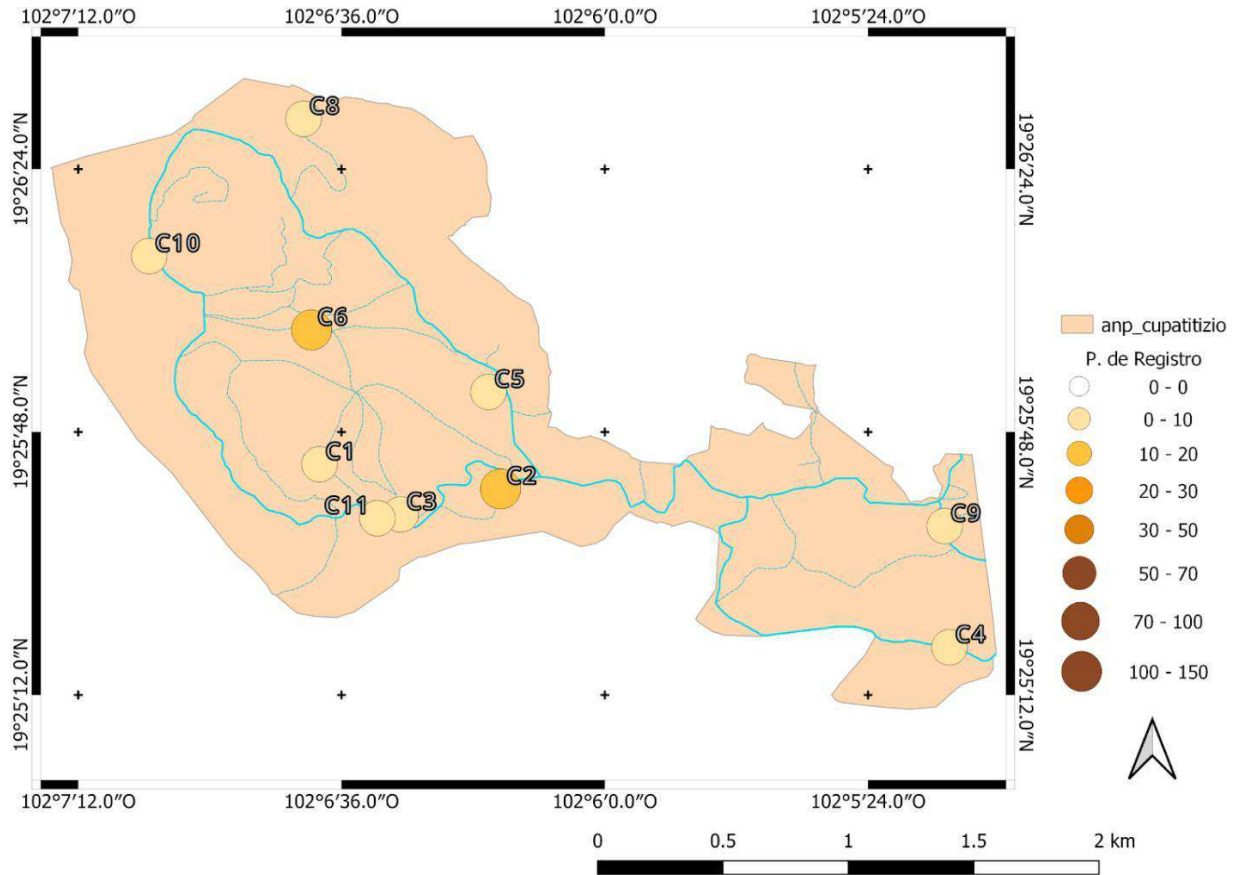


Figure S3. Number of coyote (*Canis latrans*) records per camera trap in the Barranca del Cupatitzio National Park in Uruapan, Michoacán, Mexico.

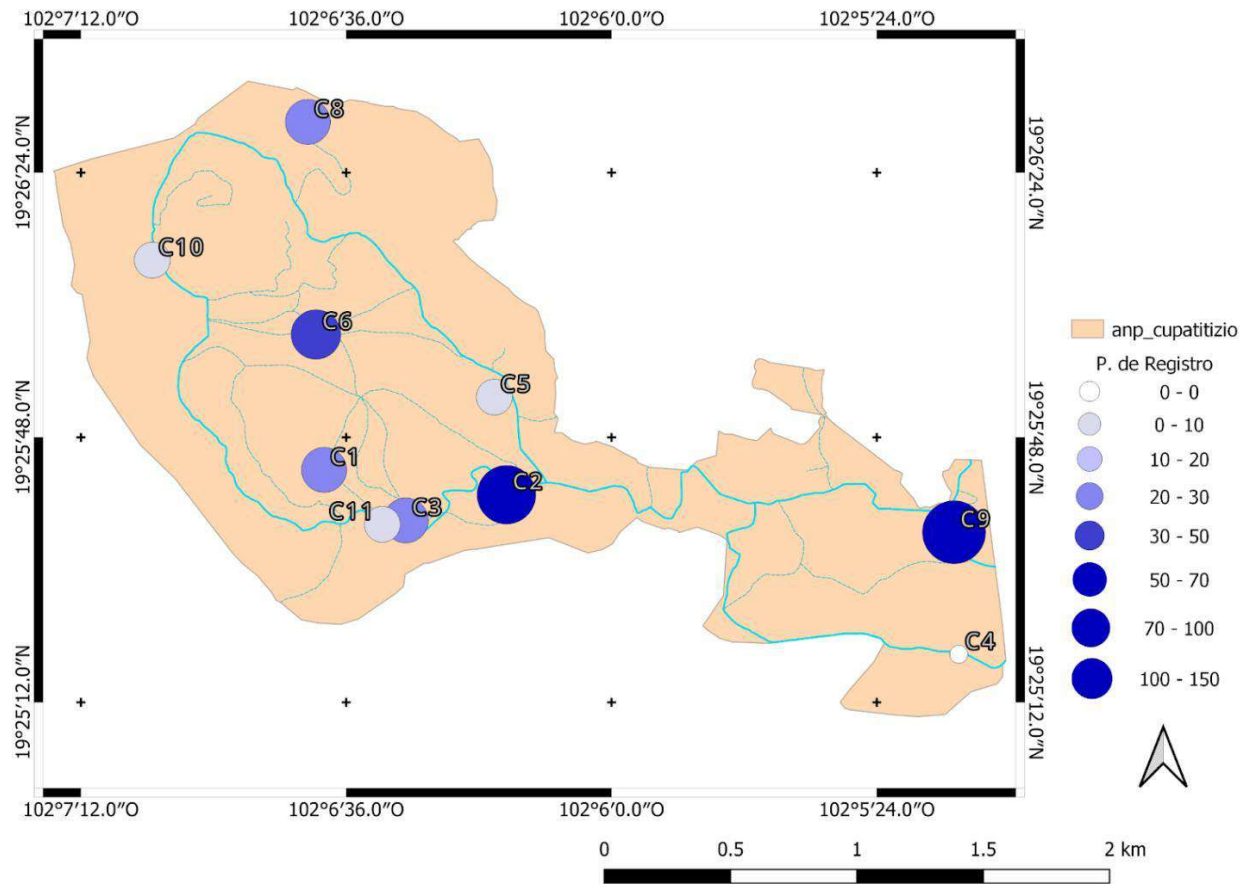


Figure S4. Number of gray fox (*Urocyon cinereoargenteus*) records per camera trap in the Barranca del Cupatitzio National Park in Uruapan, Michoacán, Mexico.

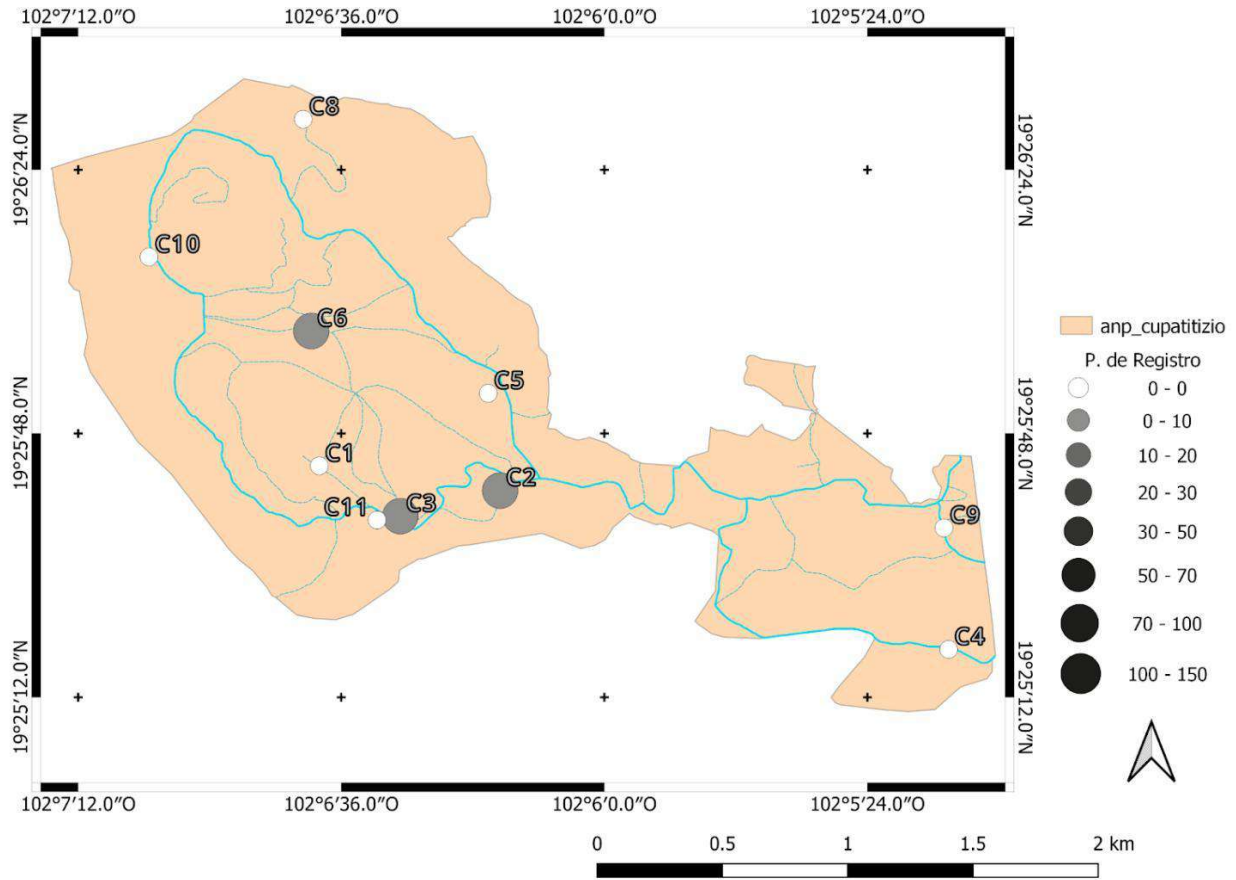


Figure S5. Number of bobcat (*Lynx rufus*) records per camera trap in the Barranca del Cupatitzio National Park in Uruapan, Michoacán, Mexico.

XI. **Capítulo II**

**Desarrollo de una metodología basada en el uso de IA
para el procesamiento de datos de fototrampeo e identificación automatizada de perros**

Enil Perales-Calderón ¹, Eduardo Mendoza ¹

Introducción

Un elemento importante dentro del manejo y conservación de la biodiversidad es el conocimiento del comportamiento de la fauna silvestre, su abundancia y patrones de actividad, tanto espaciales como temporales (Silveira et al., 2003). El fototrampeo es la técnica no invasiva más utilizada para el estudio y monitoreo de fauna, especialmente para los mamíferos terrestres (Mendoza et al., 2022; Mutwiri, 2022). El uso del fototrampeo en hábitats naturales ha transformado la investigación relacionada con el estudio de la ecología y conservación de la vida silvestre, y las publicaciones anuales de artículos que utilizan esta técnica se han multiplicado notoriamente desde 1994 (O'Connell et al., 2010; Delisle et al., 2021).

Si bien el contar con grandes volúmenes de imágenes y videos de la fauna es benéfico; su revisión, clasificación y la extracción de datos asociados, se ha convertido en un reto muy importante, por la inversión de tiempo y esfuerzo que requiere (Pérez et al., 2021). El tener que invertir una gran cantidad de tiempo y esfuerzo para el procesamiento de la información deriva en que, por razones prácticas, sólo se analice parte de la misma y esto afecta negativamente el alcance de los estudios (González et al., 2022).

La necesidad de extraer información de grandes volúmenes de datos (“Big data”) ha surgido de manera paralela en distintos aspectos de la actividad humana como en el caso de las mediciones de flujos de CO₂, agua y energía de los ecosistemas; (<https://ameriflux.lbl.gov/>), y la recopilación de las recomendaciones que se hacen en el comercio electrónico y la epidemiología (<https://www.isciii.es/>) (Farley et al., 2018; Choiński et al., 2021). El uso del aprendizaje automático y la visión por computadora, han surgido como una alternativa para facilitar la clasificación de imágenes en estudios de fototrampeo (Li et al., 2023). Estas técnicas pertenecientes al campo de la inteligencia

artificial (IA), permiten a una computadora interpretar imágenes y videos extrayendo de ellos patrones, contornos, colores y formas a través de algoritmos y aprendizaje automático (como las redes neuronales convolucionales), para las cuales se requieren conjuntos de imágenes manualmente etiquetadas de las cuales, el modelo puede aprender características y desarrollar así, su propio conjunto de patrones para realizar la identificación de objetos (Spiesman et al., 2021).

Los modelos basados en redes neuronales con aprendizaje profundo, se utilizan principalmente para analizar datos visuales, a partir del entrenamiento y validación del modelo. Esto les permite realizar predicciones y comparaciones de los objetos que se encuentran en los archivos (imágenes o videos), el tipo de objeto que se encuentra en ellos (clases o etiquetas) y la ubicación de estos objetos en los archivos. Estos modelos se entrenan a partir de procesar grandes cantidades de datos con patrones complejos lo que les permite reconocer objetos como las especies animales (Figura 1; Simonyan and Zisserman 2014).

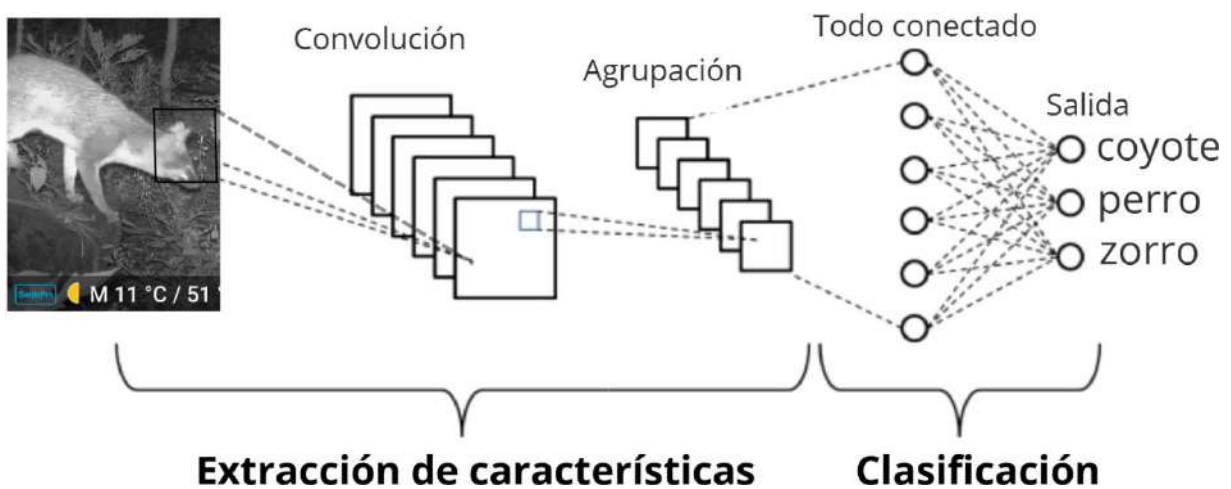


Figura 1. Proceso de entrenamiento de una red neuronal convolucional (algoritmo de aprendizaje profundo para datos visuales) de un modelo de visión por computadora. El modelo abstrae patrones visuales a partir de imágenes de entrenamiento y forma capas jerárquicas que permiten identificar objetos, asociarlos con clases

específicas y determinar su ubicación dentro de las imágenes.

La arquitectura You Only Look Once (YOLO) es una de las muchas arquitecturas de aprendizaje profundo creadas para la detección de objetos (Tyagi et al., 2023). Se ha destacado por sus importantes contribuciones a la visión por computadora, debido a su funcionamiento en tiempo real, facilidad de implementación y en particular su aplicación para el estudio de la fauna silvestre, ya que, en lugar de realizar múltiples pasos para detectar objetos en una imagen, YOLO analiza la imagen completa en un solo paso (Vélez et al., 2023). Por ejemplo, Bhagabati (2024) utilizó modelos de aprendizaje profundo y YOLOv5 para detectar tigres, elefantes y venados en tiempo real y abordar el conflicto humanos-fauna en Assam, e India. Por su parte, Leorna y Brinkman (2022) utilizaron la herramienta “MegaDetector” © Microsoft AI for Earth basado en YOLO para un estudio de fototrampeo en Alaska, EE UU. Este estudio se enfocó a identificar fortalezas y debilidades del uso de herramientas de IA para detectar fauna silvestre en comparación con la revisión hecha por humanos. Ellos concluyeron que a pesar de que esta herramienta de IA tuvo un rendimiento excepcional en la detección de fauna, seguía siendo necesario realizar una revisión minuciosa de las imágenes. Los resultados de este tipo de estudios han llevado a que se sigan explorando alternativas para mejorar la implementación de estas tecnologías en otros estudios sobre fauna silvestre (Bhagabati et al., 2024, Schindler y Steinhage 2021, Xie et al., 2023).

Existen algunas plataformas y software libre, en línea que permiten la identificación automatizada de especies de mamíferos, entre ellas están: Conservation AI (<https://www.conservationai.co.uk/>), MLWIC2 (<https://github.com/mikeyEcology/MLWIC2>) y Wildlife Insight

(<https://www.wildlifeinsights.org/>). La efectividad de estas plataformas para identificar algunas especies populares (p.ej. león, tigre) es alta ya que estos modelos son desarrollados con un sesgo a estas especies. Sin embargo, en especies poco comunes (p.ej. jaguarundi), tienen generalmente una efectividad de baja a moderada (Vélez et al., 2023). Otras plataformas como MegaDetector (<https://github.com/agentmorris/MegaDetector>) o MLWIC2 tienen una alta efectividad para separar imágenes vacías de las que presentan algún animal. Es por ello que, en la mayoría de los casos, los usuarios de plataformas para la identificación automatizada de especies, deben confirmar las predicciones de las páginas para asegurar que no se haya cometido algún error durante la clasificación. Aun así, estas plataformas facilitan el procesamiento de imágenes de cámaras trampa, al permitir filtrar un gran volumen de imágenes (p.ej. imágenes vacías) que se pueden verificar con mayor facilidad (Vélez 2023).

En caso de que las plataformas actuales no se adapten a las necesidades del investigador, se pueden crear modelos propios con librerías de uso gratuito que permitan realizar la clasificación de especies focales (Spiesman et al., 2021). El proceso para crear un modelo de identificación personalizado consta en: realizar el fototrampeo, etiquetar imágenes con objetos de interés, seleccionar el modelo de entrenamiento, entrenar el modelo y realizar pruebas sobre el modelo (Figura 2).

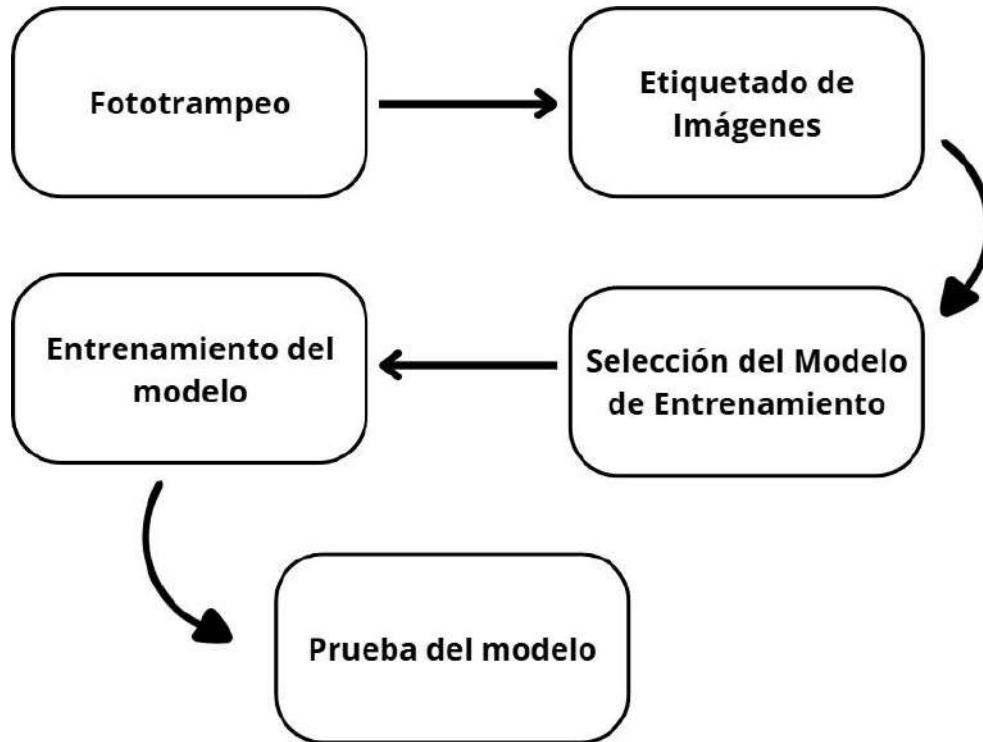


Figura 2. Proceso de creación de un modelo personalizado para la detección de objetos. El flujo de trabajo consta de cinco etapas: (1) realización del fototrampeo para obtener imágenes, (2) etiquetado de los objetos de interés en las imágenes, (3) selección del modelo de entrenamiento, (4) entrenamiento del modelo con los datos anotados y (5) evaluación mediante pruebas para validar su desempeño.

Etiquetado de imágenes

Hay dos problemas importantes a enfrentar en la detección automatizada de fauna silvestre. Por una parte, se requiere una enorme cantidad de etiquetado manual de las imágenes para entrenar los modelos y que sean efectivos para identificar las especies focales (Yu et al., 2013; Figura 3). Por otra parte, las imágenes de la fauna silvestre son muy heterogéneas en términos de composición de imagen (su iluminación, la posición en las que los individuos son registrados y la nitidez de la imagen), lo que dificulta aún más su identificación por medio de visión por computadora; ya que, la heterogeneidad de las

imágenes (incluso de una misma especie), repercute directamente en la calidad del entrenamiento de los modelos (Li et al., 2023; Figura 4).

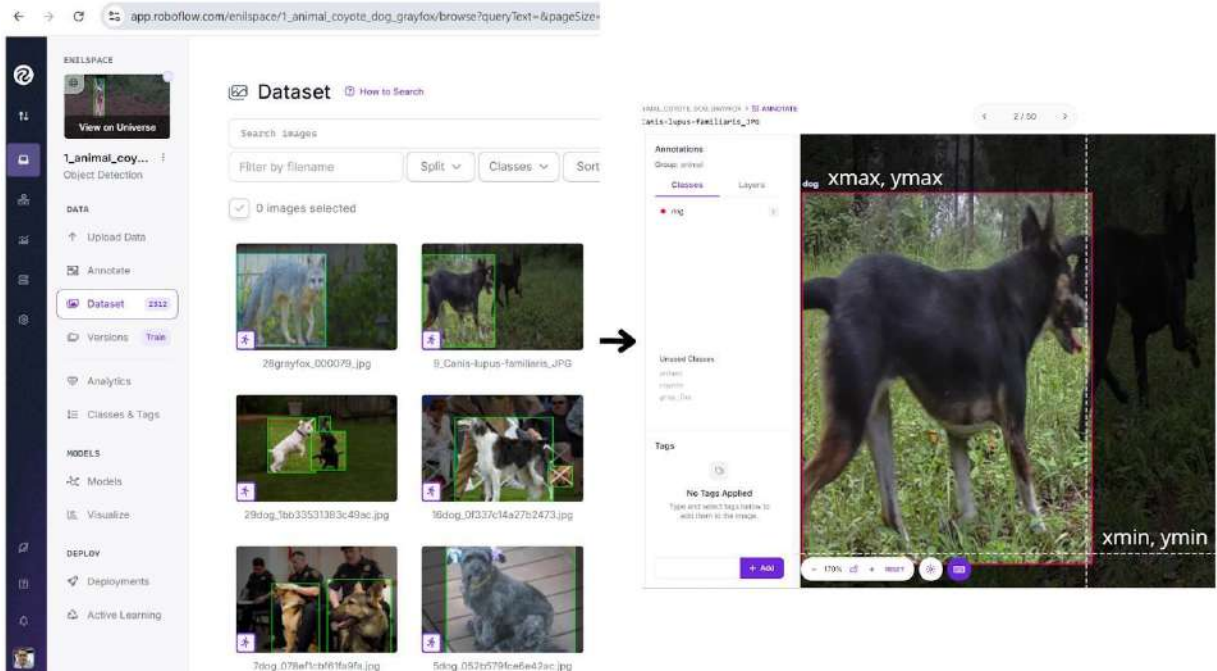


Figura 3. Etiquetado en la plataforma © RoboFlow. Este etiquetado se hace para cada imagen del conjunto de datos. Como parte del proceso se establece un perímetro que delimita el objeto que se desea que el modelo reconozca. Se guarda en un archivo las dimensiones de la imagen y las coordenadas de la caja (xmin, ymin, xmax, ymax), para el entrenamiento.

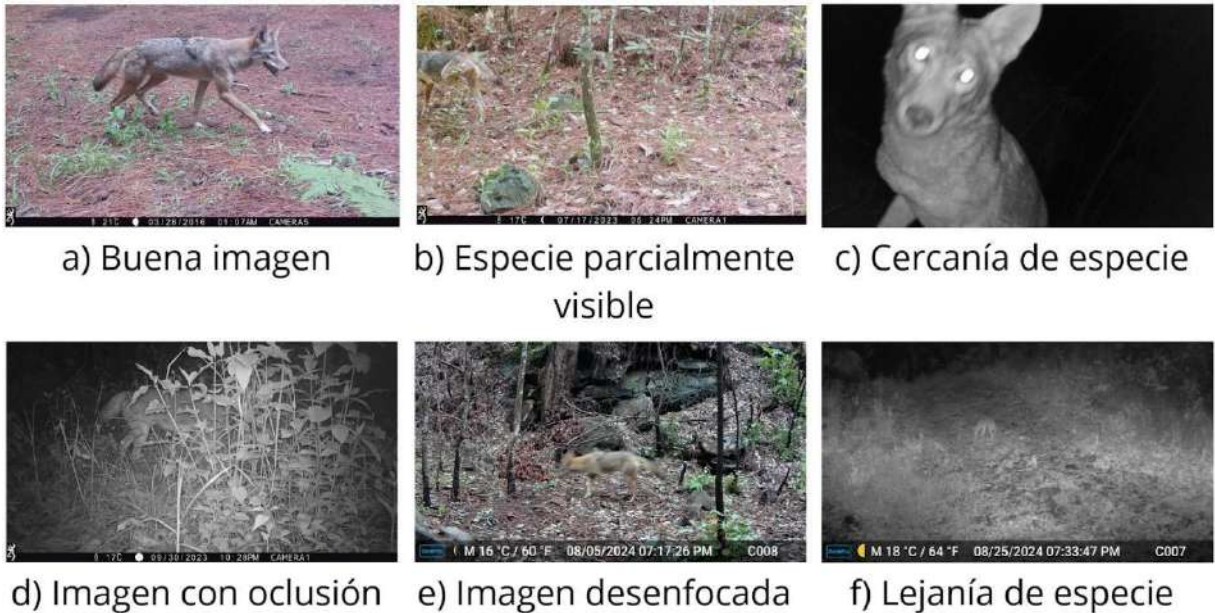


Figura 4. Ejemplos de imágenes de fototrampeo que muestran la gran variabilidad en las características de la forma en como la fauna es registrada que afectan la identificación automatizada por modelos de visión por computadora.

Selección del modelo de entrenamiento

Dentro del mundo de la identificación de objetos con el uso de visión por computadora e inteligencia artificial, existen una variedad de opciones que han sido desarrolladas por diferentes iniciativas, tales como: YOLO © Ultralytics, SSD © Google Research, Faster R-CNN © Microsoft Research, RetinaNet © Facebook AI Research y EfficientDet © Google Research. La selección del modelo es un paso muy importante antes de que sean personalizados, ya que cada uno de estos modelos, aunque todos están orientados al análisis de datos visuales, tienen diferentes propósitos. Por ejemplo, YOLO es ideal para detección de imágenes y videos en tiempo real y es utilizado en cámaras, mientras que SSD es más utilizado en aplicaciones móviles.

Entrenamiento del modelo

A lo largo de ciclos de entrenamiento, los modelos realizan inferencias sobre las imágenes que procesan creando cuadros delimitadores y asignando clases (etiquetas) a los objetos presentes en las imágenes (Figura 5). Los resultados de las predicciones son guardados y utilizados como parámetros que permiten evaluar el modelo (precisión y pérdida; Tabla 1), los cuales permiten a través de 10 gráficas (unidas en una sola imagen; Figura 5), hacer una visualización sobre el comportamiento del modelo durante el entrenamiento. Estos parámetros de entrenamiento están relacionados con predicciones como: presencia de un objeto (box_loss), clase a la que pertenece un objeto (etiqueta; cls_loss) y coordenadas del objeto dentro de la imagen (dfl_loss); así como: detecciones correctas sobre el total de detecciones y objetos detectados sobre el total de objetos en una imagen © software (yolov8 ultralytics) (Tabla 1). Por ejemplo, las curvas de pérdida “loss” indican cuánto error está cometiendo el modelo en los datos de entrenamiento y validación. Lo deseable es que todos los parámetros “_loss” disminuyan progresivamente; Figura 6). Existen relaciones entre estas métricas como las curvas F1 y Precisión-Recall (Figura 3S) que nos permiten identificar intervalos de confianza donde nuestros modelos son más certeros en sus predicciones y la proporción de predicciones correctas. Estas gráficas nos ayudan a realizar una primera evaluación del desempeño de los modelos y detectar fallos como sobre ajuste o pocos datos de entrenamiento gracias a las formas de las gráficas. Un mal entrenamiento puede manifestarse en las gráficas cuando el error en conjunto de entrenamiento disminuye continuamente, pero en el conjunto de validación se estabiliza, equivale a sobreajuste (Overfitting) © software (yolov8 ultralytics). Cuando hay oscilaciones significativas en las curvas equivale a entrenamiento inestable (puede darse por una tasa de aprendizaje inapropiado o datos de entrenamiento ruidosos; Figura 6).

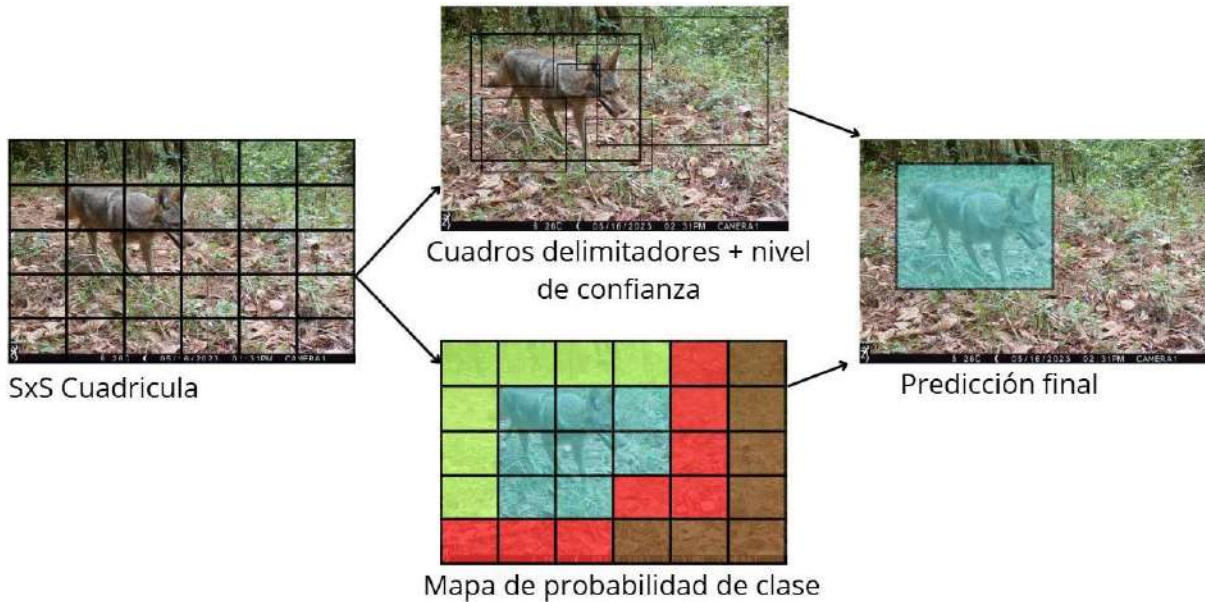


Figura 5. Representación de la inferencia para la ubicación de un objeto dentro de una imagen durante el entrenamiento. Este proceso estima de forma iterativa probabilidades sobre la presencia de clases (etiquetas) en regiones dentro de la imagen y afina progresivamente la precisión de la localización y clasificación de los objetos.

Tabla 1. Parámetros que permiten evaluar el error y métricas de validación del entrenamiento de un modelo de visión por computadora. Los valores de los parámetros de error (loss) se miden tanto en los datos de entrenamiento como en los de validación y están asociadas al aprendizaje del modelo (una disminución progresiva en los valores de error indica que el modelo está aprendiendo). Por su parte el un aumento progresivo en los valores de las métricas de precisión refleja una mejora en el desempeño del modelo.

Parámetros y Métricas	Tipo de Parámetro	Características que se evalúa	Indicador de Mejora
box_loss	Error	Predicción de coordenadas del objeto dentro de la imagen	Disminuye
cls_loss	Error	Predicción de la etiqueta a la que pertenece la clase	Disminuye

df_l_loss	Error	Predicción de presencia de un objeto	Disminuye
precisión	Precisión	Predicciones correctas sobre el total de detecciones	Aumenta
recall	Precisión	Proporción de objetos detectados sobre el total de objetos presentes en una imagen	Aumenta
mAP5	Precisión	Promedio de precisión para todas las clases	Aumenta

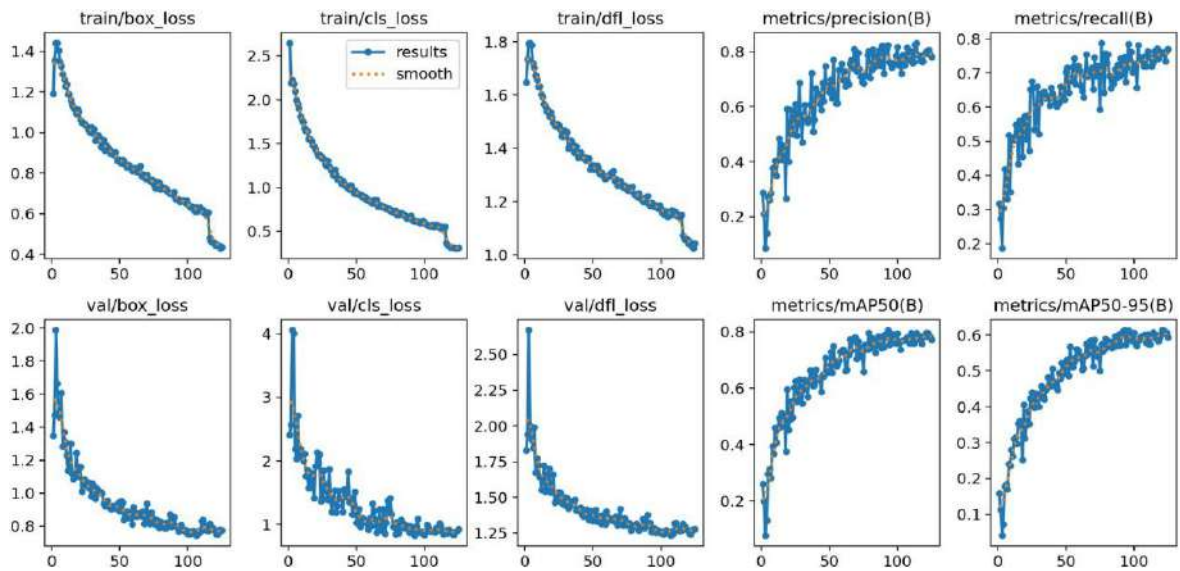


Figura 6. Curvas de parámetros de precisión y pérdida. Las curvas reflejan el comportamiento del modelo durante el entrenamiento. El eje x representa las épocas de entrenamiento. La disminución progresiva del error y el incremento en la precisión, indican la mejora y aprendizaje del modelo durante el entrenamiento, respecto a los datos de entrenamiento y validación.

Prueba del modelo

Aunque los indicadores de rendimiento obtenidos durante el entrenamiento (como la precisión, recall o mAP) brindan una primera aproximación del desempeño de un modelo de detección de objetos, es fundamental realizar una evaluación adicional utilizando registros reales de fototrampeo que no hayan sido etiquetados previamente. Esta validación independiente permite identificar aciertos y fallos en condiciones más cercanas a un contexto real. Evaluar los resultados con registros “reales” (registros de fototrampeo que no hayan sido utilizados para entrenar los modelos), revela qué tan bien generaliza el modelo nuevas imágenes y si es capaz de mantener un rendimiento consistente fuera del conjunto de entrenamiento (Leorna S. y Brinkman, 2022). En definitiva, esta prueba refleja el desempeño real del modelo en el entorno específico en el que se utilizará, permitiendo detectar sesgos, sobre ajustes o limitaciones prácticas que podrían no ser evidentes durante el proceso de entrenamiento.

Objetivos

Mediante el uso de herramientas de aprendizaje automático y visión por computadora a) separar registros (imágenes y videos) de fototrampeo vacías de las que tienen algún mamífero u otro objeto (Modelo 1), b) descartar registros de personas o vehículos, c) identificar los registros de fototrampeo de perros, coyotes y zorros (Modelo 2).

Materiales y Métodos

Características de la base de imágenes de fototrampeo

Se partió de una base de datos de 29,070 imágenes obtenidas con 10-11 cámaras

trampa, de las marcas: Bushnell (119932C), GardPro (T5NG) y Browning (BTC-5HD-850). Estas cámaras trampa estuvieron instaladas en el Parque Nacional “Barranca del Cupatitzio” (PNBC), que se encuentra a un costado de la ciudad de Uruapan, Michoacán (Figura 1S). La vegetación principal del PNBC es el bosque de pino, pino-encino y el bosque mesófilo de montaña (Bello y Madrigal et al., 1996). Del total de imágenes utilizadas para crear los modelos 123 fueron de *Canis latrans* (coyote), 247 de *Canis lupus familiaris* (perro), 760 de *Urocyon cinereoargenteus* (zorra gris), 500 imágenes con diferentes tipos de objeto (especie animal, persona o vehículo) y 500 imágenes vacías (con solo el follaje de fondo y rocas).

Selección de los modelos

Por su eficiencia y precisión en tareas de visión por computadora utilizamos YOLOv8 como modelo base e inicializamos los pesos preestablecidos con los que fue entrenado el Dataset COCO (Common Objects in Context) © Microsoft COCO. Esto proporciona una base sólida para el aprendizaje transferido, ya que este modelo permite una mejor adaptación a nuevas tareas de identificación, con menor cantidad de datos anotados (Alqaysi et al., 2021).

Entrenamiento de los modelos

Para crear los modelos separamos en tres grupos el total de imágenes utilizadas: entrenamiento, validación y pruebas. Esto es necesario para poder utilizar los parámetros de evaluación. Las imágenes fueron separadas de la siguiente manera: 80% para entrenamiento, 10% validación, 10% pruebas, para cada clase de los Modelos 1 y 2 (Tabla

2). Se utilizó un ajuste fino (fine tuning) para utilizar el aprendizaje de la red neuronal COCO y transferirlo a nuestros modelos y personalizamos el número de clases a identificar para cada modelo (Tabla 2). Se ajustó la resolución de las imágenes y el número de repeticiones del entrenamiento. El número de imágenes por ciclo de entrenamiento (tamaño de lote), se dejó en el valor predeterminado de 16 (Figura 7). Inicialmente el equipo de cómputo utilizado para realizar este procedimiento fue una HUAWEI MateBook 14 Notebook con Unidad Central de Procesamiento (CPU): AMD Ryzen 5 5500U, Unidad Procesamiento Grafico (GPU): AMD Radeon Graphics, RAM: 8GB y sistema operativo Windows 11. Sin embargo, durante el entrenamiento este equipo se sobrecalentó por lo que se migró a la plataforma gratuita en la nube © Google Colab (https://colab.research.google.com/github/roboflow-ai/notebooks/blob/main/notebooks/train-yolov8-object-detection-on-custom-dataset.ipynb?authuser=2#scrollTo=D2YkphuiaE7_). Se utilizó una Unidad de Procesamiento Gráfico (GPU), para realizar el entrenamiento, lo cual implicó aceptar sus limitaciones de disponibilidad en el plan gratuito.

Tabla 2. Características de los modelos personalizados utilizados en este estudio. Se incluye el tipo de clasificación realizada, las clases (etiquetas) detectables por cada modelo, el número de imágenes utilizadas para su entrenamiento, la cantidad de épocas empleadas durante el proceso de entrenamiento y el tiempo que duró su entrenamiento.

Modelo	Tipo de Modelo	Clases del Modelo	Conjunto de Imágenes	Número de Épocas	Tamaño del lote	Tiempo de Entrenamiento
Modelo 1	Binario	Objetos y Vacíos	1000	50	16	1 h
Modelo 2	Multiclase	Coyotes, Perros y Zorros	2,312	100	16	2h y 15 min




Figura 7. Ejemplo de un lote de 16 imágenes utilizado durante el entrenamiento del Modelo 1. En cada ciclo del entrenamiento el modelo toma 16 imágenes, calcula las predicciones y el error (pérdida o loss), promedia ese error y actualiza los parámetros del modelo (pesos) hasta completar una época.

Métricas de evaluación

Evalúe el desempeño de los modelos, con 1,757 imágenes y 103 videos obtenidos en seis cámaras trampa que estuvieron aproximadamente tres meses en funcionamiento.

Estas imágenes y videos fueron diferentes a los utilizados para entrenar los modelos. Les apliqué a las imágenes un algoritmo que de forma secuencial utiliza el Modelo 1 (Objetos y Vacíos), un Modelo pre-entrenado de alto desempeño y acceso gratuito (yolov8s.pt) con la finalidad de filtrar imágenes de personas y vehículos (conocido por su eficacia en detección de objetos de este tipo) y el Modelo 2 (coyotes, perros y zorros). Evalué la eficiencia de cada uno de los modelos para detectar sus respectivas clases (etiquetas), contando sus aciertos y fallos en la clasificación de los objetos presentes en cada archivo (imagen o video), por cada cámara trampa.

Resultados

Las curvas de pérdida (loss) y precisión sobre el progreso de aprendizaje del Modelo 1 durante su entrenamiento, en los parámetros de cajas delimitadoras (box_loss), clases de objetos (cls_loss) y presencia de objetos en las imágenes (dfl_loss), mostraron una evolución positiva en la que se disminuyeron los errores (box, cls y dfl). Esto indicó un incremento en el aprendizaje del modelo (Figura 2S).

El aumento progresivo de las métricas mAP@50 y mAP@50-95 indicó a su vez una mejora en la precisión de las predicciones realizadas por el modelo, en contraste, con las clases del etiquetado manual (Figura 2S). Además, las curvas de Precisión y Recuperación (Figura 3S) muestran que se alcanza el mejor umbral de confianza F1 del modelo (Figura 3Sa), cuando se ajusta aproximadamente en 0.5 la exigencia para aceptar predicciones.

Para la clase vacío (color naranja), tiene una curva más alta y más estable lo que indica que el modelo tiene mejor rendimiento para identificar esta clase en casi todos los niveles de confianza. Para la clase objeto (color azul claro) tiene un F1 más bajo, especialmente cuando la confianza es alta (> 0.8), lo que puede indicar que el modelo

pierde muchas detecciones verdaderas si se vuelve muy estricto para esta clase. Por su parte la curva de precisión de recuperación (Figura 3Sb), muestra que el modelo, en términos generales, es muy preciso para ambas clases con 0.96 mAP@0.5. Tomando en cuenta la cercanía al vértice superior derecho (Recuperación ≈ 1 , Precisión ≈ 1) el Modelo 1 es especialmente bueno en detectar la clase vacío (color naranja) ya que obtuvo un comportamiento excelente con un (valor de área bajo la curva de 0.99. Este modelo también es bueno para detectar la clase objeto (color azul claro), pero ligeramente menos confiable 0.93 (valor de área bajo la curva).

El Modelo 1 aplicado a los registros de las seis cámaras de evaluación, tuvo una buena capacidad para distinguir entre imágenes donde aparecían animales y donde no, ya que detectó correctamente el 88% de las imágenes con animales y descartó correctamente el 90% de las imágenes vacías (Figura 8; Figura 9). Por su parte y como continuación del filtrado de archivos (imágenes y videos), el modelo pre-entrenado yolov8s.pt descartó correctamente el 95% de imágenes en donde aparecen personas (Figura 8; Figura 9).

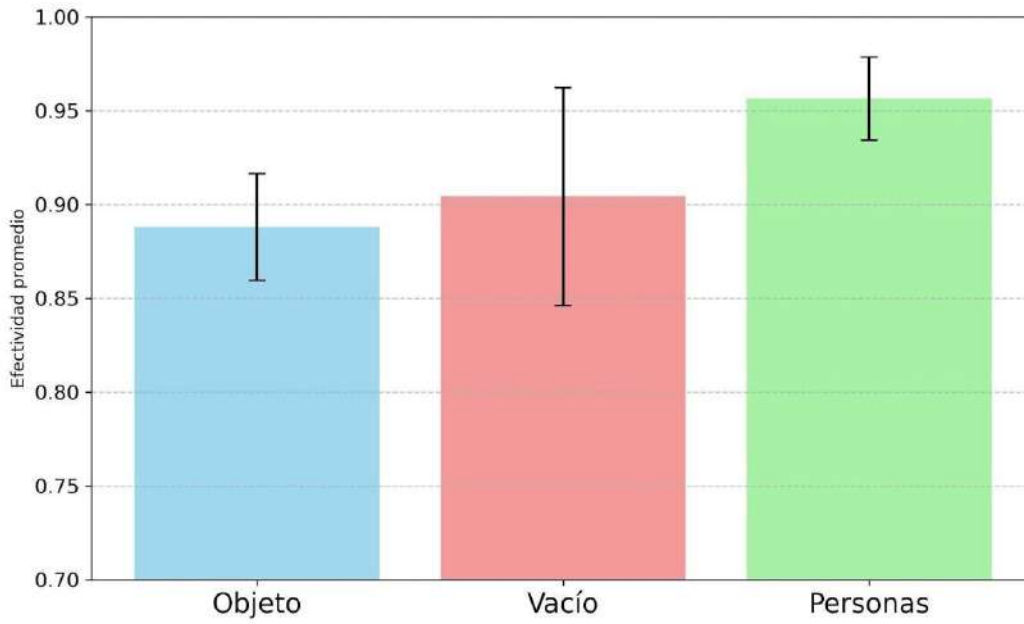


Figura 8. Efectividad del Modelo 1 y el Modelo yolov8s.pt, basadas en el conteo de aciertos y errores al clasificar imágenes. Las gráficas reflejan el desempeño del Modelo 1 (objetos y vacíos) y el Modelo yolov8s.pt (personas) en función de su capacidad para detectar correctamente sus clases permitiendo evaluar su utilidad en tareas específicas de filtrado y clasificación de imágenes.

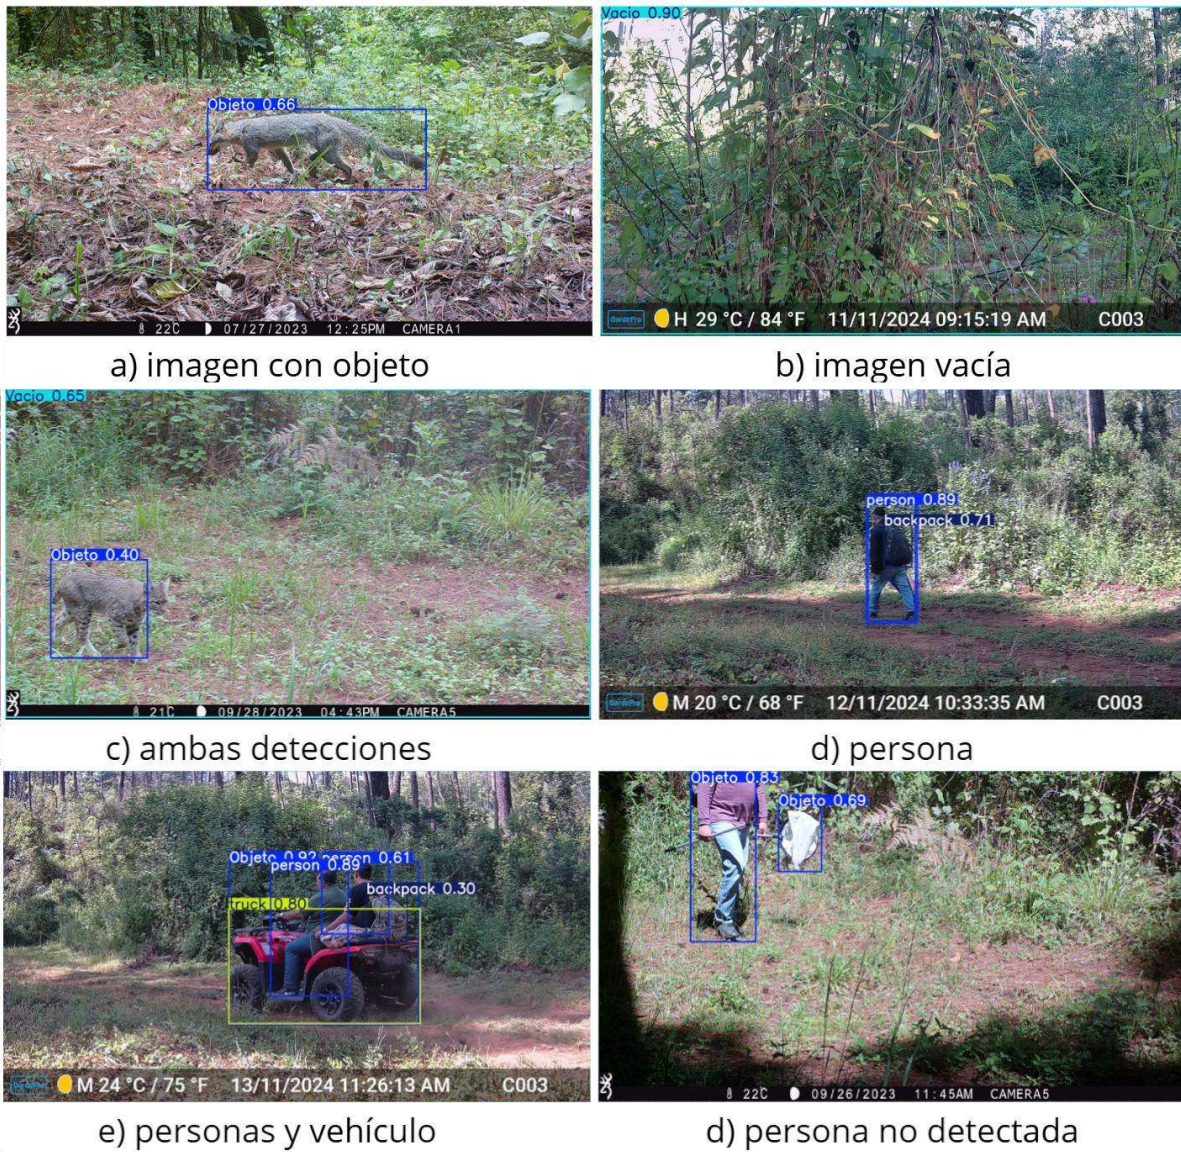


Figura 9. Ejemplos de detecciones realizadas por el Modelo 1 (a, b, c) diseñado para identificar imágenes con vacíos o con objetos y por el modelo pre entrenado “yolov8s.pt” (d, e, f) enfocado en la detección específica de personas. Las imágenes ilustran el comportamiento de ambos modelos ante diferentes escenarios registrados por cámaras trampa.

La utilidad del Modelo 1 en la clasificación de registros de fototrampeo (imágenes o videos), resultó en el filtrado de un gran número de registros vacíos que no son útiles para el estudio de la fauna silvestre. En algunas de las cámaras de prueba logró descartar correctamente casi la mitad de registros que esta captó durante los tres meses de muestreo

(Tabla 3), lo cual se traduce en un gran volumen de archivos no útiles filtrados correctamente.

Tabla 3. Detecciones del Modelo 1 en primer filtrado de imágenes (vacías y con objetos) en 6 cámaras trampa de evaluación. La tabla resume el desempeño del modelo en la clasificación inicial de registros útiles para el análisis de vida silvestre descartando los vacíos de forma automatizada. V = videos, I = imágenes.

Cámara Trampa	No. Registros	No. de Registros con Objetos	No. de Registros con Objetos Detec.	No. de Registros con Vacíos	No. Registros con Vacíos Detec.
T1	37 ^V	26	26	11	9
T2	497 ^I	271	237	226	166
T6	285 ^I	184	177	101	101
T7	513 ^I	457	407	56	53
T8	461 ^I	227	187	235	220
T9	66 ^V	26	26	46	27

Por su parte, en el filtrado de registros con personas el modelo yolov8s.pt tuvo una gran utilidad y clasifico correctamente un gran número de registros, acertando en algunas cámaras todos los registros de personas que estas habían captado (Tabla 4). Reduciendo considerablemente la cantidad de registros de fototrampeo, no útiles en estudios de fauna.

Tabla 4. Detecciones del Modelo Pre-entrenado para el segundo filtrado de imágenes (personas y vehículos) por cada cámara trampa de evaluación. La tabla resume los archivos sobrantes del primer filtrado y el desempeño del modelo para clasificar imágenes/videos con presencia de personas ya que estos no son útiles para para el análisis de vida silvestre. V = videos, I = imágenes.

Cámara Trampa	No. Registros	No. de Registros con Personas	No. de Registros con Personas Detectados
T1	28 ^V	-	-
T2	297 ^I	107	103
T6	177 ^I	57	51
T7	500 ^I	283	274
T8	202 ^I	6	6
T9	45 ^V	1	1

El Modelo 2 también mostró una evolución positiva durante su entrenamiento, al disminuir los errores (Box, Object y Clasification), más el aumento progresivo de las métricas maP@50 y mAP@50-95 indicando una mejora en la precisión de las predicciones realizadas por el modelo (Figura 4S). Las curvas de Precisión y Recall del Modelo 2 (Figura 5S) muestran que este modelo alcanza el mejor umbral de confianza F1 (Figura 5Sa) cuando el modelo filtró predicciones con una confianza aproximada de 0.6.

La clase más débil del Modelo 2, es la clase coyote (color naranja). Su curva se mantiene por debajo de las demás en la mayoría de los tramos, con un F1 menor incluso en los mejores puntos. Puede estar teniendo problemas con falsos positivos o falsos negativos. Por su parte, la clase perro (color verde), tiene un muy buen desempeño, con un F1 alto y estable. La clase zorro gris (color rojo), también tiene una buena estabilidad, aunque con ligeras caídas en algunos tramos.

Por su parte la curva Precisión de recuperación (Figura 5Sb) muestra que el desempeño del modelo en términos generales es bueno para las distintas clases con 0.93 mAP@0.5. Tomando en cuenta la cercanía al vértice superior derecho (Recuperación \approx 1, Precisión \approx 1), el Modelo 2 tiene tendencias menos estables que el Modelo 1 y esto refleja

la dificultad que tuvo el modelo en generalizar las detecciones para cada especie.

El Modelo 2 tuvo una capacidad moderada para identificar imágenes de coyotes, perros y zorros. Este modelo identificó correctamente el 57% de las imágenes donde aparecieron coyotes, 60% en las que aparecían perros y 65% donde aparecían zorros (Fig. 10; Figura 11). La utilidad del Modelo 2 en la clasificación de coyote, perro y zorro, resulto en la clasificación correcta de una parte significativa de los registros de cada cámara (Tabla 5). Destacando su rendimiento en la detección de zorro, en las cámaras T6 con 42 de 44 y T8 con 72 de 92 detecciones correctas. También fue eficaz identificando perros en T6 con 20 detecciones de 24 registros y coyotes en T2 con 23 detecciones de 29 registros. En general, estos resultados evidencian que el Modelo 2 es útil para automatizar la clasificación preliminar de especies focales, facilitando el manejo de grandes volúmenes de datos en estudios de monitoreo de fauna.

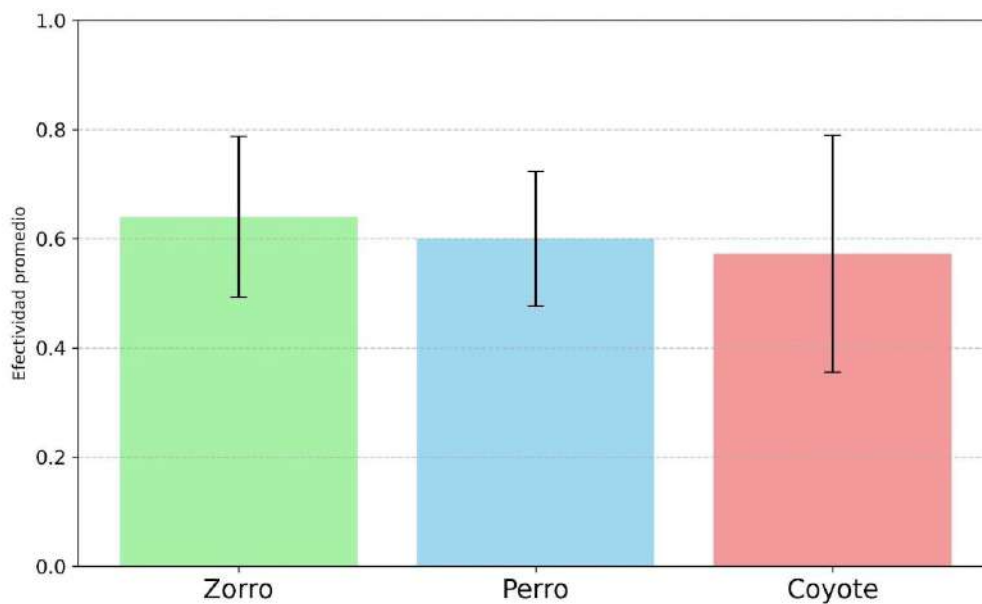


Figura 10. Efectividad del Modelo 2 basadas en el conteo de aciertos y errores al clasificar imágenes de coyotes, perros y zorros en cámaras (n=6).

Tabla 5. Detecciones del Modelo 2 para el tercer filtrado de imágenes (perros, coyotes y zorros), por cada cámara trampa de evaluación. La tabla resume el desempeño del modelo en la clasificación final de archivos con especies focales para el análisis de vida silvestre de forma automatizada. V = videos, I = imágenes.

Cámara Trampa	No. Registros	No. Total, Registros de Perros	No. de Registros Perros Detec.	No. Total, Registros Coyotes	No. de Registros Coyotes Detec.	No. Total, Registros Zorros	No. de Registros Zorros Detec.
T1	28 ^v	2	2	-	-	2	2
T2	194 ⁱ	9	5	29	23	-	-
T6	126 ⁱ	24	20	1	0	44	42
T7	226 ⁱ	46	19	-	-	26	7
T8	196 ⁱ	-	-	6	3	92	72
T9	44 ^v	-	-	-	-	9	5



Figura 11. a-c) Ejemplos de detecciones correctas realizadas por el Modelo 2. Ejemplos de detecciones, donde el modelo identificó adecuadamente las especies presentes. d) Caso de confusión entre especies: individuos de venado fueron incorrectamente etiquetados como perros, e) Imagen con dos coyotes donde el modelo identificó correctamente a uno, pero asignó la etiqueta perro al otro, f) Detección errónea de un zorro parcialmente visible al que el modelo clasificó como perro.

El tiempo que fue invertido por una persona para clasificar los registros de las seis cámaras de prueba, fue mayor que el requerido para clasificar con el uso de los modelos. En promedio le tomó a una persona 18.5 min clasificar los registros de una cámara trampa,

mientras que con el uso de los modelos de visión por computadora el tiempo promedio se redujo a 5.8 min (Tabla 6). Se pudo notar que los modelos de visión por computadora trabajan notablemente rápido al organizar imágenes y clasificar un gran número de registros en muy poco tiempo, como en el caso de la trampa de prueba T7. El algoritmo clasificó 513 imágenes en 6min, lo que, en comparación con la persona, que le tomó 32 min. Con respecto a los registros de videos, a pesar de que los modelos también fueron más rápidos que la persona, el tiempo de clasificación no cambió demasiado (Tabla 6).

Tabla 6. Comparación del tiempo requerido para clasificar los registros obtenidos por seis cámaras trampa mediante: clasificación manual realizada por una persona y clasificación automatizada mediante un modelo de detección de objetos. Se muestra el tiempo total invertido por cada método para evidenciar la diferencia en eficiencia. V = videos, I = imágenes.

Cámara Trampa	No. Registros	Tiempo de clasificación manual (min)	Tiempo de clasificación de los modelos (min)
T1	37 ^V	12	7.5
T2	497 ^I	12	8
T6	285 ^I	26	3
T7	513 ^I	32	6
T8	461 ^I	17	2.5
T9	66 ^V	12	8
Promedio	309.8	18.5	5.8

Discusión

El Modelo 1 (entrenado para la clasificación binaria de imágenes con objetos e

imágenes vacías) y Modelo 2 (entrenado para la identificación específica de coyotes, perros y zorros) presentaron diferencias en su desempeño. En general el Modelo 1 tuvo un buen desempeño descartando imágenes y videos vacíos y dejando archivos útiles para el análisis de vida silvestre. Esta alta eficiencia se traduce en un gran número de archivos (imágenes o videos) filtrados que no son útiles para el análisis de vida silvestre, lo cual es muy útil para el investigador. Sin embargo, en otras cámaras llegó a clasificar como archivos vacíos alguna imagen o video que sí contenían alguna especie, lo cual no permite automatizar por completo el proceso de clasificación en el contexto de un proyecto de fototrampeo.

Por su parte el Modelo 2 tuvo un mayor número de errores de clasificación y omisiones que obligan a mantener una revisión manual para asegurar la calidad y precisión de los resultados. Esto representa una limitación importante en la implementación práctica de estos modelos y plantea desafíos para su uso; pero, pueden ser utilizados como herramientas de apoyo para un primer filtrado automatizado. Por lo que si bien no resuelve de manera completa el problema sí puede contribuir a optimizar el flujo clasificación de archivos, reduciendo el tiempo para la depuración de los mismos.

La integración de modelos de visión por computadora en proyectos de fototrampeo puede representar una estrategia valiosa para acelerar el procesamiento de grandes volúmenes de imágenes o videos y apoyarse con metodologías más escalables como el uso de personas en una segunda instancia para la revisión de archivos.

En términos de detección, así como en otros estudios (Li 2023) se tuvieron casos de detección errónea y omitida (al dejar un archivo sin realizar predicción alguna cuando sí estaba presente un de las clases para la que fue entrenado un modelo), e incluso detecciones de una especie como dos animales diferentes, pero aun así confirmé y estoy de acuerdo con (Yu 2013) que las técnicas de reconocimiento de visión por computadora se pueden utilizar

eficazmente para identificar mamíferos silvestres. Li et al. (2023) desarrollaron un modelo propio con el cual obtuvieron una precisión mAP 2.9% superior que el mismo conjunto de datos entrenado con YOLOv7 y 0.5 % mayor que el entrenado con YOLOv8 mostrando la importancia de personalizar nuestros propios modelos. Por otra parte, los resultados concuerdan con Gómez (2017), en que la clasificación automática de especies sigue siendo en la actualidad un problema no resuelto, a pesar de existir varios proyectos que intentan abordar el problema (Leorna y Brinkman, 2022).

Por su parte las plataformas Conservation AI (<https://www.conservationai.co.uk/>), MLWIC2 (<https://github.com/mikeyEcology/MLWIC2>) y Wildlife Insight (<https://www.wildlifeinsights.org/>), también sufren de detecciones erróneas, o están más especializadas en detectar solo algunas especies en zonas particulares en el mundo. Al utilizar estas plataformas Vélez et al. (2023), con un conjunto de datos que contiene 3611 de imágenes de cámaras trampa, con un total de 10,222 imágenes llamada “Snapshot Kgalagadi” (<https://lila.science/datasets/snapshot-kgalagadi>), reportó que el puntaje más bajo del parámetro F1 (umbral de confianza) correspondió a las plataformas MegaDetector y MLWIC2 (con un 0.87 y 0.53 respectivamente), cuando se evaluó utilizando un umbral de confianza de 0.65 % y presentando una recuperación de baja a moderada.

Sin embargo, la precisión para algunas especies y grupos taxonómicos superiores (p. ej. género, familia, orden o clase), generalmente incrementó la puntuación F1 en las categorías evaluadas), en la plataforma Conservation AI, las puntuación F1 más alta se obtuvo a nivel de clase (91 % para la clase Mammalia), a nivel de orden (puntuación F1 del 91 % para el orden Artiodactyla), además de predicciones altamente precisas para la especie *Struthio camelus* (con F1 del 99%), Wildlife Insights también tuvo puntajes F1 relativamente altos en los niveles de clase (79% para Mammalia en el conjunto), orden

(79% para Otidiformes) y familia (79% para Otidae). El puntaje F1 más alto para MLWIC2 fue para la clase Mammalia (77%).

Por otra parte, Gómez (2017) destaca que la clasificación realizada por personas también está sujeta a errores, tanto en la clasificación de vacíos como en la clasificación de especies. Esta problemática se acentúa en proyectos que involucran ciencia ciudadana, donde la experiencia y el conocimiento de los participantes pueden afectar la calidad del etiquetado. Al igual que en otros estudios (Vélez et al., 2023; Gómez et al., 2017) los desafíos comunes asociados con el reconocimiento de imágenes mediante IA, como: la variabilidad de precisión, al clasificar en cámaras con diferentes campos visuales (mayor o menor densidad vegetal), es persistentes incluso cuando se utilizaron modelos entrenados a partir de conjuntos de imágenes amplios y diversos; estos factores repercuten en el rendimiento del modelo para clasificar especies.

En su estudio Gómez (2017) utilizó un modelo de identificación automática de especies aplicado también al conjunto de datos Snapshot Serengeti (<https://lila.science/datasets/snapshot-serengeti>) enfocado en 26 de las especies más comunes en ese parque y reportó una precisión del 88.9 % para la especie más común que denominaron Top-1 y del 98.1 % para el Top-5. Gómez et al. (2017) concluyó que es posible obtener altos niveles de clasificación para especies en imágenes de cámaras trampa.

Por su parte (Vélez et al., 2023) concluye que, a pesar de los desafíos de la identificación de especies mediante el uso de visión por computadora, las plataformas impulsadas por inteligencia artificial pueden ayudar a los ecólogos a establecer flujos de trabajo más eficientes. Un ejemplo de ello es el trabajo de Fennell et al. (2022) donde reporta que el uso de la herramienta MegaDetector aumentó la eficiencia del procesamiento en un 500% en comparación con un flujo de trabajo completamente manual.

El área de investigación para la clasificación de especies es activa y tanto los modelos como las plataformas están en constante desarrollo lo cual debería conducir a un mejor rendimiento con el tiempo (Vélez et al., 2023).

El utilizar modelos de visión por computadora pueden ser benéficos para proyectos de foto trapeo al ser implementados en un flujo de trabajo semiautomatizado mientras el desarrollo de los modelos continúa de forma paralela buscando obtener mejores resultados. Entre otras cosas, el desempeño de los modelos puede estar relacionado con la posición en que fue colocada la cámara ya que p. g: el Modelo 1 clasificó correctamente todas las imágenes vacías de una de las cámaras de prueba que estuvieron activas durante un periodo de tres meses de funcionamiento (Cámara T6; Tabla 3). Es posible que el buen desempeño en esta cámara se deba a las características de panorama (composición de imagen) que esta cámara registra, ya que tiene cobertura vegetal poco densa, un panorama reducido y las especies solo pueden pasar cercanas a la cámara.

La flexibilidad de poder utilizar y adaptar a nuestras necesidades modelos pre-entrenados de alto rendimiento y especializados, también nos permite filtrar un gran volumen de registros que no son útiles para el estudio de vida silvestre, como personas y vehículos. La suma del filtrado de modelos con altas efectividades para detectar sus clases permite reducir de forma significativa la cantidad de registros que deben ser revisados manualmente y queda muy por debajo del número total de archivos originales, haciendo más fácil el trabajo de organización de archivos.

En conclusión, el uso de modelos de visión por computadora para el filtrado semiautomatizado de imágenes y videos en estudios de fototrapeo representa una herramienta valiosa para optimizar el manejo de grandes volúmenes de archivos (imágenes o videos). En este estudio alcanzó niveles altos de clasificación de imágenes con

herramientas totalmente gratuitas y obtuvo resultados similares a los reportados por (Vélez et al., 2023). Sin duda hay más herramientas y técnicas que se pueden explorar para afinar con mayor detalle la efectividad de los modelos. La integración de modelos de visión por computadora en proyectos de fototrampeo representa una estrategia prometedora para agilizar el procesamiento de grandes volúmenes de imágenes y videos. Este enfoque permite automatizar la detección preliminar de especies de interés, lo cual no solo reduce significativamente la carga de trabajo manual, sino que, también facilita la implementación de metodologías más escalables. En este sentido, el uso de revisores humanos como una segunda instancia para validar o corregir los resultados generados por los modelos automatizados puede optimizar tanto la precisión como la eficiencia del análisis de datos. Propongo que la visión por computadora aplicada en estudios de fototrampeo sea utilizada como una herramienta no de automatización total, ya que la revisión manual de los momentos captados en cámara le brinda al investigador información adicional sobre el comportamiento de una especie. También es importante la revisión manual para evitar la pérdida de registros importantes por errores de clasificación de los modelos, ya que estos podrían afectar los resultados de los análisis sobre la especie.

Referencias

- Alqaysi H., Fedorov I., Qureshi, F.Z. O’Nils, M. A. (2021) Temporal boosted YOLO based model for birds detection around wind farms. *Imaging*, 227. <https://doi.org/10.3390/jimaging7110227>
- Bello M. & Madrigal X. (1996). Estudio florístico del campo experimental “Barranca del Cupatitzio”, Uruapan, Michoacán. *Folleto Científico*, 2.
- Bhagabati B., Sarma K. & Bora K. C. (2024). An automated approach for human-animal conflict minimisation in Assam and protection of wildlife around the Kaziranga National Park using YOLO and SENet Attention Framework. *Ecological Informatics*, 79, <https://doi.org/10.1016/j.ecoinf.2023.102398>.
- Bhattacharya S., Sultana M., Das B. (2024) A deep neural network framework for

- detection and identification of bengal tigers. *Innovations Systems Software Engineering*, 151–159. <https://doi.org/10.1007/s11334-021-00431-5>
- Chen G., Han T. X., He Z., Kays R. & Forrester T. (2014) “Deep convolutional neural network based species recognition for wild animal monitoring,”. *IEEE International Conference on Image Processing*, pp. 858–862. <https://doi.org/10.1109/ICIP.2014.7025172>
- Choiński M., Rogowski M., Tynecki P., Kuijper D. P. J., Churski M. & Bubnicki J. W. (2021). A First Step Towards Automated Species Recognition from Camera Trap Images of Mammals Using AI in a European Temperate Forest. *Springer Nature*, 299–310. https://doi.org/10.1007/978-3-030-84340-3_24
- Delisle Z. J., Flaherty, E. A., Nobbe, M. R., Wzientek, C. M., & Swihart, R. K. (2021). Next-generation camera trapping: systematic review of historic trends suggests keys to expanded research applications in ecology and conservation. *Frontiers in Ecology and Evolution*, 9. <https://doi.org/10.3389/fevo.2021.617996>
- Farley S., Dawson A., Goring S. & Williams J. (2018). Situating ecology as a big-data science: Current advances, challenges, and solutions. *BioScience*, 563–576. <https://doi.org/10.1093/biosci/biy06>.
- Fennell M., Beirne C. & Burton A. C. (2022). Use of object detection in camera trap image identification: Assessing a method to rapidly and accurately classify human and animal detections for research and application in recreation ecology. *Global Ecology and Conservation*, 35. <https://doi.org/10.1016/j.gecco.2022.e02104>
- Gómez A., Salazar A., Vargas F. (2017). Towards Automatic Wild Animal Monitoring: Identification of Animal Species in Cameratrapp Images using Very Deep Convolutional Neural Networks, *Ecological Informatics*, <https://doi.org/10.1016/j.ecoinf.2017.07.004>
- Gonzalez F., Viera L., Soler R., Chiarvetto P. L., Gel M., Bustamante G. & Pérez I. (2022). Inteligencia artificial para la multi-clasificación de fauna en fotografías automáticas utilizadas en investigación científica. *SEDIC*, 2-3. <https://doi.org/10.48550/arXiv.2502.04064>
- Guo J., He G., Deng H., Fan W., Xu L., Cao L. & Hassan S. G. (2022). Pigeon cleaning behavior detection algorithm based on light-weight network. *Computers and Electronics in Agriculture*, 199. <https://doi.org/10.1016/j.compag.2022.107032>
- Guo Q., Wang C., Xiao D. & Huang Q. (2023). Automatic monitoring of flying vegetable insect pests using an RGB camera and YOLO-SIP detector. *Precision Agriculture*, 24(2), 436–457. <https://doi.org/10.1007/s11119-022-09952-w>
- Kumar S. V. & Kondaveeti H. K. (2024). Towards transparency in AI: Explainable bird species image classification for ecological research. *Ecological Indicators*, 169, 112886. <https://doi.org/10.1016/j.ecolind.2024.112886>
- Leorna S. & Brinkman T. (2022). Human vs. machine: Detecting wildlife in camera trap images. *Ecological Informatics*, 72, <https://doi.org/10.1016/j.ecoinf.2022.101876>

- Li S., Zhang H. & Xu, F. (2023). Intelligent Detection Method for Wildlife Based on Deep Learning. *Sensors*, 1-2. <https://doi.org/10.3390/s23249669>
- Li D., Ahmed F., Wu N. & Sethi A. I. (2022). Yolo-JD: A Deep Learning Network for jute diseases and pests detection from images. *Plants*, 937. <https://doi.org/10.3390/plants11070937>
- Mendoza E., Camargo-Sanabria A. & Godínez-Gómez O. (2022). Is camera trapping helping us to fill knowledge gaps related to the conservation of wild mammals? *Journal for Nature Conservation*, 1-2. <https://doi.org/10.1016/j.jnc.2022.126282>
- Mutwiri M. (2022). Wildlife Species Detection Using an Image Analysis System Deployed on a Wireless Sensor Node. *Heliyon*, 1–19. <https://doi.org/http://dx.doi.org/10.2139/ssrn.4039647>
- Nichols J. D., O’Connell A. F., & Karanth K. U. (2011). Camera traps in animal ecology and conservation: What’s next? *Springer Nature*, 253-263. https://doi.org/10.1007/978-4-431-99495-4_14
- Nguyen H., Maclagan S. J., Nguyen T. D., Nguyen T., Flemons P., Andrews K. & Phung D. (2017). Animal recognition and identification with deep convolutional neural networks for automated wildlife monitoring. *IEEE international conference on data science and advanced Analytics*, pp. 40-49. doi:10.1109/dsaa.2017.31
- Schindler F., Steinhage V. (2021). Identification of Animals and Recognition of Their Actions in Wildlife Videos Using Deep Learning Techniques. *Ecological Informatics*, 61. <https://doi.org/10.1016/j.ecoinf.2021.101215>
- Silveira L., Jácomo A. T. & Diniz-Filho J. A. F. (2003). Camera trap, line transect census and track surveys: a comparative evaluation. *Biological Conservation*, 351-355. [https://doi.org/10.1016/S0006-3207\(03\)00063-6](https://doi.org/10.1016/S0006-3207(03)00063-6)
- Spiesman B. J., Gratton C., Hatfield R. G., Hsu W. H., Jepsen S., McCornack B. & Wang G. (2021). Assessing the potential for deep learning and computer vision to identify bumble bee species from images. *Scientific reports*, 11(1), 7580. <https://doi.org/10.1038/s41598-021-87210-1>
- Tyagi H., Saroj V. K., Shahzad M. D. & Agarwal A. (2023). Evolution of YOLO: Exploring the advancements in YOLOv8 for real-time wildlife detection. *ABES*, 1-2.
- Vélez J., McShea W., Shamon H., Castiblanco-Camacho P. J., Tabak M. A., Chalmers C. & Fieberg J. (2023). An evaluation of platforms for processing camera-trap data using artificial intelligence. *Methods in Ecology and Evolution*, 14(2), 459-477. <https://doi.org/10.1111/2041-210X.14044>
- Wen C., Chen H., Ma Z., Zhang T., Yang C., Su H. & Chen H. (2022). Pest-YOLO: A model for large-scale multi-class dense and tiny pest detection and counting. *Frontiers in Plant Science*, 13, <https://doi.org/10.3389/fpls.2022.973985>.
- Xie Y., Jiang J., Bao H., Zhai P., Zhao Y., Zhou X. & Jiang G. (2023). Recognition of Big Mammal Species in Airborne Thermal Imaging Based on YOLO V5 Algorithm. *Integr. Zoology*, 333–352. <https://doi.org/10.1111/1749-4877.12667>

Yu X., Wang J., Kays R., Jansen P. A., Wang T. & Huang T. (2013). “Automated identification of animal species in camera trap images,” *Springer Nature*, vol. 2, no. 1, pp. 1–10. <https://doi.org/10.1186/1687-5281-2013-52>

Material suplementario

Sito de Estudio

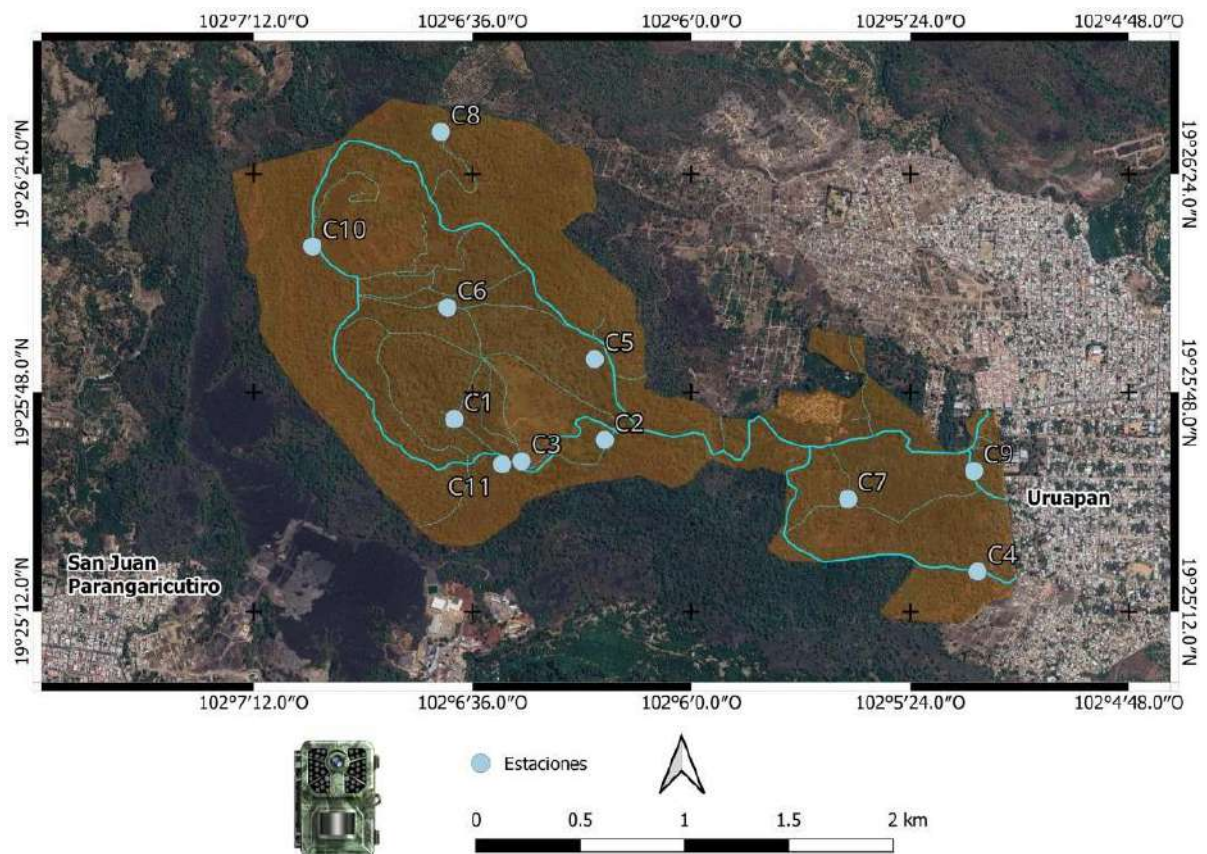


Figura S1. Distribución de las cámaras trampa utilizadas para muestrear la fauna de mamíferos terrestres medianos y grandes presentes en el Parque Nacional Barranca del Cupatitzio en Uruapan, Michoacán, México.

Resultados de Entrenamiento de los Modelos

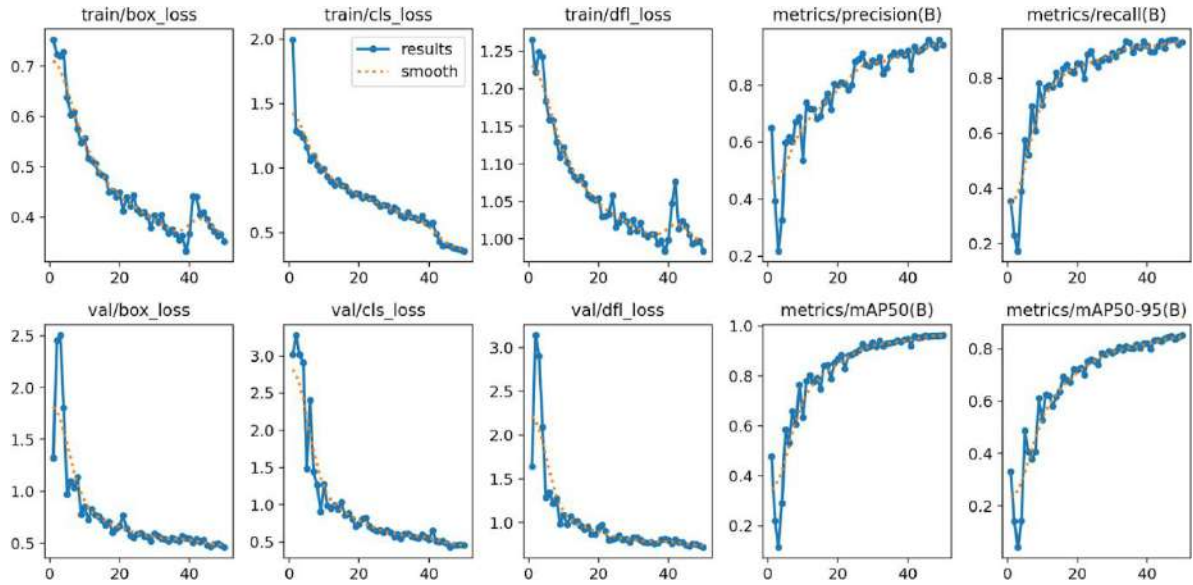


Figura S2. Curvas de pérdida (loss) y precisión del entrenamiento del Modelo 1. Las gráficas muestran la evolución del desempeño del modelo en función de las épocas, mostrando el proceso de optimización de los parámetros y la mejora progresiva de la capacidad de identificación.

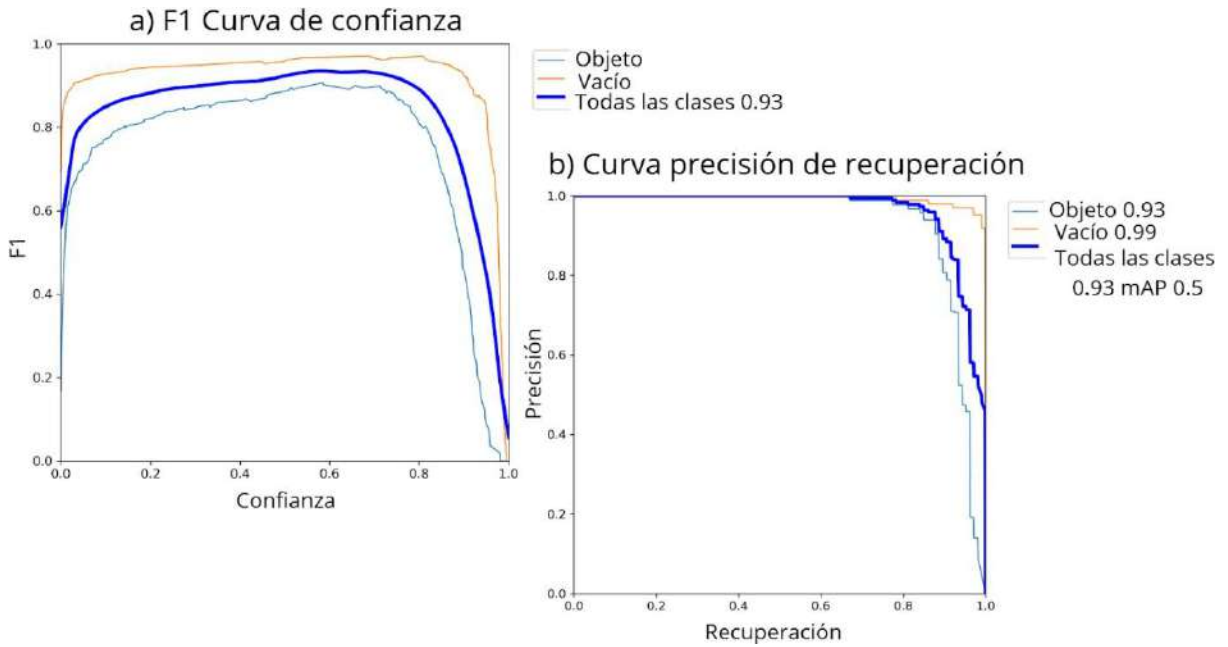


Figura S3. Curva F1 de confianza (umbral de confianza), curva Precisión-Recall (relación entre precisión y detecciones reales) del Modelo 1. La curva F1 permite identificar el umbral (rango) de confianza que maximiza la precisión. La curva de precisión de recuperación (Precisión-Recall) muestra la relación entre la detección correcta de objetos dentro de la imagen contra el total de objetos que realmente se encontraban en dicha imagen.




Figura S4. Curvas de pérdida (loss) y precisión durante el entrenamiento del Modelo 2. Las gráficas muestran la evolución del desempeño del modelo en función de las épocas, mostrando el proceso de optimización de los parámetros y la mejora progresiva de la capacidad de identificación.

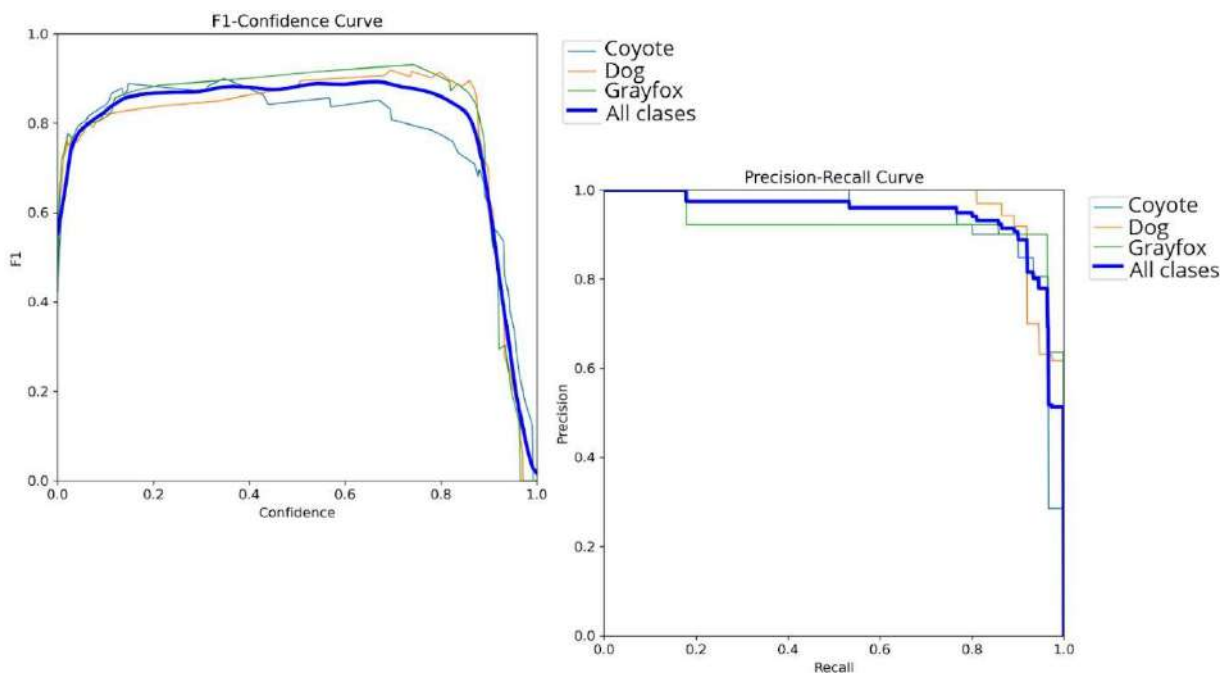


Figura S5. Curva F1 de confianza (umbral de confianza), curva Precision-Recall (relación entre precisión y detecciones reales) del Modelo 2. La curva F1 permite identificar el umbral (rango) de confianza que maximiza la precisión. La curva de Precisión-Recall muestra la relación entre la detección correcta de objetos dentro de la imagen contra el total de objetos que realmente se encontraban en la imagen.

XII. Discusión general

Esta investigación generó información sobre los patrones de actividad de perros y tres especies de mesocarnívoros nativos en el PNBC, lo que permitió identificar las zonas y periodos del día con mayor presencia de estas especies y así evaluar su potencial de interacción. A partir de estos resultados concluimos que existe una alta posibilidad de que las especies silvestres sean impactadas negativamente por los perros. Los resultados de esta investigación pueden servir al personal encargado del cuidado del PNBC para enfocar las estrategias de control de la fauna introducida en los sitios en donde ésta es más activa. Dada la alta presencia de perros en el parque y los altos traslapes espacio-temporales que presentaron con algunas especies de la fauna silvestre, se vuelve relevante plantear el desarrollo de estudios más detallados sobre los impactos que se pueden estar generando.

Para diseñar priorizar e implementar eficazmente planes y acciones de conservación, es necesario saber cómo y dónde afectan los perros a la vida silvestre y seguir mejorando el conocimiento de los efectos que causan los perros en la fauna (Doherty, 2017; Young et al., 2011). Por ejemplo, se pueden realizar estudios para evaluar la dieta de los perros y determinar el grado en el consumo fauna nativa del PNBC (García, 2012). Así mismo, dado que los perros están asociados con más de 60 enfermedades zoonóticas (Matter y Daniels, 2000), es urgente realizar evaluaciones de su estado de salud para tener una mayor certeza de su potencial para afectar a las especies silvestres (Figuerêdo et al., 2022). Los ámbitos de movimiento de los perros también pueden ser un factor importante a evaluar ya que están estrechamente vinculados a su capacidad de dispersión de patógenos. Otro factor que influye en su capacidad de transmitir enfermedades es el grupo al que pertenecen los perros (p.ej., asociados principalmente a hogares, los que se mueven libremente, y los que no requieren contacto humano) (Hughes y Macdonald, 2013). Sería ideal implementar estudios de telemetría para poder hacer un análisis de los territorios de los perros y mesocarnívoros nativos y así tener información complementaria para definir su potencial de interacción (Marin, 2024).

Por otra parte, esta investigación generó una aportación valiosa al monitoreo del parque, al abordar el procesamiento de la información de fototrampeo de manera automatizada a través de la visión por computadora e IA. Se crearon dos modelos de clasificación para registros de fototrampeo y reducir el tiempo de clasificación de especies. El filtrado de registros vacíos (Modelo 1) tuvo un buen desempeño haciendo detecciones correctas en la mayoría de los casos, pero no permitió automatizar el proceso por completo, ya que en algunos casos clasificó como registro vacío algún archivo que contenía una especie en la imagen o video y fue necesario hacer la corrección de forma manual para evitar la pérdida de registros valiosos. Esto sucedió también con el modelo para identificación de especies (perro, coyote, zorro gris; Modelo 2). Sin embargo, la rapidez con la que la visión por computadora clasifica los registros de fototrampeo (imágenes o videos) es una gran ventaja ya que supera la velocidad que se puede tener con trabajo realizado directamente por humanos. De esta manera, ambos modelos pueden permitir simplificar el proceso de organización y clasificación de archivos de fototrampeo.

Los resultados obtenidos en este proyecto permiten contar con una línea base para evaluar los impactos que los perros tienen sobre la fauna silvestre. El continuar este

monitoreo podrá permitir contar con elementos sólidos para evaluar el impacto que las estrategias de manejo y conservación que se implementen tengan sobre el control de esta especie introducida. Por otra parte, el continuar con el desarrollo de herramientas tecnológicas que permitan hacer más eficiente el monitoreo de la fauna silvestre sería muy importante para apoyar a que áreas naturales protegidas como el PNBC pueda cumplir su tarea fundamental de proteger la biodiversidad.

XIII. Referencias

- Banks P.B. & Bryant J.V. (2007). Four-legged friend or foe? Dog walking displaces native birds from natural areas. *Biology Letters*, 611 – 613. <https://doi.org/10.1098/rsbl.2007.0374>
- Doherty T. S., Dickman C. R., Glen A. S., Newsome T. M., Nimmo D. G., Ritchie E. G., Vanak A. T. & Wirsing A. J. (2017). The global impacts of domestic dogs on threatened vertebrates. *Biological Conservation*, 56–59. <https://doi.org/10.1016/j.biocon.2017.04.007>
- Figuerêdo M., de Souza A. & Lux E. G. (2022). Filarids (Spirurida: Onchocercidae) in wild carnivores and domestic dogs from the Brazilian Atlantic forest. *PLoS Neglected Tropical Diseases*, 16. <https://doi.org/10.1371/journal.pntd.0010213>
- García M. C. (2012). Monitoreo de la población de perros ferales en la Isla de Cedros, Baja California, y las amenazas a la mastofauna nativa. *Acta zoológica mexicana*, 28(1), 37-48. ISSN 2448-8445
- Marin C. & Couderchet L. (2024). Unveiling hidden aspects of GPS deployment on wildlife: A multistep and transdisciplinary approach to urban wild boar monitoring. *MethodsX*, 13. <https://doi.org/10.1016/j.mex.2024.102931>
- Matter H. C. & Daniels T. J. (2000). Dog ecology and population biology, dogs, zoonoses and public health., *Wallingford, UK*. <https://doi.org/10.1079/9780851994369.0017>
- Young J. K., Olson K. A., Reading R. P., Amgalanbaatar S. & Berger, J. (2011). Is wildlife going to the dogs? Impacts of feral and free-roaming dogs on wildlife populations. *BioScience*, 125-132. <https://doi.org/10.1525/bio.2011.61.2.7>
- Zapata-Ríos G. & Branch L. C. (2016). Altered activity patterns and reduced abundance of native mammals in sites with feral dogs in the high Andes. *Biological Conservation*, 9-16. <https://doi.org/10.1016/j.biocon.2015.10.016>