

UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ

Colegio de Ciencias Biológicas y Ambientales

Hacia una nueva era automatizada: evaluación de la precisión de la inteligencia artificial AddaxAI, para la detección de ocelotes (*Leopardus pardalis*) en registros de cámaras trampa con datos de 2014 - 2024 en Tiputini, Yasuní.

Juan Diego Chávez Reyes

BIOLOGÍA

Trabajo de fin de carrera presentado como requisito

para la obtención del título de

Biólogo

Quito, 9 de mayo del 2025

UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ

Colegio de Ciencias Biológicas y Ambientales

HOJA DE CALIFICACIÓN

DE TRABAJO DE FIN DE CARRERA

Hacia una nueva era automatizada: evaluación de la precisión de la inteligencia artificial AddaxAI, para la detección de ocelotes (*Leopardus pardalis*) en registros de cámaras trampa con datos de 2014 y 2024 en Tiputini, Yasuní.

Juan Diego Chávez Reyes

Gonzalo Rivas-Torres, Doctor en Ecología y Conservación de la Vida Silvestre

Quito, 9 de mayo del 2025

© DERECHOS DE AUTOR

Por medio del presente documento certifico que he leído todas las Políticas y Manuales de la Universidad San Francisco de Quito USFQ, incluyendo la Política de Propiedad Intelectual USFQ, y estoy de acuerdo con su contenido, por lo que los derechos de propiedad intelectual del presente trabajo quedan sujetos a lo dispuesto en esas Políticas.

Asimismo, autorizo a la USFQ para que realice la digitalización y publicación de este trabajo en el repositorio virtual, de conformidad a lo dispuesto en la Ley Orgánica de Educación Superior del Ecuador.

Nombres y apellidos: Juan Diego Chávez Reyes

Código: 00325868

Cédula de identidad: 1724555972

Lugar y fecha: Quito, Ecuador, 9 de mayo del 2025

ACLARACIÓN PARA PUBLICACIÓN

Nota: El presente trabajo, en su totalidad o cualquiera de sus partes, no debe ser considerado como una publicación, incluso a pesar de estar disponible sin restricciones a través de un repositorio institucional. Esta declaración se alinea con las prácticas y recomendaciones presentadas por el Committee on Publication Ethics COPE descritas por Barbour et al. (2017) Discussion document on best practice for issues around theses publishing, disponible en <http://bit.ly/COPETheses>.

UNPUBLISHED DOCUMENT

Note: The following capstone project is available through Universidad San Francisco de Quito USFQ institutional repository. Nonetheless, this project – in whole or in part – should not be considered a publication. This statement follows the recommendations presented by the Committee on Publication Ethics COPE described by Barbour et al. (2017) Discussion document on best practice for issues around theses publishing available on <http://bit.ly/COPETheses>.

RESUMEN

La inteligencia artificial (IA) se muestra como una herramienta clave para optimizar el análisis de grandes volúmenes de datos ecológicos, especialmente en entornos de alta biodiversidad. Este estudio evaluó la eficacia del modelo AddaxAI para detectar ocelotes (*Leopardus pardalis*) en imágenes de cámaras trampa de la Estación de Biodiversidad Tiputini, Ecuador, comparando sus resultados con el conteo manual humano realizado por el investigador John Blake. Se analizaron registros tomados entre 2014 y 2024 mediante tres configuraciones distintas del modelo, evaluando aciertos, omisiones y errores de clasificación.

Se realizaron pruebas estadísticas como Chi-cuadrado y t de Student para comparar los niveles de confianza entre aciertos y errores. Los hallazgos mostraron que AddaxAI alcanzó un nivel de precisión superior al 67% en la identificación de imágenes de *L. pardalis*, aunque su rendimiento varió según el tipo de error y la configuración utilizada. Las omisiones y los errores por confusión con otras especies similares a *L. pardalis* fueron las principales limitaciones. Asimismo, se identificó un patrón de comportamiento nocturno consistente en la actividad del ocelote, lo que refuerza el valor de la IA no solo como herramienta de clasificación, sino también como fuente confiable para generar información ecológica.

Este estudio propone una metodología replicable para evaluar y estandarizar el uso de IA en monitoreo de fauna silvestre, destacando la importancia de combinar herramientas automatizadas con revisión humana. Se concluye que AddaxAI representa una alternativa prometedora para acelerar procesos de análisis en estudios de conservación, aunque se recomienda seguir afinando su uso y validar sus resultados, especialmente en ecosistemas complejos como la Amazonía. Los resultados de este estudio sientan una base sólida para futuras investigaciones que integren IA y la ecológica aplicada.

Palabras clave: biodiversidad, conservación, detección automática, inteligencia artificial, monitoreo de fauna, ocelote, Tiputini.

ABSTRACT

Artificial intelligence (AI) is becoming a key tool for optimizing the analysis of large ecological datasets, especially in highly biodiverse environments. This study assessed the effectiveness of the AddaxAI model in detecting ocelots (*Leopardus pardalis*) in camera trap images from the Tiputini Biodiversity Station in Ecuador, comparing AI results to human visual identification. Data collected between 2014 and 2024 were analyzed under three AI parameter configurations, categorizing detections as correct, omitted, or misclassified.

Statistical analyses, including Chi-square and t-tests, were used to compare confidence levels across correct and incorrect detections. Results showed that AddaxAI reached an overall accuracy above 67% although its performance varied depending on the type of error and parameter setting. The most frequent limitations were omission errors and species misidentification, especially in visually complex images. Additionally, a consistent nocturnal activity pattern for ocelots was observed, with a peak around 19:00, demonstrating AI's potential not only for species classification but also for ecological behavior inference.

This research proposes a replicable methodology for evaluating and standardizing the use of AI in wildlife monitoring, highlighting the value of combining automation with human validation. It concludes that AddaxAI is a promising tool to accelerate conservation research workflows, but its application in complex ecosystems such as the Amazon still requires caution and critical supervision. The study provides a practical framework for researchers aiming to integrate AI-based monitoring systems into conservation biology and wildlife management. By documenting both, the strengths and limitations of the model, this work lays the groundwork for future efforts to improve detection algorithms, expand analyses to other species, and develop protocols that effectively integrate automated systems with expert review.

Key words: automated detection, artificial intelligence, biodiversity, conservation, ocelot, Tiputini, wildlife monitoring

TABLA DE CONTENIDOS

RESUMEN	5
ABSTRACT	7
TABLA DE CONTENIDOS	9
LISTA DE FIGURAS	11
LISTA DE TABLAS	12
1. INTRODUCCIÓN	13
2. MÉTODOS	15
2.1 SITIO DE ESTUDIO.	15
2.2 RECOLECCIÓN DE DATOS.	15
2.3 EXTRACCIÓN DE DATOS.	16
2.4 CATEGORIZACIÓN DE NIVELES	18
2.5 ANÁLISIS DE DATOS.	19
3. RESULTADOS	20
3.1 ERRORES Y LIMITACIONES DE ADDAXAI	20
3.1.1 COMPARACIÓN ENTRE CONFIGURACIONES: FRECUENCIA DE ERRORES.	20
3.1.2 DIFERENCIAS ENTRE NIVELES DE CONFIANZA ENTRE ACIERTOS Y ERRORES.	21
3.2 COMPOSICIÓN Y EVOLUCIÓN DE LOS ERRORES DE DETECCIÓN	23
3.2.1 COMPOSICIÓN GENERAL DE ERRORES POR TIPO.	23
3.2.2 EVOLUCIÓN ANUAL DEL DESEMPEÑO DE ADDAXAI.	24
3.3 PATRONES DE ACTIVIDAD TEMPORAL DE OCELOTES	25
3.3.1 DISTRIBUCIÓN HORARIA DE DETECCIONES POR ADDAXAI.	25
3.1.4 COMPARACIÓN ENTRE ACTIVIDAD DIURNA Y NOCTURNA	26
4. DISCUSIÓN	27
4.1 PRECISIÓN Y EFICACIA DEL MODELO ADDAXAI	27
4.2 LIMITACIONES EN LA IDENTIFICACIÓN AUTOMÁTICA	28
3.3 PROPUESTA METODOLÓGICA PARA ESTUDIOS FUTUROS	29
3.4 APLICACIONES ECOLÓGICAS DE LA INTELIGENCIA ARTIFICIAL	30

5. CONCLUSIÓN **30****REFERENCIAS** **32****ANEXO A: EXCEL BASE DE DATOS** **36**

Tabla 1. Headline de la visualización de la tabla usada para la base de datos.

36

LISTA DE FIGURAS

Figura 1. Distribución porcentual de los tipos de detección (correcto, error de especie, error vacío y omisión) generados por AddaxAI bajo tres configuraciones distintas de parámetros. ____ **¡Error!**

Marcador no definido.

Figura 2. Distribución de densidad de los niveles de confianza asignados por el modelo. **¡Error!**

Marcador no definido.

Figura 3. Distribución general de las detecciones realizadas por la inteligencia artificial según el tipo de salida: correcta, omisión, error de especie y error vacío. **¡Error! Marcador no definido.**

Figura 4. Distribución anual de detecciones realizadas por AddaxAI entre los años 2014 y 2024, clasificadas por tipo de salida. _____ **¡Error! Marcador no definido.**

Figura 5. Distribución horaria de las detecciones de ocelotes por el modelo de inteligencia artificial a lo largo del día. _____ 26

Figura 6. Comparación entre el número total de eventos detectados durante el periodo diurno (06h–18h) y el periodo nocturno (18h–06h). _____ **¡Error! Marcador no definido.**

LISTA DE TABLAS

Tabla 1. Ejemplo de la visualización de la tabla usada para la base de datos. _____	18
Tabla 2. Test de Pearson Chi cuadrado. _____	21
Tabla 3. T-test de dos muestras de Welch: Comparación de los niveles de confianza entre detecciones de dos grupos. _____	23

1. INTRODUCCIÓN

La Estación de Biodiversidad Tiputini ubicada en la Amazonía ecuatoriana, protege varios de los ecosistemas más biodiversos del planeta. Su ubicación remota, a 100 km al Este de la ciudad de El Coca-Provincia de Orellana, y su mínima perturbación antrópica, la convierten en un sitio clave para el estudio de comunidades de animales, en especial de mamíferos en bosques tropicales (Blake & Loiselle, 2018). Estos ecosistemas albergan una gran proporción de especies aún poco conocidas (Montalvo-Salazar et al., 2024; Peñaherrera - R. & Cisneros - Heredia, 2023).

Entre las herramientas más utilizadas para monitorear mamíferos sin generar perturbación ni estrés en los animales están las cámaras trampa, que permiten registrar presencia, actividad y comportamiento sin interferencia directa. Su uso se ha incrementado notablemente en la última década debido al desarrollo continuo de la tecnología de las cámaras y a la capacidad de recolectar grandes volúmenes de datos visuales de forma continua y en hábitats difíciles de acceder (Akcali et al., 2019). Estas cámaras operan de forma pasiva y automática, lo que permite cubrir amplias áreas durante largos periodos sin requerir presencia humana constante (Blake & Mosquera, 2014), lo cual resulta especialmente valioso en regiones remotas como Tiputini.

No obstante, estas cámaras pueden generar miles de imágenes en un corto período de tiempo, lo que representa un desafío logístico y humano si se recurre al conteo e identificación manual, un proceso que puede retrasar el avance de las investigaciones. Ante esta situación, el uso de modelos de inteligencia artificial ha surgido como una solución prometedora, especialmente en los últimos años, al automatizar el reconocimiento de especies en bases de datos extensas con miles de

fotografías, permitiendo así liberar tiempo y recursos para la realización de análisis ecológicos más profundos. (Rigoudy et al., 2023); (Tabak et al., 2022).

Herramientas como AddaxAI 2023 Van Lunteren (antes conocido como EcoAssist 5.28), permiten procesar de forma eficiente imágenes de cámaras trampa, incluso en centros de investigación con recursos limitados. Estas soluciones de código abierto han demostrado su utilidad en diversos contextos, aunque aún existen incertidumbres sobre el rendimiento de los programas en ecosistemas complejos como la Amazonía (Velasco-Montero et al., 2024); (Van Lunteren, 2023).

La precisión de los modelos de inteligencia artificial sigue siendo un desafío, especialmente cuando especies morfológicamente similares comparten el hábitat, como ocurre con el ocelote (*Leopardus pardalis*) y otras especies similares como el Jaguar (*Panthera onca*). Una clasificación errónea podría afectar análisis espaciales, temporales o decisiones de conservación. Por lo tanto, evaluar la eficacia de estas herramientas es fundamental para asegurar decisiones ecológicas y políticas basadas en datos confiables (Díaz et al., 2024).

En base a este contexto, este estudio buscó como objetivo general: comparar la precisión y eficiencia del software de inteligencia artificial AddaxAI con el conteo manual humano en la detección de ocelotes (*Leopardus pardalis*) en imágenes de cámaras trampa recolectadas durante un periodo total de 8 años en la Estación de Biodiversidad Tiputini. Para ello, se utilizarán bases de datos preexistentes de cámaras trampa y se aplicó un enfoque comparativo entre el conteo manual y la identificación automática realizada por el software. Como objetivos específicos esta investigación buscó: 1. Evaluar los errores y limitaciones de AddaxAI identificando en qué condiciones AddaxAI presenta fallas al identificar animales en imágenes; 2. Estandarizar métodos de recolección y detección en imágenes de monitoreo con ayuda de AddaxAI y las cámaras trampa;

3. Identificar patrones de ecología relevantes para la especie focal, que incluyen patrones de actividad temporal a lo largo de los años, y; 4. Generar información ecológica, a partir de imágenes de trampas cámara durante varios años utilizando AddaxAI, que describa generalidades sobre los patrones de comportamiento de ocelotes.

2. Métodos

2.1 Sitio de estudio.

La investigación se llevó a cabo en la Estación de Biodiversidad Tiputini, ubicada en la provincia de Orellana, Ecuador ($\sim 0^{\circ} 38' S$, $76^{\circ} 09' W$, altitud de 190-270 m). Esta estación, fundada en 1994 por la Universidad San Francisco de Quito (USFQ), se encuentra dentro de la Reserva de la Biósfera Yasuní, una de las áreas más biodiversas del mundo (Blake et al., 2014). La estación cubre aproximadamente 744 ha de bosque primario en la cuenca baja del río Tiputini, que es un ecosistema de alta diversidad biológica, donde se han registrado especies representativas de la región como el ocelote (*Leopardus pardalis*) (Blake et al., 2011). La estación se encuentra rodeada por diversos ecosistemas, como bosques de tierra firme y varzea, pantanos de palma y otros humedales, además de áreas en proceso de sucesión natural. El río Tiputini delimita el sur de la estación, pero no existen barreras para el movimiento de los ocelotes hacia otras direcciones. El clima de la zona es cálido y húmedo durante todo el año, con temperaturas promedio de 24-27°C y una precipitación anual de aproximadamente 3,200 mm, lo que favorece la abundancia de especies de flora y fauna en la región (Bass et al., 2010).

2.2 Recolección de datos.

Para la obtención de los datos, se utilizaron cámaras trampa que han sido colocadas en la Estación de Biodiversidad Tiputini-EBT, del 2014 al 2024. La base de datos utilizada fue generada por el investigador John Blake, quien ha liderado el monitoreo con cámaras trampa en la Estación de Biodiversidad Tiputini durante estos años. Como parte de este trabajo que continua al momento, se han generado varias investigaciones que detallan los métodos usados para obtener las fotos y resultados mencionados (Blake, 2025; Blake et al., 2011, 2014; Blake & Loiselle, 2018). John Blake y otros (Blake et al., 2011, 2014) seleccionaron y establecieron 10 puntos estratégicos a lo largo de diferentes senderos que fueron previamente analizados en función de la actividad de las especies en la zona de la EBT (Bass et al., 2010). Es importante mencionar que las cámaras instaladas desde el 2014 al 2024 solo se colocan en los meses de diciembre a abril de cada año, fecha en la que el investigador John Blake visita la EBT. En cada uno de los puntos seleccionados ese proyecto, se instalaron dos cámaras, ubicadas de manera que cubrieran ambos lados del sendero. Las cámaras, activadas por sensores de movimiento e infrarrojos, fueron colocadas a una altura de aproximadamente 0.5-0.75 metros del suelo (Blake et al., 2011).

Las cámaras se han mantenido operativas desde el inicio de la mencionada investigación, en diciembre de 2013 y han continuado funcionando hasta febrero 2024. En el año 2021 no se colectaron imágenes de cámaras trampa debido a la pandemia de COVID (Kar et al., 2020). Para asegurar una cobertura adecuada y obtener imágenes de ambos flancos de los individuos, las cámaras fueron instaladas a distancias de entre 1 y 1.2 km en senderos preexistentes de bosque primario dentro de la EBT (Blake & Mosquera, 2014). Se ajustó un intervalo mínimo entre fotos de 3 a 5 minutos para asegurar la captura de imágenes consecutivas de los animales. Las cámaras fueron revisadas mensualmente para cambiar tarjetas SD, baterías y comprobar el funcionamiento de los equipos. Cada imagen capturada fue etiquetada automáticamente en una base de datos Excel

con la fecha, hora, ubicación y número de cámara correspondiente, lo que facilitó el manejo y la organización de los datos (Burton et al., 2015).

2.3 Extracción de datos.

John Blake construyó su base de datos identificando manualmente las especies presentes en las imágenes captadas por cámaras trampa durante el período 2014–2024. Para evitar contar múltiples veces al mismo individuo que pasaba repetidamente por una misma cámara, estableció un criterio temporal: solo se registraba una detección cada 30 minutos, a menos que apareciera una especie diferente en ese intervalo. Cada registro incluía el nombre del género y la especie resumido en una palabra clave (por ejemplo, *Leopardus pardalis* como “Leopar”) para facilitar el conteo. También anotaba en la base de datos general de su proyecto, la hora de detección, la cámara específica (A o B, según el lado del sendero), el sexo del animal cuando era posible y cualquier característica distintiva, como cicatrices.

Para cumplir con el objetivo 1 de esta tesis, que busca evaluar los errores y limitaciones de AddaxAI, comparando sus identificaciones con las realizadas por el proyecto de John Blake et al, se utilizó la versión 5.28 de este software, especializado en la detección automática de especies en imágenes de cámaras trampa (Van Lunteren, 2023). Se configuraron tres ajustes diferentes para analizar su desempeño. En el primer ajuste, se emplearon los valores predeterminados del software con valores de 0.4 en umbral de confianza de detección y 0.6 en el umbral de fiabilidad. En el segundo, se estableció un umbral de confianza de detección en 0.1 y un umbral de fiabilidad en 0.8, con el fin de aplicar una configuración más estricta que reduzca la cantidad de falsos positivos. Esta configuración permite que el modelo detecte objetos con mayor sensibilidad (detectando incluso señales débiles como animales pequeños y movimientos sutiles), pero solo considera válidas aquellas detecciones cuya clasificación sea altamente confiable en cuanto a la especie focal,

asegurando así mayor precisión en la identificación final de las especies. El tercer ajuste fijó ambos valores en 0.5, buscando un equilibrio entre sensibilidad y especificidad (Dussert et al., 2024). El primer valor es el umbral de confianza que muestra la detección entre Humano, Animal, Vehículo o Nada (vacío), mientras que el segundo valor es el que clasifica, una vez pasado el primer valor, todos los animales que se hayan configurado para identificar. Las detecciones generadas bajo cada configuración fueron comparadas con el conteo manual previamente realizado por el investigador John Blake, utilizando las mismas bases de datos de cámaras trampa en la Estación de Biodiversidad Tiputini (

Tabla 1).

Tabla 1. Ejemplo de la visualización de la tabla usada para la base de datos.

Photo ID	Setting	Año	Mes	Día	Detección	Nivel de confianza detección	Tipo de Objeto	Ubicación cámara	Hora del día
M3600/11 (60) JPG	1	2014	1	19	1	0.6132	Ocelote	M3600	1:10:46
P150B/15 (12) JPG	1	2014	1	10	1	1	Ocelote	P150	1:37:49

2.4 Categorización de niveles

Se clasificaron las categorías del software de inteligencia artificial en cuatro categorías codificadas con caracteres numéricos: 0 = omisión (el humano detectó un ocelote en una imagen, pero AddaxAI no lo detectó), 1 = correcto (Humano y AddaxAI detectan correctamente un ocelote en una imagen), 2 = falso positivo 1, error de especie (AddaxAI identificó incorrectamente la especie, por otra morfológicamente parecida), y 3 = falso positivo 2, error vacío (AddaxAI detecta incorrectamente la presencia del ocelote en una imagen vacía). Estas categorías permitieron cuantificar la precisión y los fallos del sistema AI bajo distintos parámetros, aportando evidencia

para determinar qué configuración resulta más efectiva y robusta para identificar la especie focal de este estudio y en el contexto amazónico (Smith et al., 2024).

2.5 Análisis de datos.

Para realizar el análisis comparativo de los datos obtenidos de la inteligencia artificial AddaxAI versión 5.28, con aquellos obtenidos por el ser humano (derivados de la investigación de John Blake et al.), se utilizó el software estadístico R, el cual ofrece herramientas robustas para la manipulación, exploración y visualización de datos (Core Team, 2021). En específico, se emplearon los paquetes *dplyr*, *lubridate*, *readxl*, *tidyr* y *ggplot2*, cada uno con una función específica dentro del flujo de trabajo. *dplyr* y *tidyr* fueron utilizados para la limpieza, transformación y estructuración de los datos, asegurando su correcta organización antes del análisis (Wickham et al., 2014). El paquete *lubridate* facilitó el manejo de datos temporales, permitiendo la estandarización de fechas y tiempos de captura (Spinu et al., 2010). *readxl* se usó para la importación de datos desde archivos de Excel, optimizando la integración con bases de datos externas (Wickham & Bryan, 2015). Finalmente, *ggplot2* fue empleado para la generación de gráficos informativos y visualizaciones de patrones, lo que permitió interpretar con mayor claridad los resultados obtenidos (Wickham, 2016). Gracias a estas herramientas, se logró un análisis detallado y una representación visual efectiva de los datos recopilados.

Para cumplir con el objetivo 1, que busca evaluar los errores y limitaciones de AddaxAI, se realizaron diversas pruebas estadísticas y análisis gráficos para comparar el desempeño de la inteligencia artificial frente a la identificación manual de ocelotes. Primeramente, se aplicó una prueba de Chi-cuadrado para determinar si existían diferencias significativas en la proporción de

errores entre los distintos ajustes del software comparando un ajuste con otro. Además, se ejecutó una prueba t de Student para comparar los niveles de confianza en las detecciones correctas frente a los errores. Para visualizar la distribución de estos valores, se generaron gráficos de densidad y se analizaron los patrones de asignación de confianza por parte de AddaxAI, observándose una tendencia a asignar valores extremos (muy altos o bajos) en sus predicciones.

El segundo objetivo de esta investigación fue estandarizar los métodos de recolección y detección de fauna en imágenes provenientes de cámaras trampa, integrando herramientas de inteligencia artificial. Para ello, se definieron protocolos consistentes para el procesamiento de imágenes, así como parámetros específicos en la configuración de AddaxAI, lo que permitió mejorar la eficiencia en la clasificación de especies y facilitar la comparación entre distintos periodos y sitios de muestreo.

Por otro lado, y en línea con el objetivo 3, se propuso una metodología de estandarización para calibrar los niveles de confianza del modelo, con el fin de reducir la sobre confianza en detecciones erróneas y aumentar la precisión en la identificación de especies en contextos ecológicos complejos.

Finalmente, el objetivo 4 de esta investigación fue, utilizando los resultados de la identificación de ocelotes en fotografías multianuales, corroborar patrones ecológicos y de nicho temporal de estos felinos.

3. Resultados

3.1 Errores y Limitaciones de AddaxAI

3.1.1 Comparación entre configuraciones: frecuencia de errores.

Como resultado del **objetivo 1** y después de aplicar la metodología descrita en el punto 2, se evaluaron los resultados del modelo de inteligencia artificial clasificados en cuatro tipos de detección. El análisis se hace por tipo de error, comparando las categorías: detección correcta, omisión, error de especie y error vacío.

Al comparar las medias de detección por cada tipo entre los tres ajustes (Setting) evaluados, se encontró que no existen diferencias significativas en las proporciones de errores entre configuraciones ($\chi^2 = 0.775$, $df = 2$, $p = 0.6787$), lo cual indica que los distintos parámetros del modelo no influyen de forma significativa en su precisión general (**¡Error! No se encuentra el origen de la referencia.**)

Tabla 2. Test de Pearson Chi cuadrado. Comparación de la frecuencia de detecciones por tipo (correctas y erróneas) entre diferentes configuraciones del modelo de inteligencia artificial. Se utiliza una prueba de Chi cuadrado para evaluar diferencias en la distribución.

χ^2	0.77525
df	2
p-value	0.6787

3.1.2 Diferencias entre niveles de confianza entre aciertos y errores.

La tendencia se confirma en la **Figura 1**, donde se observa que los tres ajustes del modelo presentan proporciones similares entre detecciones correctas y los distintos tipos de error, lo que refuerza el hallazgo de que no hay diferencias estadísticas significativas entre configuraciones. Asimismo, al comparar los niveles de confianza asignados por la AddaxAI, se obtuvo una diferencia estadísticamente significativa entre detecciones correctas y erróneas ($t = 2.87$, $df \approx 128.3$, $p = 0.0048$), siendo más alta la confianza en las predicciones acertadas (**Tabla 3**). Esta diferencia también se evidencia visualmente en la Figura 2, donde se representa la distribución de densidad

de los niveles de confianza por tipo de detección. Se observa que las predicciones correctas tienden a concentrarse en valores cercanos a 1.0, mientras que los errores presentan una distribución más dispersa y menor densidad en valores altos.

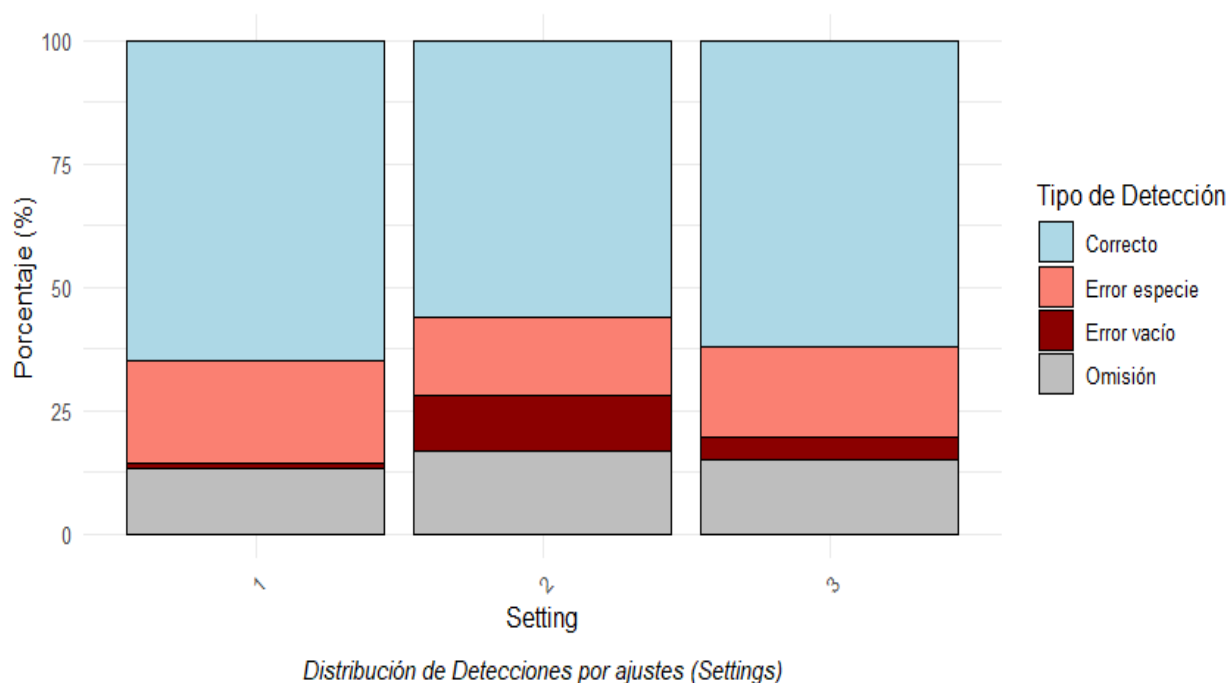


Figura 1. Distribución porcentual de los tipos de detección (correcto, error de especie, error vacío y omisión) generados por AddaxAI bajo tres configuraciones distintas de parámetros (Setting 1 con 0.4 de umbral de confianza de detección y 0.6 de umbral de clasificación; Setting 2 con 0.1 de umbral de confianza de detección y 0.8 de umbral de clasificación; Setting 3 con 0.5 de umbral de confianza de detección y 0.5 de umbral de clasificación). El gráfico permite visualizar comparativamente la composición de resultados en cada Setting.

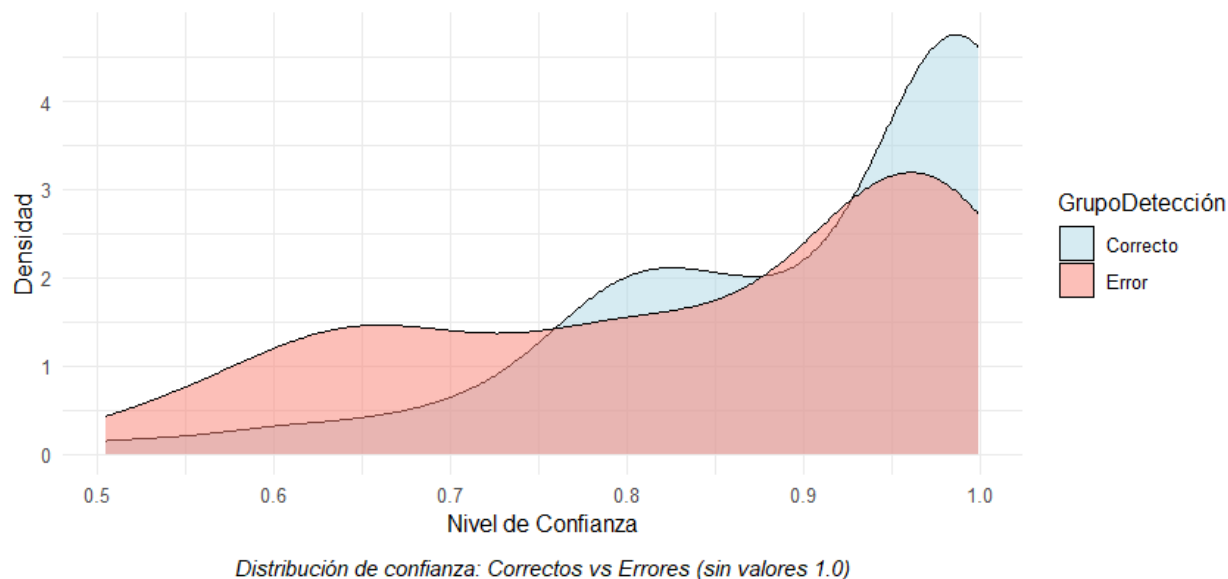


Figura 2. Distribución de densidad de los niveles de confianza asignados por AddaxAI, diferenciando entre detecciones correctas (azul) y errores (rojo). Se excluyeron los valores iguales a 1.0 para mejorar la visualización de la variabilidad. Se observa que el modelo asigna mayores niveles de confianza a las detecciones correctas.

Tabla 3. T-test de dos muestras de Welch: Comparación de los niveles de confianza entre detecciones de dos grupos: correctas y errores (omisión; falso positivo 1, error especie; falso positivo 2, error vacío) mediante una prueba t de Student. Se muestran las medias y el intervalo de confianza asociado.

Nivel de confianza detección	$t = 2.8725$, $df = 128.32$, $p\text{-value} = 0.004767$
Media en grupo Correcto	0.901212
Media en grupo Error	0.835754

3.2 Composición y Evolución de los errores de detección

3.2.1 Composición general de errores por tipo.

Al analizar la composición de los errores generados por AddaxAI, se observa que las salidas incorrectas se distribuyen principalmente en tres categorías: errores de especie, omisiones y errores en imágenes vacías. La **Figura 3** muestra que los errores de especie (falsos positivos tipo

1) fueron los más frecuentes, seguidos por las omisiones (detecciones hechas por humanos pero ignoradas por la AddaxAI) y en menor medida por los errores tipo 2 (detecciones en imágenes vacías). Esta distribución sugiere que, aunque el modelo es capaz de identificar correctamente un alto número de eventos, aún enfrenta desafíos importantes al diferenciar especies morfológicamente similares o interpretar correctamente el contenido de imágenes con baja calidad o interferencias visuales.




Figura 3. Distribución general de las detecciones realizadas por la inteligencia artificial según el tipo de salida: correcta, omisión, error de especie y error vacío. Se registraron alrededor de 65 errores de especie, 25 errores en imágenes vacías y aproximadamente 55 omisiones (casos en los que el humano detectó pero AddaxAI no).

3.2.2 Evolución anual del desempeño de AddaxAI.

La evolución del desempeño del modelo entre los años 2014 y 2024 revela una tendencia de mejora progresiva en la precisión de las detecciones. Como se aprecia en la **Figura 4**, durante los primeros años del monitoreo (2014–2016), las omisiones fueron más comunes que los aciertos, mientras que a partir de 2017 las detecciones correctas superan de forma constante a los errores.

Este cambio puede deberse a mejoras tanto en la calidad de las imágenes captadas como en la capacidad del modelo para adaptarse a las condiciones del entorno amazónico. En particular, se observa un pico de aciertos en el año 2023, lo que refuerza la idea de que el desempeño de AddaxAI no es estático, sino que puede mejorar conforme se ajustan los parámetros y se optimizan las condiciones de monitoreo.

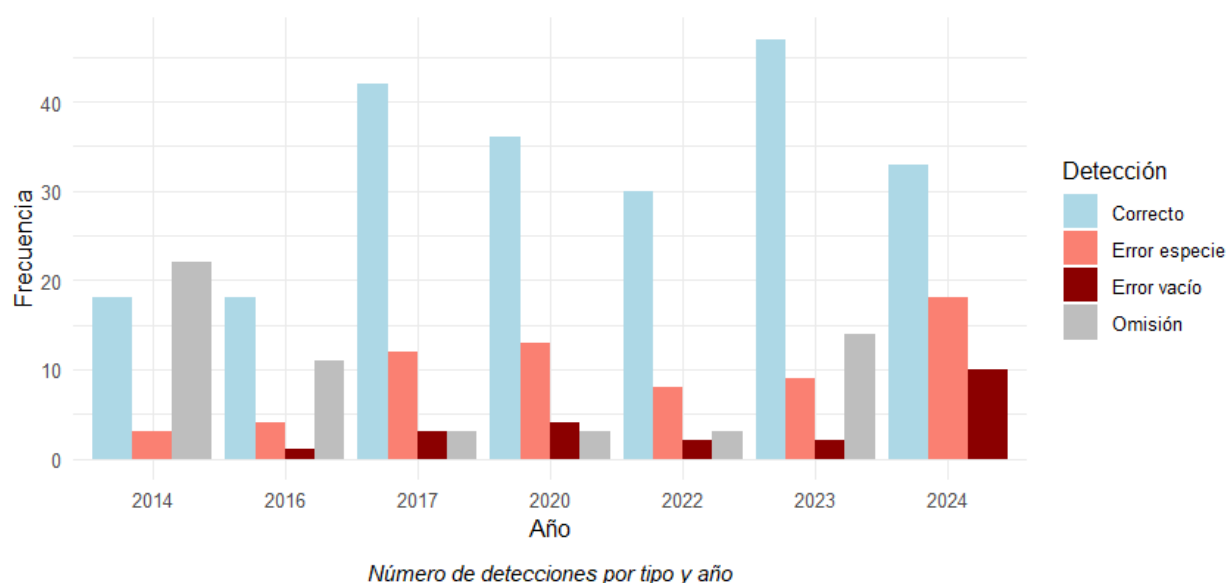


Figura 4. Distribución anual de detecciones realizadas por la inteligencia artificial entre los años 2014 y 2024, clasificadas por tipo de salida. Permite observar la evolución del desempeño a lo largo del tiempo.

3.3 Patrones de actividad temporal de ocelotes

3.3.1 Distribución horaria de detecciones por AddaxAI.

Como resultado del **objetivo 3** y luego de aplicar la metodología para extraer las horas de detección desde las imágenes procesadas por AddaxAI, se encontró un patrón de actividad fuertemente nocturno en *Leopardus pardalis*. En la **Figura 5** se observa un claro pico de actividad a las 19:00, con aproximadamente 40 eventos. Entre las 20:00 y la 01:00 se registraron entre 20 y

30 detecciones por hora, mientras que entre la 01:00 y las 06:00 esta frecuencia disminuyó progresivamente por debajo de 20 detecciones por hora. En contraste, durante el periodo diurno (de 07:00 a 17:00), las detecciones fueron mínimas, sin superar las 3 por hora. El análisis se centró en la distribución horaria de eventos agrupados por franja, utilizando histogramas y conteo por hora.




Figura 5. Distribución horaria de las detecciones de ocelotes por el modelo a lo largo del día. Se muestran los picos bimodales de actividad en función de la hora de captura dentro de 24h.

3.1.4 Comparación entre actividad diurna y nocturna

Esta tendencia se confirmó al agrupar los eventos en dos bloques horarios: diurno (06h–18h) y nocturno (18h–06h), donde se detectaron aproximadamente 250 eventos en horario nocturno frente a apenas 25 durante el día (**Figura 6**). Este patrón coincide con lo reportado en la literatura sobre hábitos crepusculares y nocturnos del ocelote en ambientes de bosque tropical. Además, la confiabilidad del modelo se mantuvo estable en las horas de mayor actividad, lo que

refuerza su utilidad para el análisis ecológico de comportamiento temporal en especies de hábitos nocturnos.

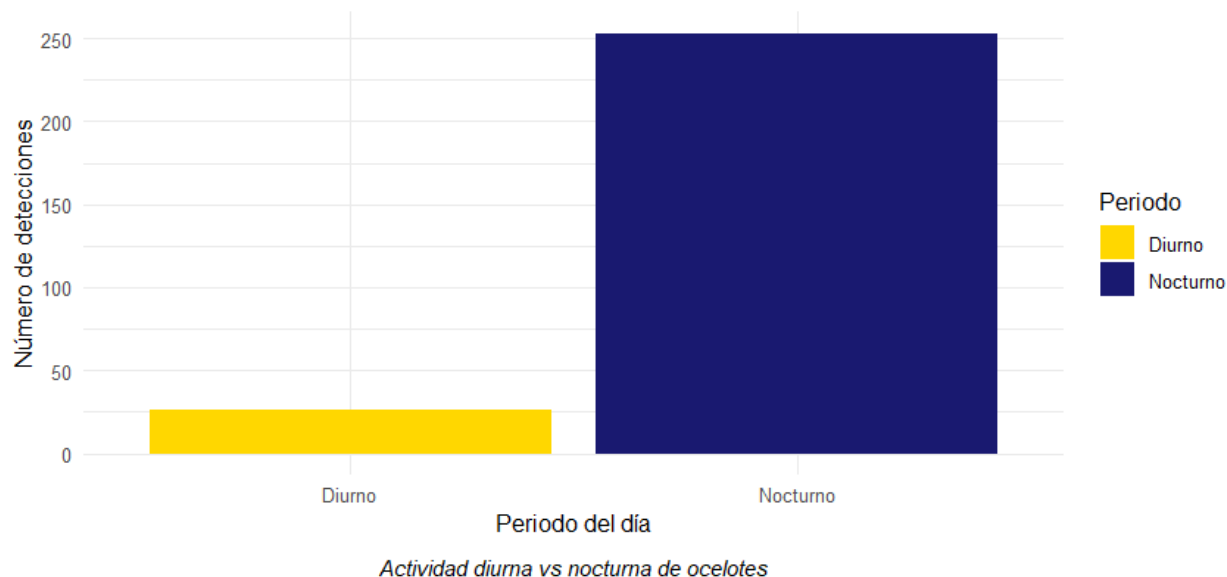


Figura 6. Comparación entre el número total de eventos detectados durante el periodo diurno (06h–18h) y el periodo nocturno (18h–06h).

4. DISCUSIÓN

4.1 Precisión y Eficacia del Modelo AddaxAI

Los resultados obtenidos revelan que AddaxAI alcanza un nivel alto de precisión en la identificación de ocelotes, con más del 67% de aciertos en general. Esta proporción resulta bastante alentadora considerando el desafío que representa identificar correctamente especies en ambientes tan complejos como la Amazonía. No obstante, es importante notar que la precisión no fue afectada significativamente por los cambios en los diferentes ajustes (Settings) del modelo ($p > 0.05$), lo que sugiere que, dentro del rango evaluado, la elección de diferentes umbrales no afecta el

desempeño general del modelo, lo que se evidencia en la prueba de Chi-cuadrado ($\chi^2 = 0.775$, $df = 2$, $p = 0.6787$; Figura 1).

Un hallazgo relevante es que, aunque las detecciones correctas presentan niveles de confianza significativamente mayores que las erróneas ($t = 2.87$, $df \approx 128.3$, $p = 0.0048$; Figura 3), las medias de confianza para los errores siguen siendo relativamente altas, lo cual representa una limitación en el modelo utilizado. En la Figura 4 se observa que, si bien las detecciones correctas tienden a agruparse en valores altos cercanos a 1.0, los errores no se concentran en niveles de confianza bajos, como sería esperable para facilitar su descarte automático. Esta superposición reduce la utilidad del nivel de confianza como un criterio sólido de validación automática, ya que genera incertidumbre para el investigador al no permitir una distinción clara entre aciertos y errores. Por tanto, aunque el nivel de confianza de dicho modelo puede ofrecer un resultado general del nivel de aciertos en las identificaciones automáticas, no resulta totalmente confiable como filtro exclusivo para separar salidas válidas de incorrectas.

4.2 Limitaciones en la Identificación Automática

Pese a los buenos resultados generales, se identificaron limitaciones que deben considerarse al utilizar AddaxAI en ambientes tropicales. Una de las principales es la ocurrencia de errores de especie, es decir cuando la inteligencia artificial confundió al ocelote con otras especies de morfología similar, como margay o jaguares. Esta clase de error representa un falso positivo relevante para estudios que requieren precisión taxonómica, como aquellos que evalúan ocupación o patrones de actividad específicos.

De igual manera, se registraron omisiones (casos donde el humano detectó un ocelote pero AddaxAI no lo hizo) y falsos positivos 2, errores de identificación en imágenes vacías. Estos dos

tipos de fallo sugieren que el modelo puede verse afectado por la calidad de las imágenes, iluminación deficiente o la presencia de elementos distractores como vegetación en movimiento. Aunque estos errores disminuyeron con los años, su presencia en las primeras fases del monitoreo indica que el contexto ecológico y técnico influye directamente en el desempeño del modelo.

Por tanto, resulta fundamental no confiar definitivamente en los resultados generados por el modelo. Las herramientas automatizadas deben emplearse con criterio, reconociendo sus limitaciones e incorporando procesos de validación cruzada o revisión humana en etapas clave del análisis, con el fin de garantizar la calidad y confiabilidad de los resultados.

3.3 Propuesta Metodológica Para Estudios Futuros

Uno de los aportes clave de esta investigación es la propuesta de una metodología estandarizada para la detección automatizada de fauna en imágenes de cámaras trampa, especialmente útil para contextos de alta biodiversidad como la Amazonía norte del Ecuador. A partir del análisis de los tres ajustes utilizados, se identificó que una configuración equilibrada (como la del Setting 3, con umbrales de 0.5 en detección y clasificación) proporciona resultados estables sin incrementar significativamente los errores (**Figura 2**).

Además, la categorización de los resultados en cuatro tipos de detección (correcto, omisión, error de especie y error en vacío) permite una interpretación más estructurada y facilita la comparación entre proyectos o periodos. Este sistema puede ser adaptado fácilmente a otras especies o regiones, permitiendo una mayor reproducibilidad entre investigaciones. El uso del nivel de confianza como variable de control, tal como se exploró en las Figura 3 y Figura 4, también permite optimizar el esfuerzo de validación manual, enfocándolo en los casos más propensos a errores.

Esta metodología puede servir como guía para investigaciones futuras que deseen implementar modelos de inteligencia artificial en monitoreo de fauna silvestre a largo plazo, reduciendo tiempos de procesamiento y mejorando la eficiencia en la toma de decisiones en conservación.

3.4 Aplicaciones Ecológicas de la Inteligencia Artificial

Más allá de la precisión técnica, los datos procesados por AddaxAI permiten obtener información ecológica valiosa. En particular, el análisis de los horarios de detección mostró un patrón de actividad nocturna en ocelotes, con un pico alrededor de las 19:00 y una alta frecuencia entre las 20:00 y la 01:00 (Figura 5). Justamente, al agrupar también los datos en bloques diurnos y nocturnos, se observó que más del 90% de las detecciones ocurrieron en horario nocturno (Figura 6). Durante el día, en cambio, las detecciones fueron escasas, lo que confirma el carácter nocturno y crepuscular de esta especie que se ve evidenciado en otros estudios (Nivelo-Villavicencio et al., 2019).

Estos hallazgos demuestran que, cuando se aplican protocolos rigurosos de procesamiento y validación, los datos generados por inteligencia artificial y revisados por el humano, no solo son útiles para automatizar procesos, sino también para responder preguntas relevantes en ecología y conservación.

5. CONCLUSIÓN

Los resultados de esta investigación demuestran que el modelo de inteligencia artificial AddaxAI posee un alto nivel de precisión en la detección de ocelotes en imágenes de cámaras trampa, alcanzando más del 67% de aciertos en general. Si bien no se observaron diferencias significativas entre las configuraciones evaluadas, se evidenció que el modelo asigna niveles de confianza más altos a las detecciones correctas, lo cual podría utilizarse como un criterio auxiliar

para filtrar salidas dudosas. No obstante, los errores de especie y las omisiones siguen representando limitaciones importantes, especialmente en contextos de alta biodiversidad como la Amazonía, donde la morfología entre especies puede ser similar y las condiciones de iluminación y abundancia de vegetación generan desafíos adicionales para que la inteligencia artificial identifique organismos en fotografías digitales.

Este trabajo sienta las bases para el desarrollo de metodologías automatizadas más precisas y eficientes en el monitoreo de fauna silvestre mediante inteligencia artificial. Al documentar tanto los aciertos como las limitaciones del modelo en un entorno complejo como el bosque amazónico, se ofrece una guía práctica y replicable para otros investigadores que deseen implementar estas herramientas en estudios similares. A futuro, esta investigación puede servir como punto de partida para el ajuste fino de modelos de inteligencia artificial, la expansión del análisis a otras especies, y el diseño de protocolos que integren la automatización con validación humana, fortaleciendo cada vez más la capacidad de respuesta científica frente a los retos de la conservación de la biodiversidad.

Referencias

- Akali, C. K., Pérez-Mendoza, H. A., Salazar-Valenzuela, D., Kikuchi, D. W., Guayasamin, J. M., & Pfennig, D. W. (2019). Evaluating the utility of camera traps in field studies of predation. *PeerJ*. <https://doi.org/10.7717/peerj.6487>
- Bass, M. S., Finer, M., Jenkins, C. N., Kreft, H., Cisneros-Heredia, D. F., McCracken, S. F., Pitman, N. C. A., English, P. H., Swing, K., Villa, G., Di Fiore, A., Voigt, C. C., & Kunz, T. H. (2010). Global Conservation Significance of Ecuador's Yasuní National Park. *PLoS ONE*, 5(1), e8767. <https://doi.org/10.1371/journal.pone.0008767>
- Blake, J. G. (2025). Two decades of jaguar and puma (Carnivora: Felidae) activity in lowland forest of eastern Ecuador. *Revista de Biología Tropical*, 73.
- Blake, J. G., & Loiselle, B. A. (2018). Annual and spatial variation in composition and activity of terrestrial mammals on two replicate plots in lowland forest of eastern Ecuador. *PeerJ*, 6, e4241. <https://doi.org/10.7717/peerj.4241>
- Blake, J. G., & Mosquera, D. (2014). Camera trapping on and off trails in lowland forest of eastern Ecuador: Does location matter? *Mastozoología neotropical*, 21(1), 17–26.
- Blake, J. G., Mosquera, D., Guerra, J., Loiselle, B. A., Romo, D., & Swing, K. (2011). Mineral Licks as Diversity Hotspots in Lowland Forest of Eastern Ecuador. *Diversity*, 3(2), 217–234. <https://doi.org/10.3390/d3020217>
- Blake, J. G., Mosquera, D., Guerra, J., Loiselle, B. A., Romo, D., & Swing, K. (2014). Yasuní – a hotspot for jaguars *Panthera onca* (Carnivora: Felidae)? Camera-traps and jaguar activity at Tiputini Biodiversity Station, Ecuador. *Rev. Biol. Trop.*, 62.
- Burton, A. C., Neilson, E., Moreira, D., Ladle, A., Steenweg, R., Fisher, J. T., Bayne, E., & Boutin, S. (2015). REVIEW: Wildlife camera trapping: a review and recommendations for linking

- surveys to ecological processes. *Journal of Applied Ecology*, 52(3), 675–685.
<https://doi.org/10.1111/1365-2664.12432>
- Díaz, L. H. L., Galindo, D. A. G., & Páez, A. M. R. (2024). CÁMARAS TRAMPA, UNA VENTANA A LA VIDA SILVESTRE EN RESERVAS NATURALES. REVISIÓN DE LITERATURA Y TENDENCIAS. *Saperes universitas*, VII(1), 6–29.
- Dussert, G., Chamailé - Jammes, S., Dray, S., & Miele, V. (2024). Being confident in confidence scores: Calibration in deep learning models for camera trap image sequences. *Remote Sensing in Ecology and Conservation*, rse2.412. <https://doi.org/10.1002/rse2.412>
- Kar, S. K., Menon, V., Arafat, S. M. Y., & Kabir, R. (2020). Research in Mental Health During the COVID-19 Pandemic. *Sultan Qaboos University Medical Journal*, 20(4), e406-407.
<https://doi.org/10.18295/squmj.2020.20.04.024>
- Montalvo-Salazar, J. L., Bejarano, M. L., Valarezo, A., & Cisneros-Heredia, D. F. (2024). A new species of velvet worm of the genus *Oroperipatus* (Onychophora, Peripatidae) from western Amazonia. *Zoosystematics and Evolution*, 100(3), 779–789.
<https://doi.org/10.3897/zse.100.117952>
- Nivelo-Villavicencio, C. H., Fernández De Córdova Torres, C. J., Jiménez, A., & Astudillo Webster, P. X. (2019). Aportes sobre la dieta y distribución del Ocelote *Leopardus pardalis* (Linné 1758) en los altos Andes de Ecuador. *Revista Peruana de Biología*, 26(3), 399–402.
<https://doi.org/10.15381/rpb.v26i3.15715>
- Peñaherrera - R., P., & Cisneros - Heredia, D. F. (2023). A new species of spider of the genus *Sadala* Simon, 1880 (Araneae, Sparassidae) from the Yasuni Biosphere Reserve, Amazonian lowlands of Ecuador. *Ecology and Evolution*, 13(7), ece3.10242.
<https://doi.org/10.1002/ece3.10242>

- Rigoudy, N., Dussert, G., Benyoub, A., Besnard, A., Birck, C., Boyer, J., Bollet, Y., Bunz, Y., Caussimont, G., Chetouane, E., Carriburu, J. C., Cornette, P., Delestrade, A., De Backer, N., Dispan, L., Le Barh, M., Duhayer, J., Elder, J.-F., Fanjul, J.-B., ... Chamaillé-Jammes, S. (2023). The DeepFaune initiative: A collaborative effort towards the automatic identification of European fauna in camera trap images. *European Journal of Wildlife Research*, 69(6), 113. <https://doi.org/10.1007/s10344-023-01742-7>
- Smith, J., Wycherley, A., Mulvaney, J., Lennane, N., Reynolds, E., Monks, C.-A., Evans, T., Mooney, T., & Fancourt, B. (2024). Man versus machine: Cost and carbon emission savings of 4G-connected Artificial Intelligence technology for classifying species in camera trap images. *Scientific Reports*, 14(1), 14530. <https://doi.org/10.1038/s41598-024-65179-x>
- Spinu, V., Grolemond, G., & Wickham, H. (2010). *lubridate: Make Dealing with Dates a Little Easier* (p. 1.9.4) [Dataset]. <https://doi.org/10.32614/CRAN.package.lubridate>
- Tabak, M. A., Falbel, D., Hamzeh, T., Brook, R. K., Goolsby, J. A., Zoromski, L. D., Boughton, R. K., Snow, N. P., VerCauteren, K. C., & Miller, R. S. (2022). *CameraTrapDetector: Automatically detect, classify, and count animals in camera trap images using artificial intelligence*. *Ecology*. <https://doi.org/10.1101/2022.02.07.479461>
- Van Lunteren, P. (2023). AddaxAI: A no-code platform to train and deploy custom YOLOv5 object detection models. *Journal of Open Source Software*, 8(88), 5581. <https://doi.org/10.21105/joss.05581>
- Velasco-Montero, D., Fernández-Berni, J., Carmona-Galán, R., Sanglas, A., & Palomares, F. (2024). Reliable and efficient integration of AI into camera traps for smart wildlife

- monitoring based on continual learning. *Ecological Informatics*, 83, 102815.
<https://doi.org/10.1016/j.ecoinf.2024.102815>
- Wickham, H. (2016). *Ggplot2*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-24277-4>
- Wickham, H., & Bryan, J. (2015). *readxl: Read Excel Files* (p. 1.4.5) [Dataset].
<https://doi.org/10.32614/CRAN.package.readxl>
- Wickham, H., Vaughan, D., & Girlich, M. (2014). *tidyr: Tidy Messy Data* (p. 1.3.1) [Dataset].
<https://doi.org/10.32614/CRAN.package.tidyr>

ANEXO A: EXCEL BASE DE DATOS

Tabla 1. Headline de la visualización de la tabla usada para la base de datos.