

Region-based convolutional neural networks for automatic detection of a Neotropical bat species

Andrés Muñoz¹; Francisco Sánchez³; Angel Cruz-Roa²

^{1,2,3} *Universidad de los Llanos, Colombia*, {andres.munoz, fsanchezbarrera, aacruz}@unillanos.edu.co

Abstract—Bats use ultrasonic echolocation signals to orient themselves and feed, and analyzing these signals can be used for non-invasive, acoustic monitoring. Traditionally, this process is carried out manually by experts, which is a slow process due to the large volume of data and the temporal resolution of the signals. Currently, acoustic monitoring is an essential tool in ecology, especially for the study of bats, due to its non-invasive nature and its broad spatial and temporal coverage. For this reason, artificial intelligence techniques, including deep learning, have been incorporated into this work. This paper presents the use of region-based convolutional neural networks using a Faster R-CNN model for the automatic detection of pulse sequences from bat species in ultrasound recordings from spectrograms. A preliminary model showed high completeness values (>89%) and solid performance at mAP@50 (>89%), demonstrating adequate spatial localization capacity for the sequences, even in high biodiversity environments. However, lower accuracy and confusion values were observed between acoustically similar species, probably due to simultaneous vocalizations and the limited diversity of the training set. The feasibility of this approach for automated acoustic monitoring is evident, and future work should focus on expanding the dataset and improving interspecies discrimination.

Keywords—Bioacoustics, Deep learning, Echolocation, Neotropical bats, Convolutional neural networks.

Redes neuronales convolucionales basadas en regiones para la detección automática de secuencias de pulsos de murciélagos neotropicales

Andrés Muñoz¹; Francisco Sánchez³; Angel Cruz-Roa²

^{1,2,3} Universidad de los Llanos, Colombia, {andres.munoz, fsanchezbarrera, aacruz}@unillanos.edu.co

Resumen— Los murciélagos utilizan señales ultrasónicas de ecolocalización para orientarse y alimentarse, y su análisis permite el monitoreo acústico no invasivo. Tradicionalmente, este proceso se realiza de forma manual por expertos, lo que resulta lento debido al gran volumen de datos y la resolución temporal de las señales. Actualmente, el monitoreo acústico es una herramienta esencial en ecología, especialmente para el estudio de los murciélagos, debido a su naturaleza no invasiva y su amplia cobertura espacial y temporal. Por esta razón, se han utilizado técnicas de inteligencia artificial incluyendo el aprendizaje profundo para ello. En este trabajo se presenta el uso de redes neuronales convolucionales basadas en regiones usando un modelo Faster R-CNN para la detección automática de secuencias de pulsos de especies de murciélagos en audios de ultrasonido a partir de espectrogramas. En los resultados preliminares, el modelo mostró altos valores de exhaustividad (>89 %) y un desempeño sólido en mAP@50 (>89%), evidenciando una adecuada capacidad de localización espacial de las secuencias, incluso en entornos de alta biodiversidad. No obstante, se observaron menores valores de precisión y confusión entre especies acústicamente similares, atribuibles a vocalizaciones simultáneas y a la limitada diversidad del conjunto de entrenamiento. Se evidencia la viabilidad del enfoque para el monitoreo acústico automatizado considerando en el trabajo futuro ampliar los datos y mejorar la discriminación entre especies.

Palabras clave— Aprendizaje profundo, Ecolocalización, Murciélagos neotropicales, Redes neuronales convolucionales.

I. INTRODUCCIÓN

El monitoreo acústico es una herramienta clave para el estudio y la conservación de la biodiversidad, especialmente en murciélagos, al ofrecer un método no invasivo con amplia cobertura espaciotemporal. Estos mamíferos cumplen funciones ecosistémicas esenciales y, en regiones megadiversas como el neotrópico. Las señales de ecolocalización, definidas por sus parámetros espectrales y temporales, permiten identificar especies, tipos de pulso y comportamientos, como la búsqueda de alimento o el intento de captura de una presa [1-6].

No obstante, el análisis manual de estas señales es lento y dependiente de expertos, lo que limita su aplicación en ambientes neotropicales ruidosos y con alta biodiversidad, donde las vocalizaciones simultáneas son frecuentes [7, 8]. Para superar estas limitaciones, se han incorporado métodos de aprendizaje automático, en particular redes neuronales convolucionales y aprendizaje profundo, que han demostrado ser eficaces en el análisis de espectrogramas, y son robustos frente al ruido [9-12]. Sin embargo, la mayoría de estos enfoques asumen vocalizaciones aisladas, lo que reduce su desempeño ante señales superpuestas, como las que se encuentran con frecuencia en la naturaleza.

Frente a esta limitación, los modelos de detección de objetos emergen como una alternativa prometedora, al permitir la localización y clasificación de múltiples señales dentro de un mismo espectrograma. Estudios recientes han mostrado su potencial en bioacústica para el análisis de señales biológicas variables y superpuestas. En este contexto, el presente estudio propone el uso de Faster R-CNN [13] para la detección y clasificación automática de secuencias de ecolocalización de murciélagos neotropicales, evaluando su desempeño en un conjunto de datos anotado por expertos que incluye seis especies y una clase de rechazo, con el fin de facilitar el procesamiento de grandes volúmenes de datos acústicos.

A diferencia de los clasificadores tradicionales, que abordan la identificación de especies como un problema de clasificación de segmentos de audio aislados, los modelos de detección de objetos como Faster R-CNN ofrecen ventajas estructurales para el monitoreo acústico en entornos de alta biodiversidad. Los clasificadores convencionales, incluyendo máquinas de soporte vectorial, bosques aleatorios y redes neuronales convolucionales de ventana deslizante, asumen que cada segmento de entrada contiene la vocalización de una única especie, lo que limita severamente su desempeño cuando múltiples individuos vocalizan de forma simultánea, situación frecuente en el neotrópico. Faster R-CNN, en cambio, es una arquitectura "end-to-end" que integra en una sola red neuronal tanto la propuesta de regiones candidatas como su clasificación, permitiendo localizar y etiquetar múltiples secuencias de pulsos dentro de un mismo espectrograma sin requerir segmentación previa de la señal. Esta capacidad de detección simultánea de

objetos múltiples es especialmente relevante para el género *Saccopteryx*, cuyas especies presentan vocalizaciones acústicamente similares que frecuentemente se superponen en el espectrograma debido a la presencia concurrente de varios individuos.

II. MATERIALES Y MÉTODOS

A. Conjunto de datos

Se obtuvieron 1,133 grabaciones de ultrasonido adquiridas con siete grabadoras Song Meter Mini Bat, instaladas en diferentes puntos de una ubicación periurbana a una frecuencia de muestreo de 384 kHz. Biólogos expertos identificaron y anotaron manualmente 854 secuencias de pulsos en fase de búsqueda correspondientes a tres especies del género *Saccopteryx* de la familia Emballonuridae: *Saccopteryx leptura*, *Saccopteryx bilineata*, *Saccopteryx* sp., y una clase de rechazo. Cada archivo tiene una duración máxima de 30 segundos y se registró con una ganancia de 12 dB.

TABLA I
CONJUNTO DE DATOS DE AUDIOS DE MURCIÉLAGOS *SACCOPTERYX*

Especie	Número de secuencias
<i>Saccopteryx leptura</i>	214
<i>Saccopteryx bilineata</i>	189
<i>Saccopteryx</i> sp.	236
Rechazo	215

B. Procesamiento de las señales de ecolocalización

Para construir el conjunto de datos utilizado en el entrenamiento del modelo Faster R-CNN, se llevó a cabo una etapa de preprocesamiento de datos, como se ilustra en la figura 1. Se parte de las grabaciones de ultrasonido originales (paso 1), a partir de las cuales se generaron clips de audio de 1,5 segundos utilizando los tiempos de inicio y fin de cada secuencia (paso 2). Este procedimiento produjo 592 clips para *Saccopteryx leptura*, 475 para *Saccopteryx bilineata*, 553 para *Saccopteryx* sp., y 640 para la clase de rechazo.

Los recortes de audio se transformaron en espectrogramas de magnitud mediante la transformada de Fourier de tiempo corto (STFT, por sus siglas en inglés) y se redimensionan a 512×512 píxeles. Para balancear las clases y mejorar la generalización del modelo (paso 3), se aplicaron técnicas de aumento de datos, incluyendo desplazamientos horizontales, variaciones de brillo y adición de ruido gaussiano, hasta obtener 1,000 espectrogramas por clase (paso 4). A partir de las anotaciones de frecuencia, se generó un archivo CSV que vincula cada espectrograma con su etiqueta y su cuadro delimitador, cuyas coordenadas se definieron según el rango de frecuencia (mínima y máxima) y la duración del clip de audio de la secuencia (tiempo inicial y tiempo final), e incluyen un identificador de grupo por secuencia (paso 5, 6).




Fig 1. Procesamiento de las señales.

C. Modelo Faster R-CNN

Las redes neuronales convolucionales basadas en regiones (R-CNN, por sus siglas en inglés) son una familia de modelos de aprendizaje automático para visión artificial y específicamente para la detección y localización de objetos. Dada una imagen de entrada, se generan un conjunto de cuadros delimitadores (*bounding boxes*) como salida, donde cada cuadro delimitador contiene un objeto y también su categoría o clase (e.g., coche o peatón). El modelo Faster R-CNN utilizado en este trabajo, es una arquitectura “end-to-end” que integra tanto la generación de regiones donde es probable que existan objetos con la clasificación de la región con el objeto más probable en la misma arquitectura de red neuronal [13].

La arquitectura Faster R-CNN (Figura 2) implementada parte de una red ResNet-50 como *backbone* acoplada a una Red Pirámide de Características (FPN, por sus siglas en inglés). La estructura principal extrae representaciones multiescala de los espectrogramas, mientras que la FPN mejora el rendimiento

combinando mapas de características de alta y baja resolución. Estas características enriquecidas se envían a la Red de Propuestas de Regiones (RPN, por sus siglas en inglés), responsable de generar regiones candidatas que potencialmente contienen secuencias de ecolocalización. Cada región propuesta se alinea por submuestreo de las regiones (*RoI pooling*) y se procesa en una serie de capas completamente conectadas que realizan conjuntamente la clasificación de las especies de murciélagos y la regresión de cuadros delimitadores con sus respectivas coordenadas en el espectrograma.




Fig 2. Arquitectura Faster R-CNN. Adaptado de [13]

III. DISEÑO EXPERIMENTAL Y MEDIDAS DE DESEMPEÑO

El modelo Faster R-CNN se inicializó con pesos pre-entrenados de COCO (fasterrcnn_resnet50_fpn_v2). Se implementó en PyTorch y se entrenó con una GPU NVIDIA GeForce RTX 4090 (24 GB VRAM), utilizando una partición estratificada por grupos (85% entrenamiento, 15% validación) para evitar fuga de información. El entrenamiento de la Faster R-CNN se realizó durante 40 épocas, con tamaño de lote 16, optimizador Adam, tasa de aprendizaje inicial de 7×10^{-6} y un programador ReduceLROnPlateau que reduce automáticamente la tasa de aprendizaje cuando la métrica de evaluación deja de mejorar durante un número específico de épocas (*patience*).

El desempeño del modelo Faster R-CNN se evaluó mediante una matriz de confusión normalizada incluyendo la clase de rechazo y medidas de desempeño convencionales de clasificación y detección: precisión (*precision*), exhaustividad (*recall*), medida F1 (F1-score), precisión promedio (AP) y precisión promedio media con un umbral de intersección sobre unión de 0,5 (mAP@50).

La precisión mide la proporción de predicciones positivas correctas respecto al total de predicciones positivas, mientras que la exhaustividad cuantifica la proporción de casos positivos correctamente identificados. La medida F1 corresponde a la media armónica entre precisión y recuperación, proporcionando una medida balanceada del desempeño del modelo.

En el contexto de detección de objetos, la precisión promedio se calcula como el área bajo la curva precisión–exhaustividad para cada clase. Finalmente, la mAP@50 se obtiene como el promedio del AP entre todas las clases, considerando un umbral de intersección sobre la unión de 0.5.

IV. RESULTADOS Y DISCUSIÓN

A. Desempeño del modelo Faster R-CNN

La tabla 2 resumen el desempeño del modelo Faster R-CNN en el conjunto de validación de las tres clases asociadas a las tres especies de *Saccopteryx* más la clase de rechazo. Los valores de precisión oscilaron entre el 63% y el 73%, mientras que los valores de exhaustividad fueron superiores a 89% para las tres especies. Esto indica que el modelo conserva una alta capacidad para localizar regiones candidatas en el espectrograma de secuencias de pulsos de *Saccopteryx* durante la fase de búsqueda, pero tiende a generar detecciones adicionales que no corresponden a secuencias correctas. Estas especies a menudo se superponen entre sí o con otras especies debido a la alta biodiversidad y presencia concurrente de diferentes individuos y especies de murciélagos, lo que contribuye a una mayor confusión.

TABLA II
MEDIDAS DE DESEMPEÑO EN EL SUBCONJUNTO DE VALIDACIÓN

Clase	Precisión	Exhaustividad	Medida F1	mAP@50
<i>Saccopteryx leptura</i>	0.7356	0.9897	0.8440	0.9697
<i>Saccopteryx bilineata</i>	0.6392	0.9573	0.7666	0.8933
<i>Saccopteryx</i> sp.	0.6564	0.8947	0.7572	0.8274
Rechazo	0.5288	0.9245	0.6728	0.8416
Promedio ponderado	0.6451	0.9430	0.7644	-

La medida F1 más alta fue para la detección de la especie *Saccopteryx leptura* (84,4%), seguida de *Saccopteryx bilineata* (76.66 %) y *Saccopteryx* sp. (75.72 %), en consonancia con su mayor similitud acústica. En general, al apreciar los resultados en términos de la medida de desempeño mAP@50, los promedios ponderados del conjunto de validación muestran que el modelo Faster R-CNN posee una buena capacidad de generalización para la detección espacial de secuencias de murciélagos del género *Saccopteryx* en el espectrograma encerrando apropiadamente la región entre las frecuencias mínima y máxima, así como entre el tiempo de inicio y finalización de la secuencia.

B. Matriz de confusión

La figura 3 muestra la matriz de confusión normalizada para el conjunto de validación del modelo Faster R-CNN en la época 20. Si bien el modelo se entrenó durante 40 épocas, se seleccionaron y guardaron los pesos correspondientes a la época 25, ya que no se observó ninguna mejora adicional en las métricas de validación más allá de esta época.




Fig 3. Matriz de confusión normalizada del modelo Faster R-CNN para la detección de secuencias de murciélagos *Saccopteryx*.

En general, la matriz de confusión confirma el buen rendimiento de clasificación del modelo propuesto para *Saccopteryx leptura*, *Saccopteryx bilineata* y *Saccopteryx* sp., que presentan en su diagonal precisiones de del 99%, 96% y 89%, respectivamente, lo que indica que la mayoría de las secuencias detectadas pertenecientes a estas especies se clasifican correctamente. Además, tiene una alta precisión para descartar secuencias que no pertenecen a alguna de estas especies de otros murciélagos u otro tipo de murciélagos.

Una fila adicional en la matriz de confusión, correspondiente a las predicciones fantasma de secuencias detectadas clasificados incorrectamente como alguna de las especies, destaca la tendencia del modelo a generar detecciones adicionales que no coinciden con ninguna anotación que deben ser analizadas en detalle en caso de ser secuencias no anotadas por los biólogos previamente o si en efecto son falsos positivos como parte del trabajo futuro. Sin embargo, estos valores son del 34% o menos.

C. Análisis cualitativo

Las figuras 4, 5 y 6 presentan tres ejemplos de resultados de detecciones automáticas predichas correctamente en el conjunto de validación del modelo Faster R-CNN para

secuencias de pulsos en los espectrogramas de *Saccopteryx leptura*, *Saccopteryx bilineata* y *Saccopteryx* sp., respectivamente.

En la figura 4 la exactitud entre la región de la secuencia de pulsos de *Saccopteryx leptura* predicha y la real fue del 99.9% y la medida de intersección sobre la unión (IoU) fue de 84.9%. En la figura 5 la exactitud entre la región de la secuencia de pulsos de *Saccopteryx bilineata* predicha y la real fue de 99.6% y la medida de IoU fue de 85.2%. En la figura 6 la exactitud entre la región de la secuencia de pulsos de *Saccopteryx* sp. predicha y la real fue de 94.6% y la medida de IoU fue de 85%.




Fig 4. Detección automática de una secuencia de *S. leptura* predicha correcta por el modelo Faster R-CNN (magenta) comparado con la secuencia real (verde).




Fig 5. Detección automática de una secuencia de *S. bilineata* predicha correcta por el modelo Faster R-CNN (magenta) comparado con la secuencia real (verde).




Fig 6. Detección automática de una secuencia de *Saccopteryx* sp. predicha correcta por el modelo Faster R-CNN (magenta) comparado con la secuencia real (verde).

Finalmente, también se identificaron algunos de los casos donde el modelo Faster R-CNN se equivocaba. Las figuras 7 y 8 presentan dos ejemplos de resultados de detecciones automáticas predichas erróneamente en el conjunto de validación por parte del modelo Faster R-CNN.

En la figura 7 aunque la confianza de la región de la secuencia de pulsos predicha fue de 91.1% considerando el modelo que era una secuencia de *Saccopteryx* sp. cuando corresponde realmente a una de *Saccopteryx leptura*, la medida de IoU fue de 0% al no corresponder en lo absoluto la región sienta un claro error. En la figura 8 la confianza de la región de la secuencia de pulsos predicha fue baja con una exactitud de 5.4% y la medida de IoU fue de 0%, prediciendo como *Saccopteryx leptura* una secuencia de *Saccopteryx* sp. lo cual no corresponde, siendo un error.




Fig 7. Detección automática de una secuencia de *S. leptura* predicha erróneamente por el modelo Faster R-CNN como *S. sp* (magenta) comparado con la secuencia real (verde).




Fig 8. Detección automática de una secuencia de *S. leptura* predicha erróneamente por el modelo Faster R-CNN como *Saccopteryx* Sp. (magenta) comparado con la secuencia real (verde).

Tanto en la figura 7 como en la figura 8, podemos evidenciar que una posible causa de la dificultad es la presencia concurrente de varias señales acústicas de varios murciélagos, lo cual puede ocasionar la confusión al no tener suficientes ejemplos similares en el conjunto de datos de entrenamiento. Una particularidad del neotrópico ante la alta biodiversidad de especies presentando desafíos adicionales para el desarrollo de modelos de inteligencia artificial de apoyo a la investigación bioacústica de murciélagos.

El desbalance de clases constituyó un factor relevante en el desempeño del modelo, particularmente visible en los resultados de precisión por especie. Aunque se aplicó sobremuestreo mediante aumento de datos para equilibrar las clases a 1,000 espectrogramas por clase durante el entrenamiento, la variabilidad en la densidad y duración de las secuencias por especie generó diferencias en la dificultad de aprendizaje entre clases. Esto se refleja en los resultados: *Saccopteryx leptura*, que presentó el mayor número de clips generados (592), obtuvo el mejor desempeño en todas las métricas ($F1 = 84.4\%$, $mAP@50 = 96.97\%$), mientras que *Saccopteryx bilineata*, con menor representación original (475 clips), mostró valores inferiores ($F1 = 76.66\%$, $mAP@50 = 89.33\%$). Este patrón sugiere que el aumento de datos, si bien eficaz para mitigar el desbalance superficial en número de imágenes, no compensa completamente la menor diversidad acústica de las clases con menos grabaciones originales, lo que puede llevar a un sobreajuste sobre los patrones más frecuentes dentro de cada clase.

Como trabajo futuro, se plantean dos líneas de acción prioritarias. En primer lugar, la ampliación del conjunto de datos mediante nuevas campañas de grabación en diferentes épocas del año y condiciones climáticas, con el objetivo de capturar mayor variabilidad. En segundo lugar, la incorporación de especies adicionales de murciélagos neotropicales más allá del género *Saccopteryx*, lo que permitirá evaluar la capacidad de generalización del modelo en escenarios de mayor complejidad taxonómica.

IV. CONCLUSIONES

Este trabajo evaluó un enfoque de detección de objetos basado en Faster R-CNN para la detección y clasificación automática de secuencias de ecolocalización de murciélagos en espectrogramas. A diferencia de los métodos tradicionales, el modelo permitió identificar múltiples secuencias de pulsos de tres especies de murciélagos del género *Saccopteryx*.

Los resultados muestran altos valores de exhaustividad (*recall*) en todas las clases, aunque con menor precisión (*precisión*) en especies acústicamente similares del mismo género de *Saccopteryx* debido a algunos falsos positivos. Las métricas de detección indican un aprendizaje efectivo de patrones espectrales, aunque puede haber algún grado de sobreajuste pese a que se incorporó la clase de rechazo, pero debido a la pequeña cantidad original del conjunto de datos, aunque se haya realizado sobremuestreo. En conjunto, el modelo se perfila como una alternativa para el monitoreo acústico automatizado, con trabajos futuros orientados a ampliar la colección de señales, audios con presencia de pocos o múltiples especies concurrentemente, mejorar la discriminación entre especies y su integración en plataformas web.

AGRADECIMIENTOS

Los autores agradecen al proyecto “Dinámica temporal de la actividad de dos especies hermanas de murciélagos insectívoros en el piedemonte llanero colombiano” con código C10-F02-001-2024”. financiado por la Universidad de los Llanos. Igualmente, los autores agradecen al Grupo de investigación GITECX y al semillero de investigación Adalab por los recursos computacionales para la experimentación, y a los integrantes del semillero de investigación Mamíferos Silvestres - Unillanos por las anotaciones, validaciones y revisión de resultados.

REFERENCIAS

- [1] A. López-Baucells, N. Yoh, R. Rocha, P. E. D. Bobrowiec, J. M. Palmeirim, C. F. J. Meyer, Optimizing bat bioacoustic surveys in human-modified neotropical landscapes, *Ecological Applications* 31 (2021) e02366.
- [2] D. Russo, J. L. Coleman, L. Ancillotto, C. Korine, Ecosystem services by bats in urban areas, Springer, 2023, pp. 167–180.
- [3] P. Stahlschmidt, C. A. Brühl, Bats as bioindicators—the need of a standardized method for acoustic bat activity surveys, *Methods in Ecology and Evolution* 3 (2012) 503–508.
- [4] M. B. Fenton, Questions, ideas and tools: lessons from bat echolocation, *Animal Behaviour* 85 (2013) 869–879.
- [5] M. C. S. Guzmán, Ecolocación en murciélagos en el neotrópico (2015).
- [6] G. Mirzaei, M. W. Majid, J. Ross, M. M. Jamali, P. V. Gorsevski, J. P. Frizado, V. P. Bingman, The bio-acoustic feature extraction and classification of bat echolocation calls, in: 2012 IEEE International Conference on Electro/Information Technology, IEEE, 2012, pp. 1–4.
- [7] V. Zamora-Gutierrez, C. Lopez-Gonzalez, M. C. M. Gonzalez, B. Fenton, G. Jones, E. K. V. Kalko, S. J. Puechmaille, V. Stathopoulos, K. E. Jones, Acoustic identification of mexican bats based on taxonomic and ecological constraints on call design, *Methods in ecology and evolution* 7 (2016) 1082–1091.
- [8] P. C. Caycedo-Rosales, J. F. Ruiz-Muñoz, M. Orozco-Alzate, Reconocimiento automatizado de señales bioacústicas: Una revisión de métodos y aplicaciones, *Ingeniería y Ciencia* 9 (2013) 171–195.
- [9] D. W. Armitage, H. K. Ober, A comparison of supervised learning techniques in the classification of bat echolocation calls, *Ecological Informatics* 5 (2010) 465–473.
- [10] D. Stowell, Computational bioacoustics with deep learning: a review and roadmap, *PeerJ* 10 (2022) e13152.
- [11] A. Lai, La imagen del sonido y la escritura espectral, *Escritura e imagen* 4 (2008) 125–146.
- [12] O. M. Aodha, R. Gibb, K. E. Barlow, E. Browning, M. Firman, R. Freeman, B. Harder, L. Kinsey, G. R. Mead, S. E. Newson, Bat detective—deep learning tools for bat acoustic signal detection, *PLoS computational biology* 14 (2018) e1005995.
- [13] S. Ren, K. He, R. Girshick, y J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 6, pp. 1137-1149, jun. 2017, doi: 10.1109/TPAMI.2016.2577031.