Desarrollo de redes neuronales para el análisis y limpieza de datos sísmicos de las misiones Apolo y el aterrizador InSight

Andrés Serrato Camero, Juan Andrés Rodríguez Peñuela, Mateo Sebastián Forero Fuentes

Universidad Escuela Colombiana de ingeniería Julio Garavito
Bogotá, Colombia

Resumen

La actividad sísmica en cuerpos planetarios y satélites es uno de los aspectos más importantes que surgen en la exploración espacial, pues el estudio de estos permite obtener información sobre la estructura interna de sus cuerpos.

Diversas investigaciones abordan el estudio e investigación de las señales sísmicas en el espacio, ello hace posible que se usen varios enfoques para la detección y caracterización de los eventos sísmicos; sin embargo, la presencia de ruido que entra inevitablemente en los datos recibidos presenta un reto significativo para la precisión del análisis de estas señales.

Por lo tanto, el objetivo de este trabajo es el desarrollo de redes neuronales para la identificación precisa del inicio y fin de eventos sísmicos en señales obtenidas por misiones espaciales, permitiendo acotar el intervalo de tiempo en el que ocurre un evento sísmico y evitando, en mayor medida la interferencia del ruido en los datos que se deben enviar a la Tierra para un análisis posterior.

Para cumplir este objetivo, se obtuvieron datos sísmicos reales de las misiones Apolo y de la sonda estática InSight de la NASA en Marte, mediante técnicas de procesamiento de señales basadas en redes neuronales convolucionales, diseñadas para identificar patrones en las ondas sísmicas y diferenciar entre eventos sísmicos o ruido. Este enfoque permite la división precisa de los eventos sísmicos, delimitando su inicio y su fin.

Como resultado, se logró una reducción cercana al 90% de la cantidad de datos irrelevantes enviados desde estas sondas y misiones espaciales hasta la Tierra, lo que abre la puerta al uso de redes neuronales como solución novedosa para este tipo de problemas. La aplicación propuesta reduce la cantidad de información transmitida a la Tierra, lo que, de forma directa, facilita el ahorro

DOI: https://doi.org/10.26507/paper.4754

de energía, un recurso escaso en este tipo de misiones y, simultáneamente, mejora la fiabilidad de la información recolectada en las misiones espaciales.

Palabras clave: redes neuronales; procesamiento de información; eventos sísmicos

Abstract

Seismic activity in planetary bodies and their satellites is one of the most important aspects that arise in space exploration, as studying it provides valuable information about the internal structure of these bodies.

Several studies have explored the detection and analysis of seismic signals in space. Several approaches are used to detect and characterize seismic events; however, the presence of noise inevitably present in the received data poses a significant challenge to the accuracy of signal analysis.

Therefore, the objective of this work is to develop neural networks for the accurate identification of the start and end of seismic events in signals obtained by space missions, allowing for the delimitation of the time interval in which a seismic event occurs and minimizing, as much as possible, the interference of noise in the data that must be sent to Earth for further analysis.

To achieve this objective, real seismic data from the Apollo missions and NASA's InSight lander on Mars were used. Signal processing techniques based on convolutional neural networks were applied, designed to identify patterns in seismic waves and distinguish between seismic events and noise. This approach allowed for the precise segmentation of seismic events, accurately identifying their beginning and end. As a result, there was a reduction of nearly 90% in the amount of irrelevant data transmitted from these space probes and missions to Earth.

Finally, this opens the door to the use of neural networks as a novel solution for this type of problem. Additionally, the proposed application reduces the amount of information transmitted to Earth, which directly saves energy scarce resources in such missions—while simultaneously improving the reliability of the information collected in space missions.

Keywords*: neural networks; information processing; seismic events*

1. Introducción

Desde mediados del siglo XX, la exploración espacial ha sido una prioridad científica y tecnológica. Misiones realizadas en el programa Apolo y aterrizadores como InSight en Marte han ampliado nuestro conocimiento sobre la geología de cuerpos celestes, en particular La luna y Marte. Uno de los avances clave ha sido el estudio de su actividad sísmica, que permite comprender mejor su estructura interna y comportamiento frente a eventos sísmicos.

Sin embargo, la recolección de datos sísmicos en estos entornos presenta desafíos importantes. La señal captada suele estar contaminada con ruido, lo que incrementa el tamaño de los datos transmitidos. En los compilados de datos en informes de la NASA, Dietz et al. (1972) se puede apreciar que esto ralentiza el envío de información a la Tierra y aumenta el consumo energético, gracias a los datos expuestos se observa que en las misiones Apolo se utilizaban aproximadamente 20 vatios que operaban a bajas velocidades de datos, alrededor de 51,2 kbps, lo que traducía en un consumo estimado de alrededor de 0.933 kWh por gigabyte transmitido, esto ha mejorado en las misiones actuales, llegando a un valor cercano a 0.04 kWh.

Debido a que los avances tecnológicos han permitido reducir el consumo energético por unidad de información transmitida, surgieron nuevas posibilidades de incrementar la cantidad de datos enviados, lo que plantea nuevos desafíos en términos de procesamiento y gestión de la información. Por esto, es crucial desarrollar métodos eficientes para la eliminación de ruido en señales sísmicas antes de ser enviadas a la tierra, con el fin de optimizar la transmisión de datos y reducir el uso de recursos en futuras misiones espaciales.

Con esto se facilita la identificación y sectorización de los eventos sísmicos presentes en las distintas ondas sísmicas que son enviadas a la tierra, por ello NASA (2024) plantea la siguiente duda ¿Como aplicar limpieza del ruido en las señales sísmicas captadas por las misiones Apolo y el aterrizador InSight de la NASA en Marte para reducir el peso de los archivos y el gasto energético para enviar los datos hasta la tierra? La propuesta será desarrollar redes neuronales que, a partir de la identificación precisa del inicio y fin de eventos sísmicos, faciliten la limpieza del ruido y consecuentemente reduzcan el peso los archivos.

2. Objetivos

Objetivo General:

- Desarrollar redes neuronales para la identificación precisa del inicio y el fin de eventos sísmicos en señales obtenidas por misiones espaciales.

Objetivos específicos:

- Procesar señales sísmicas provenientes de la misión Apolo 12.
- Generar un conjunto de datos etiquetados para el entrenamiento y validación del modelo.
- Diseñar redes convolucionales especializadas en detectar el inicio y el fin de eventos sísmicos en señales contaminadas con ruido.
- Entrenar redes convolucionales enfocadas en el inicio y fin de eventos sísmicos
- Evaluar el rendimiento del modelo usando métricas de precisión, sensibilidad, perdida, y matriz de confusión.

- Analizar el impacto de la limpieza de las señales sobre la reducción del tamaño de los datos y su potencial para optimizar la transmisión desde entorno extraplanetarios.

3. Metodología

El presente trabajo se enfoca en la detección de sismos utilizando una red neuronal convolucional entrenada con datos de velocidad sísmica obtenidos de la misión Apolo 12. La metodología desarrollada comprende varias etapas, que incluyen la preparación de los datos, el diseño del modelo, el entrenamiento de este, la evaluación del desempeño y el ajuste final para mejorar su rendimiento.

Inicialmente, se recopilaron los registros de velocidad sísmica captados por los instrumentos instalados durante la misión Apolo 12. Estos registros fueron segmentados en ventanas temporales, en la que cada una fue etiquetada como "sismo" o "no sismo" de acuerdo con la información del catálogo oficial de eventos sísmicos de dicha misión. Debido a lo limitados casos que se tenían, se utilizaron técnicas de data augmentation, las cuales fueron útiles para convertir los limitados registros con los que se contaban, aumentando en 80 veces el dataset con el que se contaba.

Una vez preparado el conjunto de datos, se procedió al diseño de las redes neuronales convolucionales encargadas de encontrar el inicio y el fin de los eventos sísmicos. Estas se componen de diversas capas llamadas capas convolucionales, responsables de extraer características relevantes de las señales, y capas de agrupamiento (pooling), que reducen la dimensión espacial de los datos, acortando o simplificando las señales para facilitar su procesamiento. A su vez se incorporaron capas de normalización para mejorar la estabilidad del entrenamiento, y capas densas (fully connected layers), donde cada neurona está conectada con todas las neuronas de la capa anterior, utilizadas al final de la red para realizar la clasificación binaria.

La arquitectura de la red se ajustó específicamente para una tarea de clasificación binaria, con el objetivo de diferenciar entre segmentos de la señal que contienen eventos sísmicos y aquellos que no, enfocándonos en la detección de inicio y final de los eventos sísmicos.

Para buscar una mejor generalización del modelo, se hizo uso de técnicas de regularización, como lo son el *early stopping* y *dropout*. Esto se implementó con el fin de evitar *overfitting* y garantizar una mejor generalización del modelo. Estas técnicas de regularización se basaron en el libro de Goodfellow, et al. (2016), en el capítulo 7, donde se listan diversos tipos de técnicas de regularización y sus beneficios, los cuales se lograron evidenciar en el modelo entrenado.

A su vez, se utilizaron algunas técnicas de optimización basadas en el capítulo 8 del mismo libro, las cuales ayudaron en el entrenamiento del modelo, logrando un menor tiempo de entrenamiento y una mejor exactitud en las predicciones. Algunas de las técnicas que proponen Goodfellow, et al. (2016) fueron, el uso de *batch* y *mini-batch* para segmentar el *dataset* en el entrenamiento. Se

usó el optimizador Adam ofrecido por Keras (s.f), el cual en su implementación posee técnicas como el *momentum* y el descenso del gradiente.

Una vez entrenado el modelo, se procedió a la evaluación de rendimiento utilizando un conjunto de prueba independiente que no había sido usado anteriormente. Esta evaluación permitió medir su capacidad de generalización y efectividad para identificar sismos en señales no vistas anteriormente, para poder analizar su efectividad sobre las detecciones hechas.

Finalmente, se llevó a cabo un proceso de optimización iterativa del modelo. Esta fase incluyó la modificación de la arquitectura, el ajuste de los hiperparámetros y la implementación de diferentes técnicas de entrenamiento, con el fin de mejorar su precisión y robustez.

4. Desarrollo del trabajo

El trabajo comenzó con la recopilación de los datos sísmicos proporcionados por la NASA (2024) sobre la misión Apolo12. Estos registros fueron utilizados como base para la detección de eventos sísmicos. En esta etapa, se diseñó un proceso de segmentación de las señales dividiéndolas en ventanas temporales de una duración fija. Cada una de las ventanas fue etiquetada como "sismo" o "no sismo", dependiendo si se encontraban eventos sísmicos registrados en el catálogo oficial de la misión, generando así un conjunto de datos supervisado confiable para el entrenamiento de las redes neuronales.

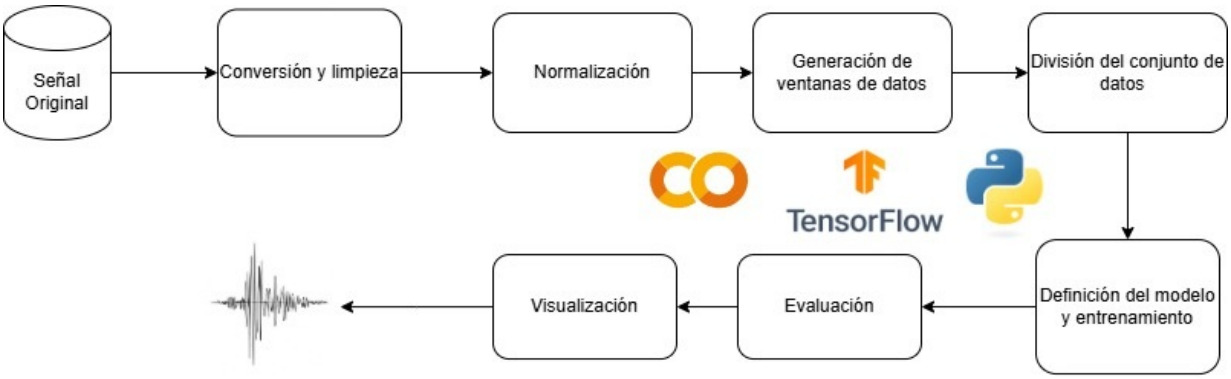

Ilustración 1, flujo de procesamiento, autoría propia, 2025.

Un desafío relevante en esta fase fue el desbalance de clases; puesto que la mayoría de las ventanas temporales no contenían sismos, podía llevar a que el modelo aprendiera con un sesgo hacia la mayoría que no contenía sismos, para evitar esto se aplicaron técnicas de submuestreo; esto consistió en la reducción controlada de ejemplos de la clase dominante y aumento de datos que se generaron con muestras artificiales mediante variaciones de las señales originales.

Una vez completada la preparación del conjunto de datos se realizó el diseño de dos redes neuronales convolucionales. La primera red fue entrenada para detectar el inicio del sismo y la segunda con la misma arquitectura y metodología fue entrenada para identificar el fin del evento sísmico.

Para asegurar un aprendizaje eficiente y robusto en ambas redes, se utilizaron funciones de activación ReLU en capas intermedias y se implementó la regulación Dropout. Esta última técnica ayuda a prevenir el sobreajuste desactivando neuronas de forma aleatoria durante el entrenamiento, promoviendo así la capacidad de generalización de los modelos.

Una vez terminado el entrenamiento revisamos los resultados de ambas redes y cuál fue su curva de sensibilidad, precisión y de perdida iniciando por la red de detección de inicio del sismo.

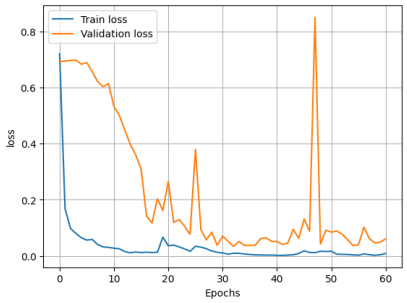

Ilustración 2, gráfica de perdida, autoría propia, 2025.

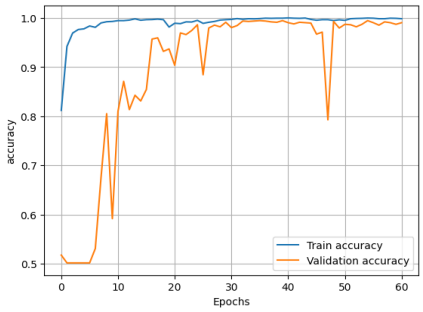

Ilustración 3, gráfica de precisión, autoría propia, 2025.

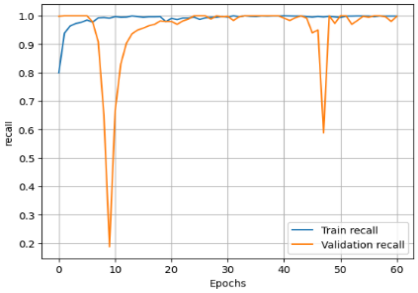

Ilustración 4, gráfica de sensibilidad, autoría propia, 2025.

La gráfica de perdida evidencia una disminución progresiva tanto en los datos de entrenamiento como en la validación, lo que indica que el modelo está disminuyendo la perdida en la función de costo que uso la red neuronal, Aunque en ciertos puntos se observan algunos picos, estos fueron corregidos rápidamente, lo que sugiere una buena capacidad de recuperación ante posibles episodios de sobre ajuste.

En cuanto a la precisión (accuracy), se observa una mejora constante, aunque el modelo comenzó con una precisión de aproximadamente 80% en el entrenamiento y 50% en la validación, pero con el avance de las épocas ambas curvas convergieron hacia un valor cercano al 99% lo que refleja un aprendizaje efectivo y una adecuada capacidad de generalización.

La grafica de recall mostro inicialmente un valor de 100%, probablemente se debió a que el modelo clasificaba todas las ventanas como "sismo". Sin embargo, este comportamiento se corrigió durante el entrenamiento, estabilizándose finalmente en valores altos. Esto indica que la red no solo logro identificar correctamente los eventos sísmicos, sino que también aprendió a reconocer cuando no ocurren diferenciando entre ventanas positivas y ventanas negativas.

	precision	recall	f1-score	support
No Sismo	1.00	0.99	0.99	607
Sismo	0.99	1.00	0.99	593
accuracy			0.99	1200
macro avg	0.99	0.99	0.99	1200
weighted avg	0.99	0.99	0.99	1200

Ilustración 5, matriz de confusión del modelo (inicial), autoría propia, 2025.

A partir de los resultados obtenidos en la matriz de confusión, se observa que el modelo alcanza una precisión del 0.99 para identificar el inicio de un sismo. Este nivel de precisión indica que el modelo generaliza de forma correcta y presenta una tasa de error muy baja lo que lo convierte en un modelo confiable para la detección de los inicios de eventos sísmicos.

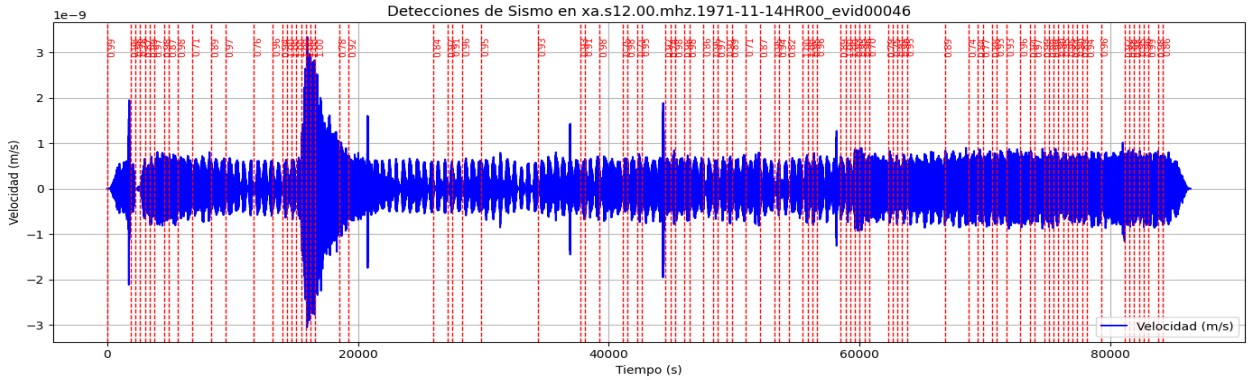

Ilustración 6, resultados del modelo de clasificación sísmica (inicio), autoría propia, 2025.

Después de esto se revisaron los valores más altos en la predicción y se realizó, un ajuste para solo tomar los valores más cercanos a 1, puesto que son aquellos que la red indica como los más seguros como inicio del sismo, de esta forma los resultados cambian y nos dan los siguientes

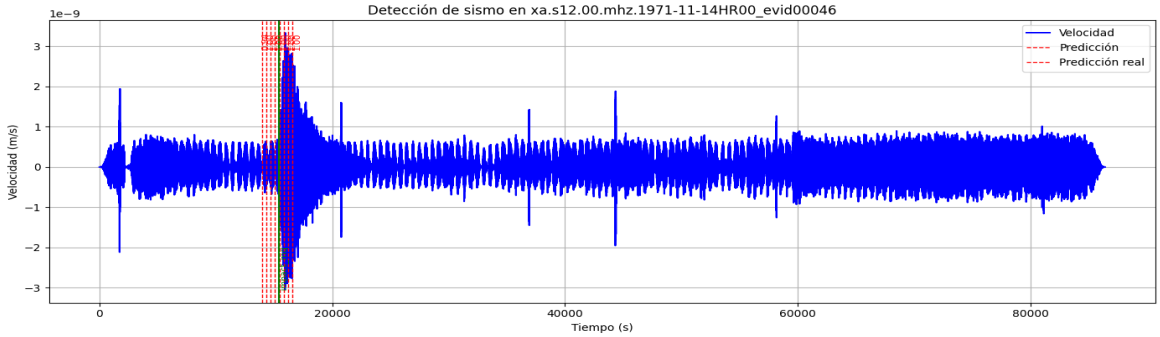

Ilustración 7, resultados del modelo filtrados por mejores clasificaciones (inicio), autoría propia, 2025.

resultados.

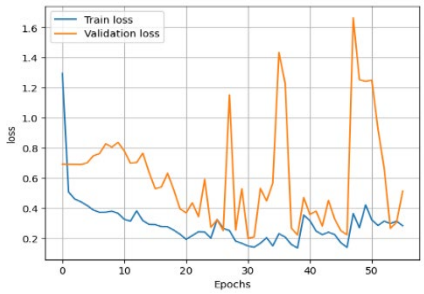

Ilustración 8, gráfica de perdida, autoría propia, 2025.

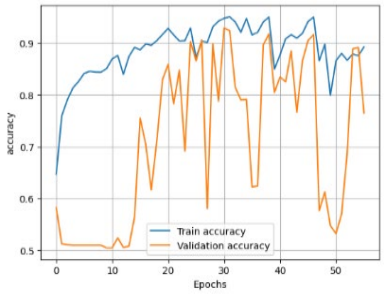

Ilustración 9, gráfica de precisión, autoría propia, 2025.

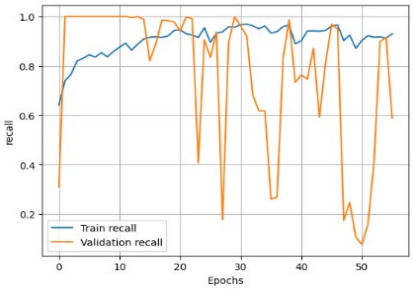

Ilustración 10, gráfica de sensibilidad, autoría propia, 2025.

En la gráfica de perdida, se observa una disminución progresiva durante el entrenamiento, lo que indica que el modelo está optimizando su función de costo. No obstante, la curva correspondiente

a la validación presenta un comportamiento mucho más inestable con varios picos pronunciados. Esta inestabilidad se puede deber a la dificultad que tiene la red neuronal para la identificación del final del sismo puesto que los patrones tienden a ser más difusos y menos definidos que los asociados al inicio.

La segunda gráfica, Accuracy, se observa la evolución de la precisión durante el entrenamiento y la precisión (línea azul) mejora de forma constante alcanzando valores entre 0.9 y con ligeras oscilaciones. Por contrario la precisión en la validación (línea naranja) es ligeramente irregular con variaciones entre 0.5 y 0.9 lo que sugiere que no está logrando encontrar un patrón constante para la actualización de los pesos, a pesar de esto la red en muchos de sus máximos presenta una exactitud considerable aproximada del 90%, la cual presento buenos resultados en la experimentación realizada.

La tercera gráfica, Recall, en el entrenamiento (línea azul) comienza con valores bajos, pero mejora de manera progresiva hasta estabilizarse en niveles altos, sin embargo, en la validación se presenta una inestabilidad alta que puede pueden indicar dificultades en el modelo para identificar consistentemente los eventos positivos en el conjunto de validación indicando posible falta de detección de verdaderos positivos.

	precision	recall	f1-score	support
No Sismo	0.95	0.90	0.93	624
Sismo	0.90	0.95	0.92	573
accuracy			0.93	1197
macro avg	0.93	0.93	0.93	1197
weighted avg	0.93	0.93	0.93	1197

Ilustración 11, matriz de confusión del modelo (final), autoría propia, 2025.

A partir de los resultados obtenidos en la matriz de confusión, se aprecia que el modelo tiene una precisión entre 0.93 y 0.92 para identificar correctamente los eventos finales del sismo. Este nivel de precisión sugiere que el modelo generaliza de forma correcta y tiene una tasa de error baja lo que lo hace apto para las tareas de detección sísmica.

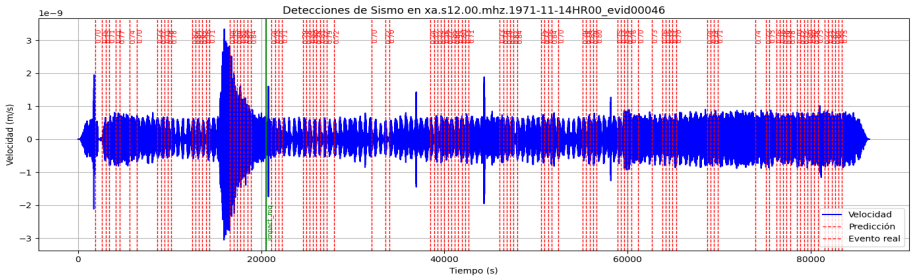

Ilustración 12, resultados del modelo de clasificación sísmica (final), autoría propia, autoría propia, 2025.

De igual forma, como se hizo anterior mente con la red que detecta el inicio del sismo se realizaron ajustes para que solo tome los valores que mayor probabilidad tenían para que se indicara que era el final del sismo lo que llevo a un cambio en el resultado que se ven de la siguiente forma.

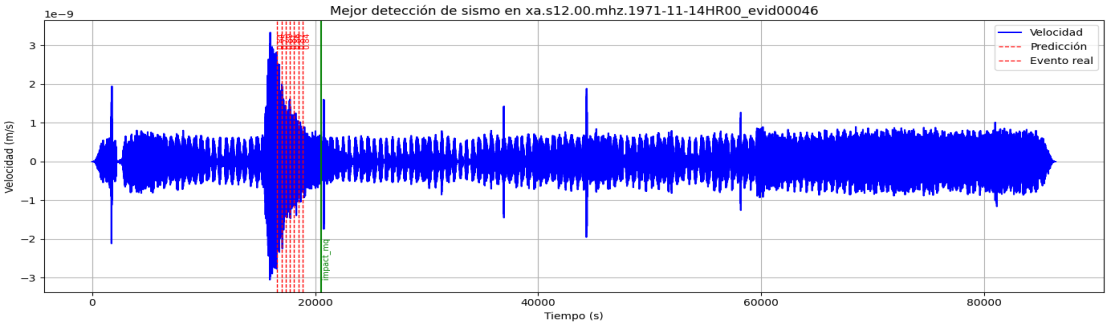

Ilustración13, resultados del modelo filtrados por mejores clasificaciones (final), autoría propia 2025.

Una vez terminada la ejecución de las redes neuronales, se procedió a unir los resultados obtenidos por ambos modelos el que indica el inicio del sismo y el que indica el fin del sismo En esta etapa se generó un nuevo dataframe, en el cual se aplicó el proceso de limpieza y recorte de las señales sísmicas. Este dataframe muestra de forma visual los eventos detectados, marcando con una línea amarrilla el inicio del sismo y marcando con una línea morada el fin de este.

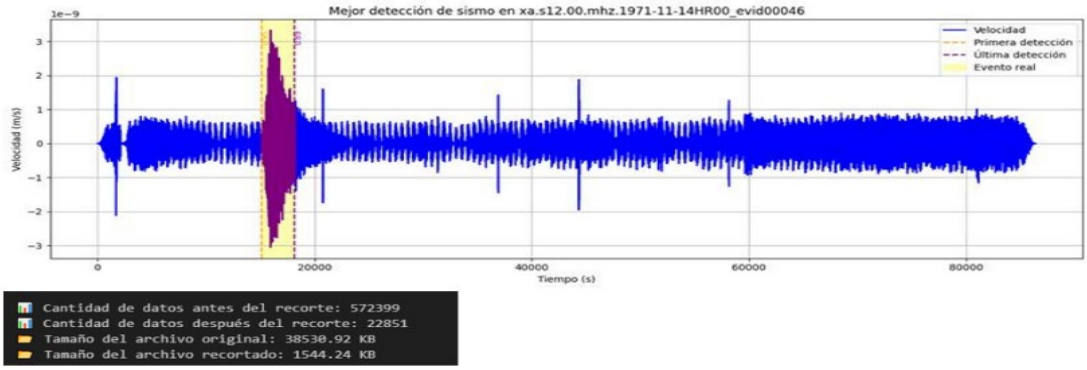

Ilustración 14, resultados unión de ambos modelos, autoría propia 2025.

Este mismo proceso fue aplicado para analizar las señales sísmicas registradas por el aterrizador InSight en Marte. Sin embargo, debido a la menor cantidad de datos disponibles y a una alta irregularidad de las señales, caracterizadas por una baja variabilidad espectral, se presentaron limitaciones.

Por esta razón fue necesario implementar un filtro manual para seleccionar y operar únicamente aquellas señales que presentaban una estructura sísmica mediana mente clara, en estos casos la red neuronal demostró ser considerablemente efectiva en la detección, limpieza y recorte de los eventos sísmicos.

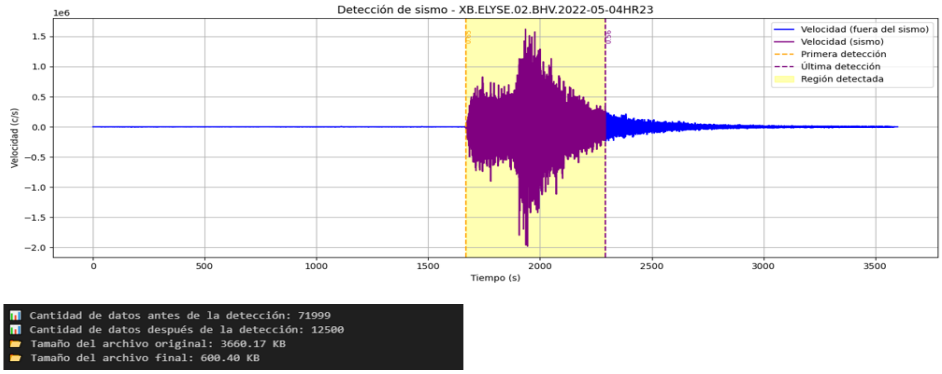

Ilustración15, resultados procesamiento de los datos de marte, autoría propia 2025

5. Análisis de resultados

Este trabajo cumplió con éxito su objetivo general, pues consiguió desarrollar redes neuronales para la identificación precisa del inicio y fin de eventos sísmicos en señales espaciales, mitigando la interferencia del ruido. El logro de esta meta fue posible mediante la consecución de los objetivos específicos planteados: se procesaron y segmentaron correctamente las señales sísmicas de la misión Apolo 12, generando así un conjunto de datos etiquetado y balanceado para el entrenamiento; se diseñaron y entrenaron redes convolucionales especializadas, cuya efectividad fue confirmada mediante una evaluación rigurosa de su rendimiento en términos de precisión, sensibilidad y pérdida.

Fundamentalmente, la aplicación del modelo demostró su efectividad al reducir drásticamente el tamaño de los archivos de datos, para Apolo, un promedio de 38 MB se redujo a menos de 4 MB, lo que representa una reducción de datos superior al 90% en los casos óptimos, mientras que para los datos de martes procesados se redujo su tamaño promedio de 3,6 MB a valores que oscilan entre los 0,6 y los 0,4 MB.

Esta optimización tiene implicaciones directas en la eficiencia energética, logrando una reducción estimada del consumo para la transferencia superior al 90% por archivo. Así, esta investigación no solo valida la aplicación de redes neuronales para el procesamiento de señales sísmicas, sino que también contribuye directamente a una gestión más eficiente y sostenible de los valiosos recursos energéticos y de la transmisión en futuras misiones de exploración espacial.

6. Referencias

- Apollo11Space. (2025, Marzo 10). The Apollo S-Band Transponder. Consultado el 10 de marzo de 2025 en https://apollo11space.com/the-apollo-s-band-transponder/
- Goodfellow, I., Bengio, Y. and Courville, A. (2016). Deep Learning. MIT Press, Cambridge, MA, pp. 775. Recuperado de http://www.deeplearningbook.org

- NASA. (2024). NASA Space Apps Challenge. Seismic Detection Across the Solar System. Consultado el 25 de septiembre de 2024 en https://www.spaceappschallenge.org/nasa-space-apps-2024/challenges/seismic-detection-across-the-solar-system/
- Dietz, R., Rhoades, E. and Davidson, J (1972). Apolo experience report – lunar module communications system, p.p. 28-56. Recuperado de https://www.nasa.gov/wp-content/uploads/static/history/alsj/tnD6974LMCommSystem.pdf
- Patarroyo G. and L. y Jején S. S. (2024). Detección del tipo de terreno sobre el que transita un Rover, a través de la aplicación de técnicas de machine learning. Escuela Colombiana de Ingeniería Julio Garavito, Bogotá, D.C., pp. 75.
- Keras Team. (s.f.). *Adam optimizer*. Consultado el 15 de abril de 2025 en https://keras.io/api/optimizers/adam/

Sobre los autores

- **Andrés Serrato Camero**: Estudiante Programa de Ingeniería de sistemas, Universidad Escuela Colombiana de Ingeniería Julio Garavito andresserratocamero@gmail.com
- **Juan Andrés Rodríguez Peñuela**: Estudiante Programa de Ingeniería de sistemas, Universidad Escuela Colombiana de Ingeniería Julio Garavito Juanpeandres0@gmail.com
- **Mateo Sebastián Forero Fuentes**: Estudiante Programa de Ingeniería de sistemas Universidad Escuela Colombiana de Ingeniería Julio Garavito mateosebastianforerofuentes@gmail.com

---

Los puntos de vista expresados en este artículo no reflejan necesariamente la opinión de la Asociación Colombiana de Facultades de Ingeniería.

Copyright © 2025 Asociación Colombiana de Facultades de Ingeniería (ACOFI)