

.UBAeconómicas **posgrado**

ENAP Escuela de Negocios y Administración Pública

Universidad de Buenos Aires

Facultad de Ciencias Económicas

Escuela de Negocios y Administración Pública

**CARRERA DE ESPECIALIZACIÓN EN
MÉTODOS CUANTITATIVOS PARA LA GESTIÓN Y
ANÁLISIS DE DATOS EN ORGANIZACIONES**

TRABAJO FINAL INTEGRADOR

**Modelos de Predicción del Comportamiento de las
Fallas Tectónicas**

AUTOR: MARCELA ANDREA PALMIERI

TUTOR: MG. JUANA LÓPEZ

DICIEMBRE 2024

Resumen

La necesidad de mejorar la precisión de las predicciones de movimientos telúricos es crítica debido a la alta vulnerabilidad sísmica de la región del cinturón de fuego de Sur América, lo que subraya la importancia de contar con sistemas de alerta temprana más efectivos.

El proyecto tiene como objetivo desarrollar un modelo predictivo capaz de anticipar la ocurrencia, magnitud y localización de terremotos con el análisis de datos multidisciplinarios y el uso de técnicas avanzadas de modelado y machine learning.

Se integrarán datos provenientes de diversas disciplinas como la sismología, geología, geodesia, hidrología y meteorología. Estos datos serán analizados para identificar patrones sísmicos históricos, se tomarán registros de eventos en el periodo comprendido desde 2004 a 2024. También se evaluará la posible influencia de factores como la variación de los rayos cósmicos, principalmente la incidencia o llegada anómala de lluvia de muones, partículas elementales de gran energía.

El modelo predictivo resultante se pondrá a disposición de la Dirección de Defensa Civil de la provincia de Mendoza, no solo contribuirá a reducir el riesgo y la vulnerabilidad de las poblaciones ante desastres naturales, sino que también aportará el conocimiento científico sobre los procesos geológicos fundamentales. Se desarrollarán herramientas de visualización de datos para apoyar la toma de decisiones y mejorar la planificación y respuesta ante futuros terremotos.

Palabras clave

Terremotos, análisis de datos, precursores sísmicos, análisis predictivo, machine learning.

Índice

Resumen	1
Palabras clave	1
Introducción	1
1. El desafío de la predicción de sismos	3
1.1. Falencias en modelos tradicionales	3
1.2. Herramientas propuestas	4
1.3. Estudios preliminares de precursores externos	5
2. Metodología aplicada	7
2.1. Recolección y preparación de datos	7
2.2. Análisis exploratorio de datos	8
2.3. Desarrollo de modelo predictivo	8
3. Desarrollo de la propuesta metodológica, insumos necesarios para el desarrollo del modelo	9
3.1. Origen de datos	9
3.1.1. Descripción de área de estudio	9
3.2. Identificación de patrones y precursores	10
3.2.1. Precursores que mejor se adaptan al modelo, creación de set de datos	11
3.2.2. Establecimiento y definición de las variables para cada precursor	13
3.3. Modelos predictivos	16
3.3.1. Procedimientos	17
3.3.2. Entrenamiento y validación de los modelos	18
3.3.3. Evaluación	19
3.4. Resultados y comparativos	20
4. Aplicativo sistema de alerta temprana	28
Conclusiones	31
Bibliografía	33
Apéndices	35



1821 Universidad
de Buenos Aires

A. Script en colab de Google Links:	35
B. Set de datos	35
Terremotos	35
Tormentas Geomagnéticas	35
Catalogo Pierre Auger Rayos C3smicos	36
Reporte del tutor	37

Introducción

La fundamentación del tratamiento del tema de predicción de terremotos con métodos y modelos de análisis de datos radica en la necesidad crítica de mejorar la capacidad de anticipar eventos sísmicos en una región altamente vulnerable como el cinturón de fuego en América del Sur. Los terremotos representan una amenaza significativa para la seguridad de las comunidades y las infraestructuras, especialmente en áreas con alta actividad tectónica. La integración de datos multidisciplinarios, incluidos aquellos relacionados con la detección en la variación de los rayos cósmicos, junto con el uso de técnicas avanzadas de modelado y machine learning, ofrece la oportunidad de superar antiguas limitaciones. Mejorar la precisión de los modelos predictivos podría resultar en sistemas de alerta temprana más eficaces, permitiendo a las autoridades tomar medidas preventivas y de respuesta más eficientes, salvando vidas y minimizando daños.

Por lo tanto, el proyecto propuesto se justifica en la necesidad de avanzar en la ciencia de la predicción sísmica para proteger a las comunidades de los impactos devastadores de los movimientos sísmicos, en general de América del Sur y en particular desarrollando una herramienta que sea de utilidad para la Dirección de Defensa Civil y sus brigadas en la Provincia de Mendoza.

Los movimientos sísmicos son una preocupación constante para la Dirección de Defensa Civil de la Provincia de Mendoza, la cual cumple con la misión de predecir y prevenir desastres de cualquier origen, para limitar, mitigar o neutralizar los daños que tales desastres pudiesen causar a personas y bienes, así como a realizar, en las zonas afectadas, las acciones de emergencia para permitir la continuidad del sistema de salud, administrativo y funcional en todos los órdenes de actividad.

Un sistema de alerta temprana en materia sísmica que movilice los esfuerzos y recursos de la organización sería una herramienta de gran aplicabilidad en la prevención y respuesta temprana de estos tipos de siniestros naturales.

¿Cómo se pueden mejorar los modelos predictivos de terremotos mediante la integración de datos multidisciplinarios y el uso de técnicas de modelado y machine learning, para anticipar de manera más precisa la ocurrencia, magnitud y localización de los eventos sísmicos?

La mejora en modelos predictivos que se propone es realizar un estudio de la correlación con los precursores, tales como tormentas geomagnéticas de mayor energía y principalmente con la influencia que se ha detectado en la variación de rayos cósmicos que cruzan o impactan el planeta unos días antes de la ocurrencia del sismo.

Se tomarán datos de terremotos ocurridos en Sur América desde repositorio de USGS¹, INPRES² y ONEMI³, repositorio de datos de *Space Weather Live*⁴, Observatorio Pierre Auger y Observatorio de rayos cósmicos distribuidos, en el periodo comprendido desde 2004 al 2024, con el objetivo de desarrollar un modelo predictivo que permita anticipar la ocurrencia, magnitud y localización de terremotos mediante el análisis de datos multidisciplinarios y técnicas de modelado.

El trabajo contempla:

- Integrar datos multidisciplinarios: recopilar y unificar datos sismológicos, geológicos, geodésicos, hidrológicos y atmosféricos para una mejor representación de los factores que influyen en la actividad sísmica.
- Mejorar la recolección de datos: implementar y optimizar técnicas de recolección de datos en tiempo real, aportadas por instituciones que utilizan sensores de alta precisión y tecnologías de monitoreo remoto.
- Identificar y analizar patrones sísmicos: examinar patrones históricos de actividad sísmica para identificar tendencias y correlaciones que puedan mejorar las predicciones futuras.
- Evaluar la incertidumbre y riesgos: desarrollar métodos para cuantificar la incertidumbre en las predicciones y evaluar los riesgos asociados con diferentes escenarios sísmicos.
- Desarrollar herramientas de visualización: crear herramientas de visualización de datos que permitan a los responsables de la toma de decisiones comprender mejor las predicciones y los posibles impactos de los terremotos.

Mediante la utilización de análisis de datos e implementación de modelos predictivos permitiría anticipar con mayor exactitud la ocurrencia, magnitud y localización de los eventos sísmicos. La aplicación de algoritmos de machine learning, como redes neuronales y técnicas de aprendizaje no supervisado, mencionado por (Gèron, 2023), mejora la detección de patrones sísmicos y la precisión de las predicciones de terremotos.

¹ (USGS, s.f.) Servicio Geológico de Estados Unidos.

² (INPRES) Instituto Nacional de Prevención Sísmica Argentina.

³ ONEMI (Servicio Nacional de Prevención y Respuesta ante D & Oficina Nacional de Emergencia del Ministerio del , s.f.)

⁴ SpaseWeatherLive (vzw-ORG, 2024), una organización sin fines de lucro de Bélgica para el estudio de astronomía, espacio, clima espacial, auroras

La optimización de la recolección de datos en tiempo real mediante el uso de sensores de alta precisión y tecnologías de monitoreo remoto permite una mejor representación de las condiciones pre sísmicas y contribuye a la mejora de los modelos predictivos. La combinación de datos históricos y en tiempo real en los modelos predictivos permite identificar tendencias y correlaciones más precisas, mejorando la capacidad de predicción a corto y largo plazo. Los datos de rayos cósmicos y el impacto sobre el planeta podrían ser utilizados para el estudio de correlaciones con eventos sísmicos.

El tratamiento de los sets de datos consistirá en un análisis cuantitativo, pero además se buscará la calidad de estos datos según los repositorios de las entidades que los ponen a disposición de estudio científico y académico.

La propuesta se desarrolla en apartados, en el primero se hace un recuento de falencias, necesidades y dificultades a sortear para llegar a un buen tratamiento del tema. En el apartado dos se describen las herramientas que se utilizan en el trabajo, la elección de precursores sísmicos y la relevancia a la hora de la predicción, la metodología, recolección, preparación de datos y análisis según la tipología de los data set de los precursores seleccionados. El desarrollo del tratamiento de los datos para el estudio se aborda en el tercer apartado donde se seleccionan los insumos necesarios para el modelo, se sectoriza concretamente el área geográfica de influencia e identifican variables precursoras y patrones que se adaptan de forma adecuada al modelo, se aplican los modelos predictivos, se optimizan los hiper parámetros y se evalúan los resultados obtenidos, por último, se detalla el desarrollo de aplicativo de alerta temprana.

1. El desafío de la predicción de sismos

La predicción precisa de terremotos sigue siendo un desafío importante debido a la complejidad de los procesos tectónicos y la interacción de múltiples factores geofísicos. Este trabajo pretende estudiar cómo se pueden mejorar los modelos predictivos de terremotos mediante la integración de datos multidisciplinarios y el uso de técnicas de modelado y *machine learning* para anticipar de manera más precisa la ocurrencia, magnitud y localización de los eventos sísmicos.

1.1. Falencias en modelos tradicionales

Los modelos predictivos actuales tienen limitaciones significativas en términos de precisión y confiabilidad, lo que impide la anticipación efectiva de eventos sísmicos. Esta falta de precisión puede llevar a una preparación inadecuada y una respuesta ineficaz ante desastres,

umentando así la vulnerabilidad de las comunidades. Algunas limitaciones se mencionan a continuación:

- Los modelos de predicción sísmica tradicionales se basan en análisis históricos de patrones de actividad sísmica y en la observación de precursores sísmicos, como variaciones en la actividad sísmica menor, cambios en el nivel del agua subterránea y anomalías en el comportamiento de los animales (Galban Rodriguez, pág. 41). Sin embargo, estos métodos han demostrado tener limitaciones significativas.
- Datos históricos insuficientes: la historia registrada de terremotos es relativamente corta en comparación con los ciclos de vida de las fallas tectónicas, lo que limita la cantidad de datos disponibles para el análisis.
- Falta de precursores claros: los precursores sísmicos no siempre se presentan de manera consistente antes de un terremoto, lo que dificulta la identificación de patrones fiables.
- Complejidad de las interacciones geofísicas: los procesos tectónicos son extremadamente complejos y están influenciados por múltiples factores, lo que complica la creación de modelos precisos.

Para superar estas limitaciones, es esencial integrar datos provenientes de diversas disciplinas.

- Geofísica: datos de sismómetros, GPS y satélites para monitorear deformaciones en la corteza terrestre como lo expresa Tapia Hernández (2013, pág. 5).
- Geología: estudios de la historia y el comportamiento de las fallas tectónicas.
- Hidrología: observación de cambios en los niveles de agua subterránea que pueden preceder a eventos sísmicos (Savarensky & Nersesov, pág. 81).
- Atmosférica: monitoreo de variaciones en la ionosfera que pueden estar relacionadas con actividad sísmica.
- Astronomía: correlación de movimientos telúricos con anomalías en los rayos cósmicos detectados en los distintos observatorios del mundo.
- Tecnología de Información: uso de bases de datos y herramientas de big data para almacenar y analizar grandes volúmenes de información.

1.2. Herramientas propuestas

Las técnicas de modelado avanzado y machine learning ofrecen oportunidades para mejorar la predicción de terremotos. Se propone utilizar las herramientas que se mencionan a continuación:

- Redes Neuronales Artificiales (ANN): permiten entrenar modelos con grandes conjuntos de datos para identificar patrones complejos no lineales en los precursores sísmicos.
- Modelos basados en Árboles de Decisión: son eficaces para manejar datos de alta dimensionalidad y detectar interacciones complejas entre variables.
- Modelos espacio temporales: permiten analizar la distribución espacial y temporal de la actividad sísmica y predecir la probabilidad de futuros eventos.
- Análisis de series temporales: permiten detectar tendencias y patrones recurrentes en la actividad sísmica a lo largo del tiempo.

1.3. Estudios preliminares de precursores externos

El estado del conocimiento sobre la predicción de terremotos está en un punto de inflexión, con la integración de tecnologías avanzadas de análisis de datos ofreciendo nuevas oportunidades para mejorar la precisión de las predicciones. La exploración de la correlación entre terremotos y rayos cósmicos representa una frontera emocionante, aunque aún incierta, en la investigación sísmica. La combinación de ambas líneas de investigación podría llevar a avances significativos en nuestra capacidad para anticipar y mitigar el impacto de los terremotos en el futuro.

Estos fenómenos naturales extra planetarios han evidenciado una correlación entre terremotos y rayos cósmicos de cierta energía e intensidad.

Los rayos cósmicos son partículas de alta energía que provienen del espacio exterior y bombardean la tierra. Algunos estudios han sugerido que estas partículas pueden influir en la actividad sísmica, posiblemente mediante la ionización de la atmósfera y la afectación de las cargas eléctricas en la corteza terrestre (GIL, 2024).

En otros estudios preliminares han observado correlaciones entre la incidencia de rayos cósmicos y la ocurrencia de terremotos, especialmente en zonas con alta actividad sísmica (Zamora, 2024). Estas observaciones sugieren que los rayos cósmicos podrían actuar como un desencadenante adicional en condiciones geológicas ya inestables.

Modelos teóricos han sido desarrollados para explicar cómo la ionización causada por rayos cósmicos podría inducir tensiones en la corteza terrestre. Estos modelos sugieren mecanismos como el aumento de la presión en fluidos subterráneos o la alteración de las cargas eléctricas en las fallas geológicas.

El estudio y aplicación de la correlación entre rayos cósmicos y terremotos es aún controversial y requiere más investigación para validarse de manera concluyente. Los

críticos argumentan que las correlaciones observadas podrían ser coincidencias estadísticas y que los mecanismos propuestos necesitan ser validados con más datos empíricos y experimentales.

Si se confirma una correlación significativa, la integración de datos de rayos cósmicos en los modelos de predicción de terremotos podría ofrecer una nueva dimensión en la detección de precursores sísmicos. Esto podría complementar las técnicas tradicionales y mejorar la capacidad de anticipar eventos sísmicos.

La inspiración para la investigación sobre los posibles efectos precursores de terremotos en los datos de rayos cósmicos que precede a este artículo se origina en la investigación realizada después del devastador terremoto de magnitud 8,8 en Chile, en 2010. Los resultados más intrigantes relacionados solo con este terremoto en particular incluyen anomalías ionosféricas por encima de la región del terremoto (Piša et al., 2010), fluctuaciones geomagnéticas en una ubicación distante (Romanova et al., 2015) y variaciones inusuales en las tasas de detección de radiación cósmica secundaria (página web pública de clima espacial del Observatorio Pierre Auger), todas precediendo al terremoto por diferentes períodos de tiempo: 15 días, 3 días y $\frac{1}{3}$ de día, respectivamente. El último resultado, es decir, la inusual tasa de rayos cósmicos secundarios, fue registrado por el Observatorio Pierre Auger (Auger), la mayor infraestructura de rayos cósmicos, dedicada principalmente a la investigación relacionada con los rayos cósmicos de energía ultra alta, pero que también ofrece oportunidades interdisciplinarias como los estudios del clima espacial con sus datos de escalador (página web pública de clima espacial del Observatorio Pierre Auger; The Pierre Auger colaborativo, 2011). El sitio Auger está ubicado en Argentina, a ~ 500 km del epicentro del terremoto chileno, por lo que es un buen lugar candidato para investigar la posible conexión entre los flujos de rayos cósmicos secundarios y este evento sísmico en particular. Si bien los estudios de Auger sobre el gran terremoto chileno no se publicaron, desencadenaron un interés a largo plazo difundido dentro de la comunidad de rayos cósmicos, lo que resultó en la reactivación de la investigación relacionada en el marco de la agenda

científica del Observatorio de Rayos Cósmicos Extremadamente Distribuido⁵. (Homola, 2023, pág. 03)

Esta inspiración mencionada por el Dr. Priotr Homola fue dada por el chileno Jilberto Zamora, doctor en ciencias físicas, quien estuvo en el momento del sismo ocurrido en Chile en 2010 y comenzó a pensar en la influencia que podía tener el cosmos en los movimientos terrestres (Zamora, 2024).

2. Metodología aplicada

Para abordar la predicción de terremotos mediante el análisis de datos en América del Sur, se propone una metodología estructurada en varias etapas, integrando datos multidisciplinarios y aplicando técnicas avanzadas de modelado y machine learning.

2.1. Recolección y preparación de datos

Se recopilarán datos de terremotos ocurridos en América del Sur entre 2004 y 2024, desde los repositorios de USGS (*United States Geological Survey*); INPRES (Instituto Nacional de Prevención Sísmica, Argentina); ONEMI (Oficina Nacional de Emergencia del Ministerio del Interior y Seguridad Pública, Chile), BGSUK (*British Geological Survey*); Observatorio Pierre Auger, CREDO (Observatorios de Rayos Cósmicos Distribuidos) y SNE (Servicio Meteorológico Nacional).

Se realizará un proceso exhaustivo de limpieza para eliminar datos inconsistentes o incompletos y se normalizarán las diferentes fuentes de datos para asegurar la compatibilidad y coherencia en los análisis.

⁵ The inspiration for the investigation on the possible earthquake precursor effects in cosmic ray data that precedes this article originates in the research undertaken after the devastating M 8.8 earthquake in Chile, in 2010. The most intriguing results concerning only this particular earthquake include ionospheric anomalies above the earthquake region (Piša et al., 2010), geomagnetic fluctuations at a distant location (Romanova et al., 2015), and unusual variations of secondary cosmic radiation detection rates (Space Weather public web page of the Pierre Auger Observatory), all preceding the earthquake by different time periods: 15 days, 3 days, and $\frac{1}{3}$ day, respectively. The latter result, i.e. the unusual secondary cosmic ray rate, was recorded by the Pierre Auger Observatory (Auger), the largest cosmic ray infrastructure, dedicated mostly to research related to ultra-high energy cosmic rays, but also offering interdisciplinary opportunities such as space weather studies with their scaler data (Space Weather public web page of the Pierre Auger Observatory; The Pierre Auger collaboration, 2011). The Auger site is located in Argentina, ~500 km away from the Chilean earthquake epicenter, thus a good candidate location to probe the possible connection between the secondary cosmic ray fluxes and this particular seismic event. While the Auger studies concerning the big Chilean earthquake were not published, they triggered a longer term interest diffused within the cosmic ray community, resulting in reviving the related research under the scientific agenda of the Cosmic Ray Extremely Distributed Observatory

2.2. Análisis exploratorio de datos

Se crearán tres sets de datos terremotos, tormentas solares y rayos cósmicos. Se tomará la magnitud de los eventos sísmicos como variable predictora general, para la relación entre precursores la variable IMF_B (intensidad de campo magnético) para tormentas solares y energía máxima de impacto de muón en rayos cósmicos.

Se utilizarán herramientas como gráficos de dispersión, histogramas, mapas de calor y otros para identificar patrones, tendencias y relaciones entre las variables.

Se calcularán las correlaciones entre las distintas variables para identificar posibles precursores sísmicos.

2.3. Desarrollo de modelo predictivo

El enfoque que se utilizara para el desarrollo del modelo predictivo de movimientos telúricos consta de 4 etapas.

Exploración de modelos de machine learning que mejor se adaptan:

- Redes Neuronales Artificiales (ANN) y Long Short-Term Memory (LSTM).
- Modelos basados en Árboles de Decisión.
- Modelos espaciotemporales.
- Análisis de series temporales.

Entrenamiento y validación:

- Los modelos seleccionados serán entrenados utilizando datos históricos de actividad sísmica.
- Se empleará validación cruzada para evaluar la precisión, capacidad predictiva y evitar problemas de sobreajuste.
- Se aplicarán técnicas, como la regularización y el ajuste de hiper parámetros para optimizar el rendimiento de los modelos.

Evaluación del modelo:

- El modelo será probado con un conjunto de datos independiente para evaluar métricas como precisión, sensibilidad y especificidad en la predicción de la ocurrencia, magnitud y localización de terremotos.
- Los resultados se compararán con eventos sísmicos reales para identificar fortalezas, debilidades y posibles ajustes necesarios.

Implementación del sistema de alerta temprana:

- En base a los resultados de la evaluación de los modelos, se diseñará un sistema de alerta temprana que permita a las autoridades de la Dirección de Defensa Civil de la

Provincia de Mendoza emitir advertencias con suficiente antelación para movilizar recursos y ejecutar planes de emergencia.

- Este sistema incluirá la integración de datos de monitoreo en tiempo real, lo que permitirá actualizar continuamente el modelo y mejorar la precisión de las predicciones.

3. Desarrollo de la propuesta metodológica, insumos necesarios para el desarrollo del modelo

El estudio de datos se nutrirá de características clave para el modelo y estas incluirán:

Datos geoespaciales de terremotos (latitud, longitud, profundidad), que publica el Instituto Nacional de Prevención Sísmica (INPRES, 2024).

Información geológica y tectónica (fallas, placas), principalmente del noroeste argentino, extraído de IRIS, Instituciones de Investigación Incorporadas para la Sismología (Consortium, 2024)

Parámetros sísmicos históricos (magnitud, frecuencia, intensidad de aceleración), desde 2004 a 2024.

Datos geofísicos (movimiento de la corteza, patrones de estrés tectónico), tipo de fallas, tipo de movimiento.

Set de datos de distintos precursores, para este trabajo se limitará a datos meteorológicos, datos de magnitudes de variación de rayos cósmicos, registro de las 50 principales tormentas geomagnéticas para el periodo en estudio.

3.1. Origen de datos

Estos datos se recopilarán de registros de eventos históricos de sismos en América del sur, se hará un fraccionamiento cada dos años comenzando desde 2004 en adelante. Concomitantemente se obtienen datos de eventos, posibles precursores, en fechas cercanas a los movimientos telúricos de mayor intensidad. El estudio y almacenamiento de estos eventos precursores pertenecen a distintas disciplinas de la ciencia, tales como meteorología, agronomía (comportamiento animal), astrofísica, geología (Murillo y otros, 2023).

3.1.1. Descripción de área de estudio


El área de estudio se limitará a la zona de influencia de la falla de San Ramón ubicada en el centro de Chile que corre de norte a sur, entre las latitudes 29°20'48.1"S y 40°02'08.5"S, cuya influencia afecta a la región continental entre las mismas latitudes dentro del territorio argentino que comprenden las provincias de La Rioja, San Juan, Mendoza y Neuquén.

3.2. Identificación de patrones y precursores

Los elementos que componen los movimientos sísmicos son el hipocentro, epicentro, la falla geológica y las ondas sísmicas de puede ver en Figura-1.

El foco sísmico o hipocentro es un punto dentro de la corteza terrestre donde se ha producido la ruptura de la roca, la ubicación se determina mediante latitud, longitud y profundidad.

Figura-1 Elementos de movimientos telúricos.



Fuente: Museo de Ciencias de Puerto Rico (2024)


Epicentro es la proyección en la superficie terrestre del hipocentro.

Falla geológica es una fractura en la corteza terrestre en donde las masas de roca, corteza o placas tectónicas se han desplazado una respecto de la otra.

Onda sísmica está relacionada con la energía liberada desde el foco, físicamente son ondas de tipo elásticas que propaga la perturbación generando los movimientos de las placas tectónicas.

Los tipos de sismos que se producen en las zonas próximas a la cordillera de Los Andes, ver Figura -2, son por movimiento interplaca superficiales y de mayor magnitud, interplaca o corticales surgidos de movimiento de fallas geológicas internas a la plataforma continental suelen ser de mayor profundidad y menor intensidad o poder destructivo.

Figura - 2 Tipos de sismos en convergencia de placas tectónicas

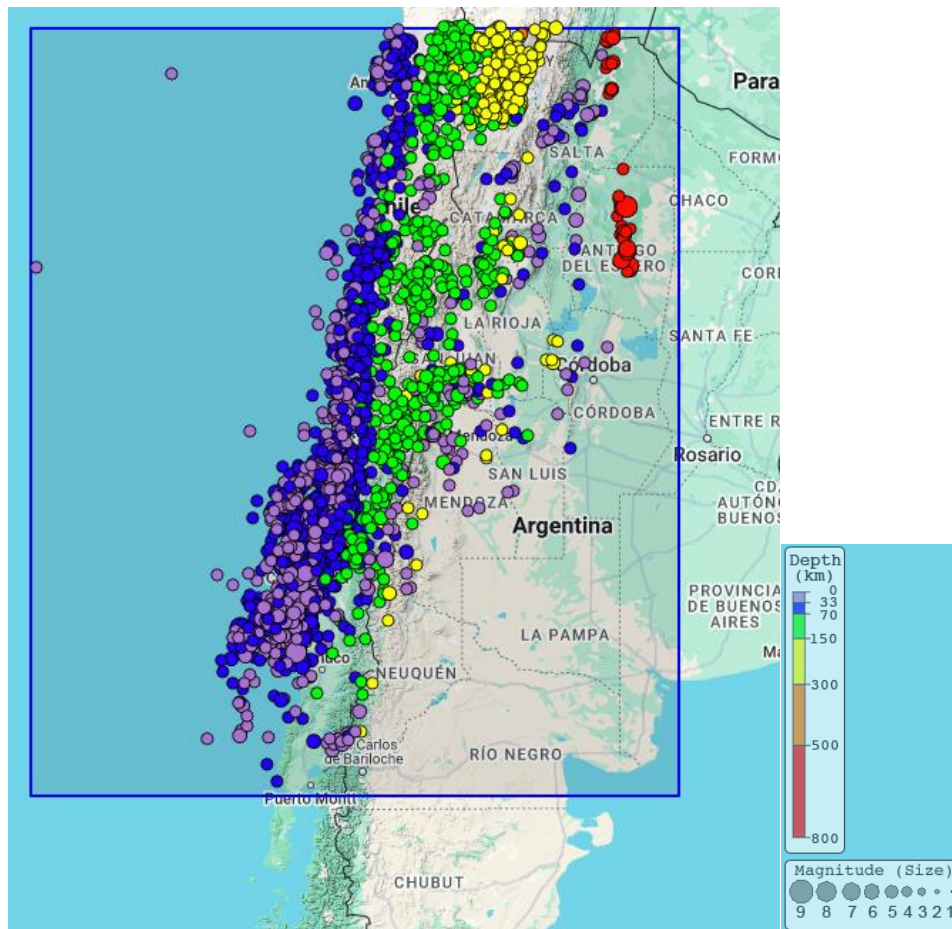


Fuente: Instituto Geofísico del Perú (Tavera, 2020, pág. 16)

3.2.1. Precursores que mejor se adaptan al modelo, creación de set de datos

Las variables de datos de movimientos sísmicos de la zona de estudio son la magnitud del terremoto en grados Richter, latitud, longitud, profundidad en kilómetros y el número de estaciones sísmicas que registraron el terremoto. Como precursor se toman los movimientos telúricos de menor magnitud y de mayor frecuencia de ocurrencia. En Figura-3 se puede observar la distribución geográfica de los sismos, cantidad y magnitud. La profundidad se mide en kilómetros, se muestra en colores y la magnitud en grados Richter por tamaño de los círculos.

Figura- 3 Zona de estudio



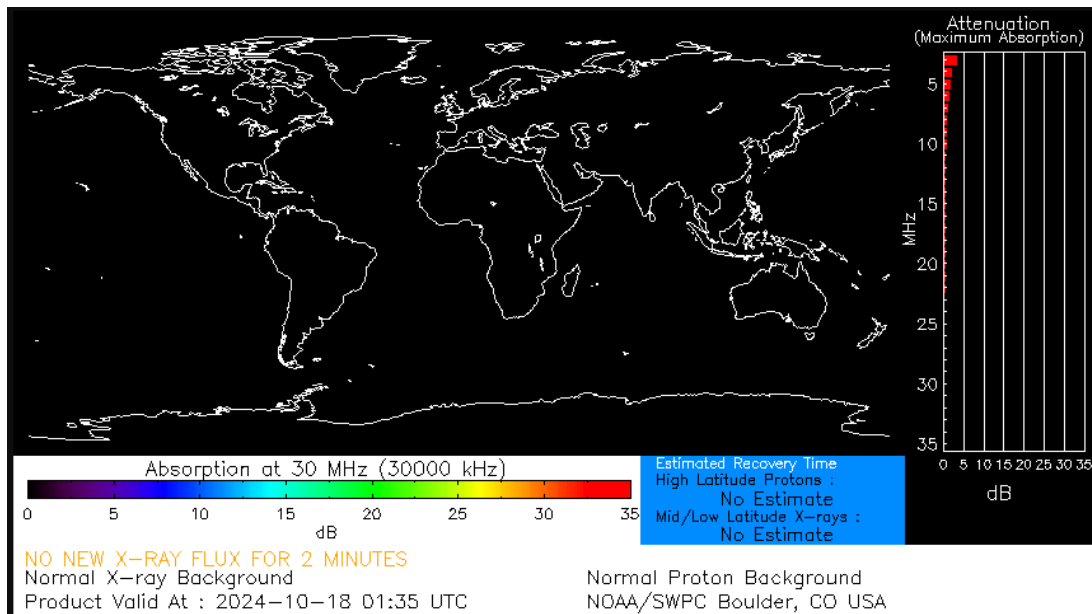
Fuente: IRIS (Consortium, 2024)

Para los sets de datos de precursores referidos a variación de los niveles de aguas subterráneas (aquabook, 2016), las variables significativas son los máximos y mínimos de cada cuenca acuífera en un periodo de tiempo de 10 años 2013 al 2023.

Para los datos meteorológicos se toman las variables temperatura máxima y presión atmosférica, de estos eventos de destacaran los *outliers* como sucesos significativos distintivos en periodos cercanos a eventos sísmicos tomando solo quince días antes del mismo.

Se tomarán los datos de tormentas geomagnéticas y solares, (USA.GOV, s.f.) y (Matzka y otros, spaceweatherlive, 2024) de los veinte días antes de la ocurrencia de terremotos de magnitud superior a los 5 grados Richter, las variables que se tomaran en cuentas son energía de partículas, nivel de flujo de partículas, índice de tiempo de tormenta de perturbación, viento solar, escala geomagnética, en Figura -3 se observa la absorción de protones en la tierra durante una tormenta solar leve de G3, índice de escala de tormenta geomagnética.

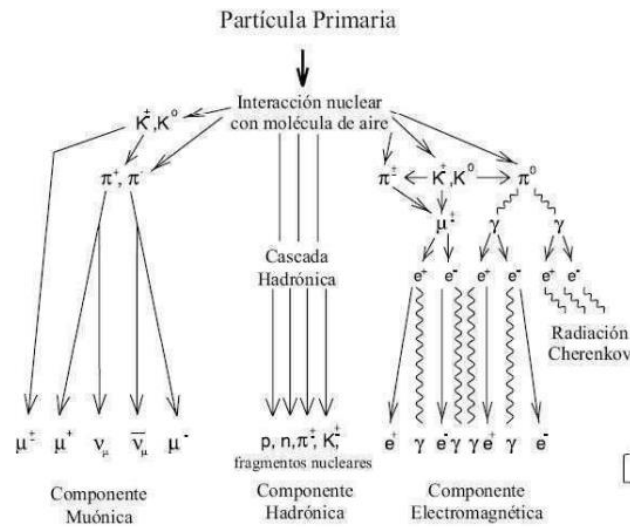
Figura -4 Absorción de protones en tierra provenientes del sol.



Fuente: Centro de predicción del clima espacial

Por último, se estudiará el fenómeno extra planetario de rayos cósmicos, en Figura- 5 se observa un esquema de lluvia de partículas, tomando como precursor principal la variación de energía intensidad y cantidad de impacto del muón.

Figura-5 Partículas extra planetarias



Componentes de lluvia de partículas generadas por un rayo cósmico Fuente: (Tamashiro, 2010, pág. 48)

3.2.2. Establecimiento y definición de las variables para cada precursor

Para la determinación de correlación entre el suceso de temblores y la variabilidad de las napas freáticas y aguas subterráneas en la zona en cuestión se estudia el comportamiento de las variables máximo, mínimo nivel de agua en cada cuenca acuífera y fechas de ocurrencia.

De la base de datos de sismos Earthquake se toman las variables fecha, intensidad en escala Richter la cual es logarítmica, epicentro en coordenadas.

Los datos de tormentas geomagnéticas poseen como variables la escala de valoración que va de G1 a G5 de (menor a mayor intensidad) y los índices Kp que van del 0 al 9 (es un excelente indicador de perturbaciones en el campo magnético de la Tierra); la frecuencia media donde un ciclo equivale a 11 años y la velocidad en kilómetros por segundo (Matzka y otros, SpaceWeatherlive, 2024), índice Ap. que indica la actividad magnética planetaria. Por lo que se toman como variables independientes campo magnético interplanetario, velocidad del plasma solar.

Las variables de interés en los data set de rayos cósmicos son energía máxima de muón, georreferencia GPS, fecha de lluvia de rayos cósmicos con mayor incidencia sobre los detectores.

3.2.2.1. Variables estáticas

Estas variables no cambian con el tiempo o se mantienen constantes para un evento específico. En el contexto de los terremotos, son propiedades geográficas o inherentes a un evento:

- Terremotos:
 - Lat, (Latitud): Posición fija en la Tierra.
 - Lon, (Longitud): Posición fija en la Tierra.
 - Depth, (Profundidad): Profundidad del hipocentro (se mantiene constante para cada terremoto específico).
 - Región: Región donde ocurre el evento. Es una clasificación estática basada en latitud y longitud.
- Tormentas solares:
 - Lat, (Latitud): Posición fija en la Tierra.
 - Lon, (Longitud): Posición fija en la Tierra.
 - GPS Coordenadas galácticas.
- Rayos cósmicos:
 - Lat, (Latitud): Posición fija en la Tierra.
 - Lon, (Longitud): Posición fija en la Tierra.
 - GPS Coordenadas galácticas.

3.2.2.2. Variables dinámicas

Estas variables cambian con el tiempo y representan eventos o magnitudes observadas en distintos momentos:

- Terremotos:
 - Mag, (Magnitud): Es la fuerza del terremoto, que varía según el evento.
 - Timestamp, (Marca temporal): Momento en que ocurre el terremoto.
 - Fecha, (Fecha y hora del terremoto): Otra representación del tiempo.
 - riesgo: Nivel de riesgo asociado, que puede calcularse dinámicamente según los eventos y otras variables.
- Tormentas solares:
 - IMF_B: Es la magnitud del campo magnético interplanetario, que varía según el evento.
 - SW_Plasma: velocidad de viento solar medida en kilómetros por hora
 - Times Date, (Marca temporal): Momento en que ocurre la eyección solar.
- Rayos cósmicos:
 - SDEnergy, (Energía): máxima energía de muon, que varía según el evento.
 - Time, (Marca temporal): Momento en que ocurre evento.
 - Fecha, (Fecha y hora de lluvia): Otra representación del tiempo.

3.2.2.3. Variables Predictoras

Estas variables se utilizan como entrada para predecir una variable objetivo. Estos suelen ser dinámicos, pero también pueden incluir algunas estáticas si ayudan a mejorar las predicciones.

Predictores comunes:

- Mag, (Magnitud)
- Lat, (Latitud)
- Lon, (Longitud)
- Depth, (Profundidad)

3.2.2.4. Variables Objetivo

Son las variables por predecir

Predictores comunes:

- Mag, (Magnitud), escala de Richter
- Lat, (Latitud) y Lon, (Longitud), ubicación del evento
- Fechas, fecha del evento a predecir

En apéndice B se describen las variables de cada set de datos.

3.3. Modelos predictivos

Se seleccionaron modelos de ML (machine learning), en Figura-6 se muestra esquema de datos y modelos utilizados, Random Forest (RF), para predecir la magnitud de eventos sísmicos en función de múltiples variables, incluyendo la actividad de rayos cósmicos (Gèron, 2023). Este modelo facilita la interpretación de los resultados, ya que proporciona una visualización clara de cómo se toman las decisiones. Para modelar la relación lineal entre una variable dependiente (en este caso, la magnitud del terremoto) y una o más variables independientes (latitud, longitud, profundidad), *LinearRegresion* (LR).

Gradient Boosting Models (GBM), para reforzar de forma adecuada la predicción al no existir una correlación fuerte entre las variables. Se trabajará con Long Short-Term Memory (LSTM) que es un tipo de red neuronal recurrente (RNN) especialmente diseñada para manejar datos secuenciales y series temporales. Su estructura permite aplicar ML a largo plazo, lo hace ideal para aplicaciones donde los eventos anteriores en la secuencia pueden influir en los eventos futuros, como en predicción de series temporales. Redes neuronales artificiales (ANN), se utilizará para identificar patrones complejos en los conjuntos de datos. Se entrena con datos históricos de terremotos y rayos cósmicos para reconocer correlaciones que no son evidentes a simple vista. Este enfoque permite modelar relaciones no lineales entre las variables, mejorando así la precisión de las predicciones.

Figura -6 Tipo de datos y ML utilizados

Variables Terremotos	<ul style="list-style-type: none"> Fecha Magnitud Latitud Longitud Profundidad 	Serie temporal	LSTM, GridSearchCV, Linear Regression <i>gradient boosting trees</i> ,
Variables Aguas Subterráneas	<ul style="list-style-type: none"> Fecha Máximos Mínimos 	Serie temporal	<i>random forest, gradient boosting trees</i>
Variables Meteorológicas	<ul style="list-style-type: none"> Fecha Temperatura máxima Evento 	Serie temporal	<i>gradient boosting trees</i>
Variables Tormentas Geomagnéticas	<ul style="list-style-type: none"> Fecha Índice Kp. Índice Ap. Índice G 	Serie temporal	LSTM , Random Forest, XGBoost
Variables Rayos Cósmicos	<ul style="list-style-type: none"> Fecha Energía máxima muon Latitud Longitud 	Serie temporal	LSTM , Random Forest, XGBoost

Fuente: elaboración propia

3.3.1. Procedimientos

Se tomo el data set de terremotos, ver Tabla-1, con una muestra de 11.310 registros y 22 columnas, acotado desde 2004 al 2024 para la zona de estudio. Se entrenaron los modelos, previa optimización de los hiper parámetros, en la tabla-1 se muestran los resultados obtenidos.

A continuación, se preparó la base de datos de terremotos para comparar y encontrar las relaciones con precursor Tormentas Geomagnéticas, con una muestra de 1.656 registros y 8 columnas, tomando el lapso 1-01-2010 a 10-03-2010, correspondiente a periodo de tiempo en que ocurrió uno de los sismos de mayor magnitud registrado con epicentro en Chile. Se toman como variables independientes `IMF_B_Total_nT` (campo magnético interplanetario), `SW_Plasma_Speed_km/s` (velocidad del plasma solar), `depth`, `day_of_year` y la variable dependiente `Mag` que es la magnitud de los sismos.

El ultimo data set en ser analizado es el de Rayos Cósmicos con una muestra inicial de 24.319 registros y 79 columnas para comprobar la posible influencia sobre el planeta como precursor de terremotos en aquellas lluvias de muones de alta energía.

Tabla-1 Muestras de datos utilizados

Set de datos	Cantidad de muestras
Terremotos	11.310 x 22
Tormentas geomagnéticas	1.656 x 8
Rayos cósmicos	24.319 x 79
Rayos cósmicos > Energía	17 x 6

Fuente: elaboración propia

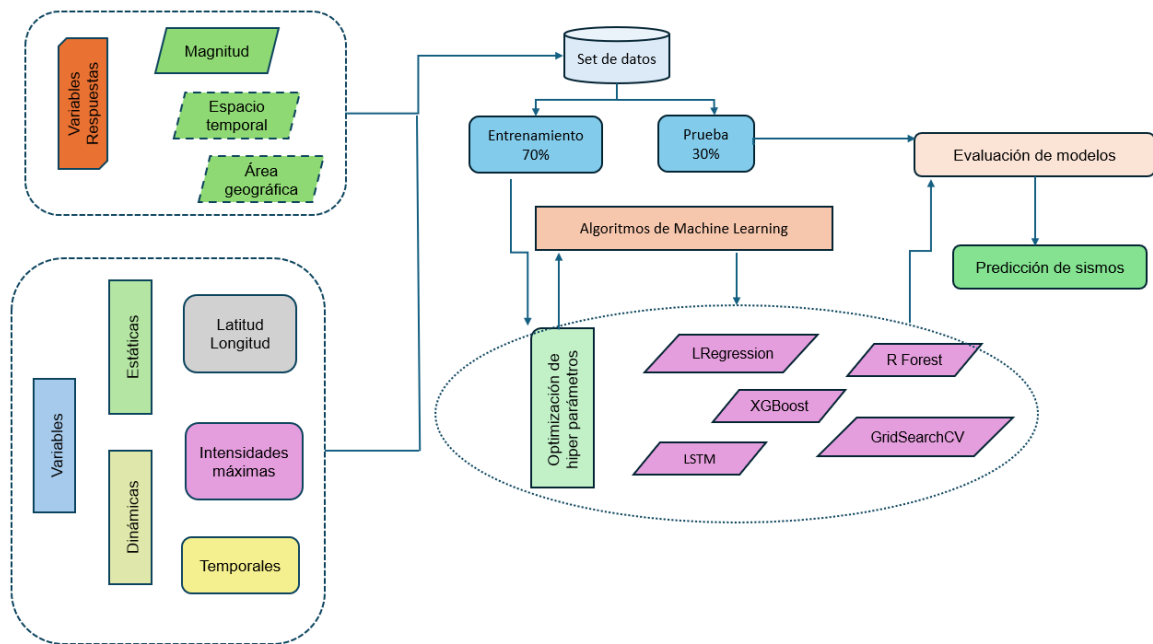
3.3.2. Entrenamiento y validación de los modelos

En esta etapa se realizó el entrenamiento de los modelos:

- Se utilizó regresión lineal múltiple para modelar la relación entre la magnitud del terremoto y la latitud, longitud, profundidad. El modelo de regresión lineal múltiple supone que existe una relación lineal entre la variable dependiente y cada una de las variables independientes y que la relación es aditiva, el efecto de cada variable independiente sobre la variable dependiente es independiente de las otras variables independientes.
- Se entrenaron modelos de RF y XGBost, para cada modelo se realizó optimización de los hiper parámetros, con la finalidad de modificar positivamente el rendimiento de los modelos y lograr resultados óptimos. Encontrando la combinación optima de valores para el ajuste.
- Para el análisis y entrenamiento de los datos de terremotos históricos se creó el modelo LSTM en dos capas y capas de *Dropout* para evitar el sobreajuste. Se realiza la predicción con datos de prueba en 70% y se valida con el 30%.

Se realizó la optimización de los hiper parámetros con algoritmo de búsqueda de cuadrícula GridSearchCV, este proporciona una técnica de validación cruzada incluida en el paquete de scikit learn. Las métricas de evaluación son error absoluto MAE, error cuadrático medio RMSE y R^2 En figura-7 se muestra esquema para evaluar la predicción de sismos.

Figura-7 Esquema de trabajo



Fuente: elaboración propia

3.3.3. Evaluación

En primer lugar, se ajustó un modelo de *LinearRegression* a la base de datos de terremotos con la premisa de saber si es posible predecir la magnitud de un nuevo terremoto teniendo en cuenta su latitud, longitud, profundidad. Esto puede ser útil para el monitoreo de terremotos y los sistemas de alerta temprana, así como para comprender las causas subyacentes de los terremotos y mejorar nuestra capacidad para predecirlos en el futuro.

Luego se aplicó *Random Forest* para predecir la magnitud de los terremotos en función de su latitud, longitud, profundidad y número de estaciones de monitoreo. Se dividieron los datos en conjuntos de entrenamiento y prueba, se entrenó el modelo de *Random Forest* con los datos de entrenamiento y se evaluó su desempeño con los datos de prueba utilizando la métrica del error cuadrático medio (MSE) y la puntuación R-cuadrado (R²).

Con la implementación de XGBoost (Extreme Gradient Boosting) se logra precisión al reducir errores por iteración, optimiza el modelo con técnica de reducción de gradiente, se logra gestionar valores nulos o faltantes de manera eficiente al aprender automáticamente la mejor forma de manejarlos en los nodos del árbol.

Se aplicó de la red neuronal LSTM (Long Short-Term Memory), ya que tiene la capacidad de aprender dependencias a largo plazo, lo que lo hace especialmente adecuado para problemas donde la información del pasado afecta el futuro. Posee la capacidad de aprender

relaciones entre múltiples variables predictoras y producir múltiples salidas, como magnitud o localización.

Para encontrar los mejores hiper parámetros del modelo se utilizó GridSearchCV, utiliza validación cruzada para evaluar el rendimiento del modelo para cada conjunto de hiper parámetros, lo que ayuda a identificar la mejor configuración para el modelo. Esta herramienta tiene la desventaja de requerir gran hardware.

3.4. Resultados y comparativos

Se calcula para cada modelo y cada set de datos

El error absoluto MAE para saber el tamaño promedio de los errores en las predicciones del modelo.

El error cuadrático medio *MSE* desviación estándar de las diferencias entre los valores predichos por el modelo y los valores observados; la raíz cuadrada de MSE, RMSE para obtener una medida de error que indica la desviación estándar de los errores del modelo. El coeficiente de determinación R^2 la proporción de la varianza total de la variable de interés que se explica por el modelo. R^2 varía entre 0 y 1, que cuanto más cerca está de 1, mejor es el ajuste del modelo. Para el data set de terremotos, haciendo análisis en el periodo de tiempo establecido y solo para la zona en estudio se toman los microsismos, siendo estos de magnitud inferior a 4,5 grados Richter los resultados se muestran en Tabla-2.

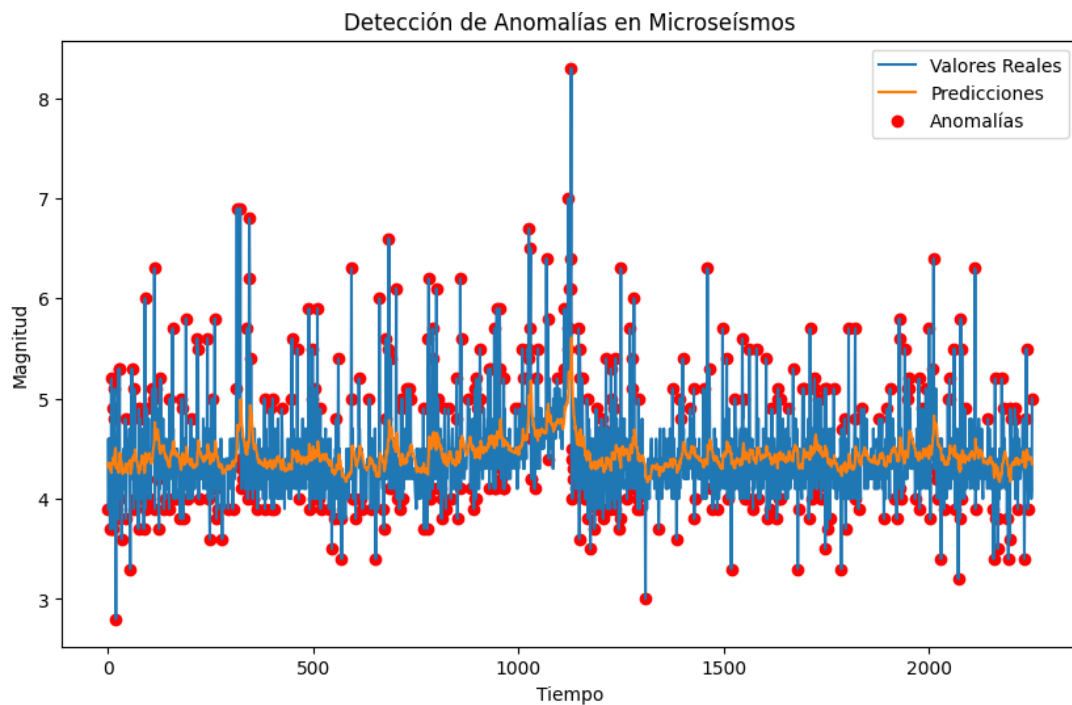
Tablas-2 - Comparativa de resultados sismos

Terremotos	MAE	MSE	R^2	RMSE
LR	-	0.53	0.05	0.58
<i>XGBoost</i>	0.50	0.41	-	0.64
LSTM	0,30	0,17	-	0.42
Hiper parámetros/GridSearchCV	-	0.58	0.05	-

Fuente: Elaboración propia

Un MAE bajo indica que el modelo tiene un buen desempeño al estimar magnitudes, el MSE da una diferencia entre valores predichos y reales baja de 0.17, el RMSE es de 0.42 indicando un nivel de error bajo, desvío de 0.42 unidades de magnitud sísmica. El R^2 de 0.05 sugiere que los modelo LR y el GridSearchCV, apenas son mejores que un modelo que simplemente predice la media en la magnitud de los sismos.

Figura –8 Anomalías y predicción con microsismos.



Fuente: Elaboración propia

El ajuste de hiper parámetros se realiza con *GridSearchCV*, armando un modelo con *Keras RwgessorWrapper*, en figura-8 se muestra grafico de predicción en color naranja, donde se observa el seguimiento temporal respecto de valores reales.

Para el conjunto de datos de terremotos y Tormentas Geomagnéticas, se realiza el análisis en el periodo de tiempo establecido y solo para la zona en estudio, los resultados se observan en Tabla-3, donde se muestran las métricas para los tres modelos y las métricas luego de realizar el ajuste de hiper parámetros.

Tabla -3 Comparativa de resultados tormentas geomagnéticas

Tormentas Geomagnéticas Vs Terremotos	MSE	MSE ajustado	R ²	R ² ajustado	cross-validation	RMSE ajustado	Accuracy atado a tolerancia ± 0.5
RF	0.18	0.18	0.75	0.77	-0.68	0.31	89.60%
XGBoost	0.38	0.23	0.42	0.68	-0.61	0.37	89.60%
LSTM	0.40	0.4	-0.08	-0.08			

Fuente: Elaboración propia


En los resultados del modelo *RandomForest* el MSE puede considerarse bastante bajo dependiendo de la escala de magnitud de los terremotos (que típicamente va de 1 a 9 en la escala de Richter), lo que sugiere que el modelo tiene un buen rendimiento en términos de precisión.

En RF el R^2 de la variabilidad en la magnitud de los terremotos puede ser explicada por las tormentas geomagnéticas y las otras variables utilizadas en el modelo, 0.75% es un buen nivel de ajuste, lo que indica que el modelo tiene un rendimiento sólido para capturar la relación entre las tormentas geomagnéticas y los terremotos. Se puede observar en la Figura -9 la curva de dispersión donde existen eventos alineados, pero también hay puntos encima de la línea de referencia $x=y$, donde el modelo sobreestima la magnitud y por debajo de la línea donde el modelo subestima la magnitud.

Para el modelo XGBoost los valores de MSE con el ajuste de hiper parámetros dieron métricas menores mejorando la precisión respecto de valor sin ajuste.

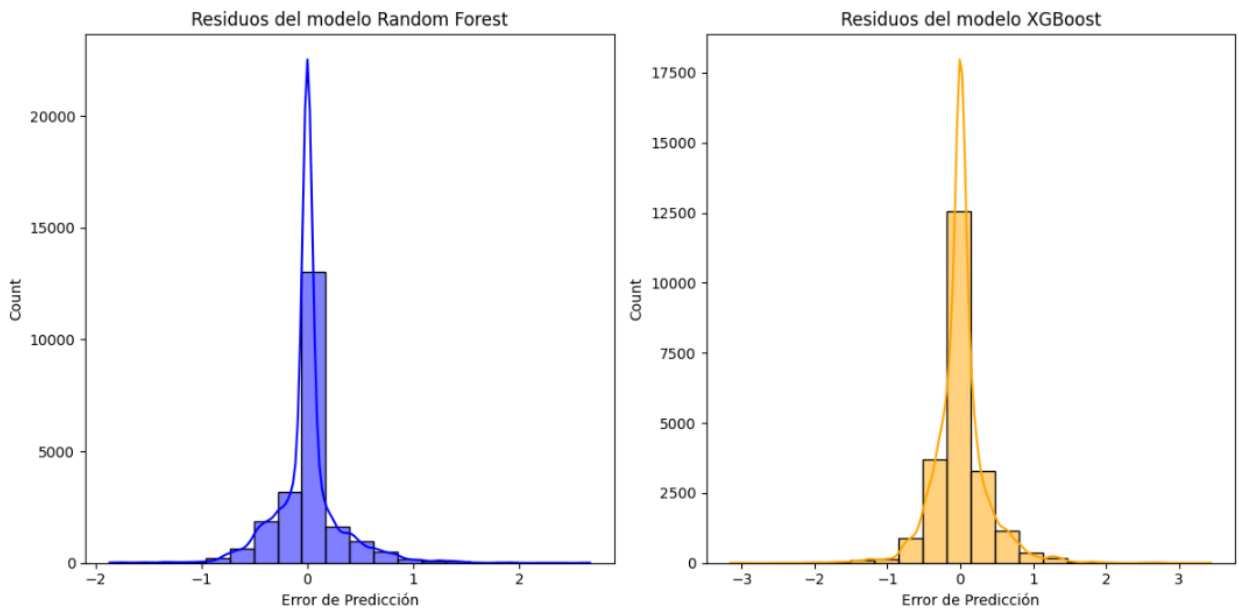
Del análisis de datos de tormentas geomagnéticas versus terremotos se puede decir que existe una elevada correlación entre las variables independientes y la variable dependiente magnitud. Sin embargo, el 25% restante de la variabilidad no explicada por el modelo podría deberse a otros factores no incluidos en el análisis, como la tectónica de placas, variaciones locales en la geología, etc.

Figura-9 Dispersión de variable magnitud



Fuente: Elaboración propia


Figura-10 comparación residuos o errores de Random Forest vs XGBoost



Fuente: Elaboración propia

En Figura-10 se observa que el modelo *XGBoost* tiene mejor calidad tiene ausencia de sesgos sistémicos y una buena predicción en promedio, por lo que se puede decir que el modelo captura correctamente la relación entre las variables independientes y las dependientes.


Figura – 11 Dispersión comparación de *Random Forest* vs *XGBoost*



Fuente: Elaboración propia

La comparación en grafico de dispersión de los modelos *Random Forest* y *XGBoost*, se observa en figura-11, siendo *XGBoost* el de mejor rendimiento.

Figura –12 Modelo real vs predicción

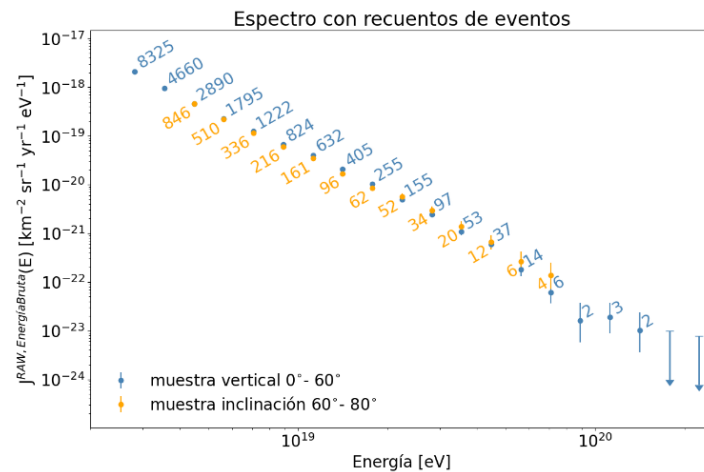


Fuente: Elaboración propia

En la figura -12 se puede observar que para el modelo LSTM (Tormentas Geomagnéticas vs Sismos), curva de frecuencia de eventos sufre un achatamiento considerable respecto de la curva observada en el modelo LSTM aplicado a microsismos, por lo que se puede estimar que tomar como precursores los mismos eventos sísmicos de menor magnitud sucedidos antes del evento mayo es un mejor predictor.

Para el data set de Rayos cósmicos, (se muestra en Figura-11 espectro de energía) y el de terremotos, haciendo análisis en el periodo de tiempo establecido y solo para la zona en estudio, se unen los data frame, haciendo conversiones necesarias para que las medidas de tiempo coincidan, ya que el set de rayos cósmicos tiene mediciones de frecuencia en GPS-time los resultados se muestran en Tabla-4.

Figura -13 Espectro de energía eventos rayos cósmicos



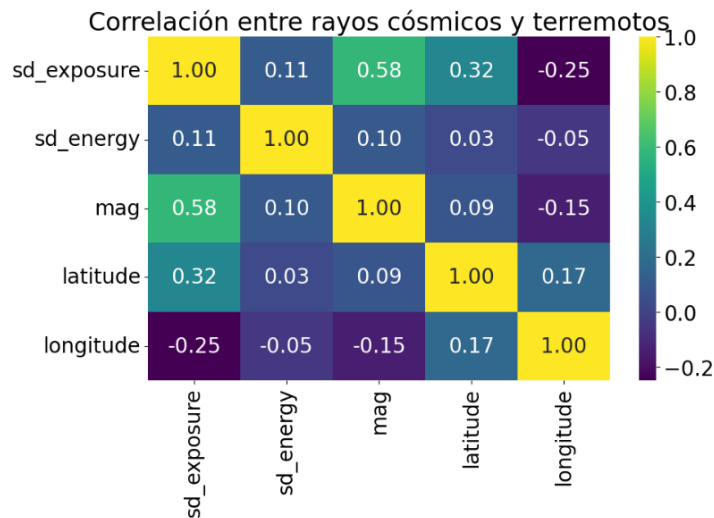
Fuente: Elaboración propia

Tabla -4 Comparativa de resultados rayos cósmicos

Rayos Cósmicos vs terremotos	MSE	R ²	MSE optimizado	R ² optimizado
RF “Mag”	0.27	0.44	-	-
RF “lat”	2.33	0.26	-	-
RF “lon”	0.42	0.62	-	-
RL	0,8	0,2	-	-
XGBoost	1.35	0.29		
Hiper parámetros/GridSearchCV	-	-	1.31	0.31


Fuente: Elaboración propia

Figura-14 Correlación



Fuente: Elaboración propia

Figura-15 Comparación predichos vs reales




Fuente: Elaboración propia

La correlación de las variables significativas de terremotos y rayos cósmicos es débil se puede visualizar en figura-14.

En la figura-15 se observa que para valores bajos de magnitud los puntos se agrupan alrededor de esta línea, significa que el modelo de XGBoost está haciendo predicciones muy precisas, ya que, para esos casos, valor real \approx valor predicho. Pero El coeficiente de determinación (R^2) es muy lejano de 1, lo que indica una correlación débil entre los valores reales y los predichos.

Figura-16 Comparación predichos vs reales



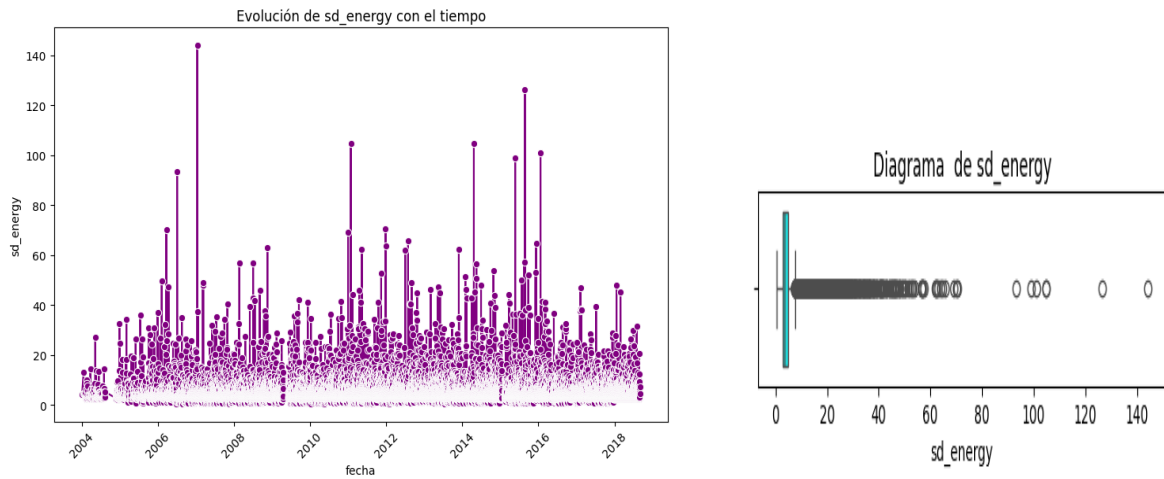
Fuente: Elaboración propia

Luego de hacer una limpieza de variables y mejorar hiper parámetros se logra un gráfico de comparación para XGBoost, se ve en figura-16, que indica una mejora significativa en los valores de predicción.

El set de datos de rayos cósmicos obtenido de datos abiertos Pierre Auger, necesita gran cantidad de consideraciones y mejora para poder ser utilizado. Aún no se pudo descartar la correlación o no de las lluvias de muones de alta energía con la ocurrencia de terremotos.

Para mejorar el análisis de relación de eventos sísmicos contra eventos de mayor energía de rayos cósmicos se extrae de data set rayos cósmicos solo los eventos por fecha de lluvia de alta energía de muones y se contrasta con el data set de terremotos para observar alguna relación en fechas cercanas a los movimientos sísmicos de magnitudes superiores a 5,5 grados Richter.

Figura -17 a y b Energía de muón




Fuente: Elaboración propia

En las Figura-17 a y b se ven los picos de mayor energía de impacto en la superficie terrestre de la partícula elemental en el periodo de interés.


Luego de aislar los eventos de energía “SD_Energy” mayores a 60 se realiza una búsqueda de eventos sísmicos de magnitud “mag” mayor a 5.5 grados R, estos eventos se visualizan en figura-18 a

Figura -18 a eventos relacionados



Fuente: Elaboración propia

Figura-18 b eventos relacionados



Fuente: Elaboración propia

En la figura -18 b se observa otro diagrama de dispersión con parámetros menos ajustados de sismos con magnitudes mayores a 4.5 grados y eventos de alta energía muonica de más de 60 Ev (electrón volt), se puede ver relación entre los eventos más significativos como el terremoto de Chile en febrero de 2010 y gran lluvia de rayos cósmicos registrada 40 días antes del sismo.

4. Aplicativo sistema de alerta temprana

Para aportar una herramienta de prevención sísmica a la dirección de Defensa Civil y los brigadistas de la Provincia de Mendoza, se implementa el desarrollo técnico del aplicativo web de aviso de posible movimiento de pacas tectónicas. Para su implementación se utiliza en modelo predictivo XGBoost (Extreme Gradient Boosting) con el cual se logra mayor precisión al reducir errores por iteración optimizando el modelo con técnica de reducción de gradiente, véase apartado 3.4. Resultados y comparativos.

El proceso de desarrollo del aplicativo contas de las siguientes actividades:

- Se recopilan datos accediendo a USGS (Servicio Geológico de Estados Unidos), este set de datos es robusto y confiable para alimentar el modelo, la extracción se limita solo a la zona de en estudio y se toman 30 días para atrás desde el momento que se

aplica el software, El precursor tomado es la secuencia de microsismos (movimientos telúricos menores a 4 en escala de Richter también llamados enjambre de sismos), estos datos se componen de latitud, longitud, magnitud, profundidad y fecha de sismos menores a 5 grados en escala Richter.

- Luego de la depuración de datos nulos o erróneos se calcula la densidad de eventos en la zona de estudio, se hace el cálculo de energía liberada por evento y magnitud.
- Se aplica modelo de clasificación binaria XGBoost, se entrena el modelo y se guarda el modelo entrenado.
- Se desarrolla una Interfaz de usuario sencilla para la visualización accesible desde cualquier dispositivo con internet URL del aplicativo:
https://marc3mz.github.io/activ_sism/
repositorio: https://github.com/Marc3mz/activ_sism
Sitio Web: <https://proud-curve-332610.rj.r.appspot.com/>
- La aplicación está en desarrollo, puede sufrir mejoras y modificaciones de versión. Ver figura-19.

La interfaz de usuario front end consta de:

Mapa: Muestra la ubicación actual del usuario y los terremotos recientes.

Formulario para carga de datos: magnitud, coordenadas y profundidad

Predicción: Muestra la probabilidad de un terremoto significativo en la ubicación seleccionada.

Alertas: Envía notificaciones si la probabilidad supera un umbral definido, por correo electrónico pre cargado.

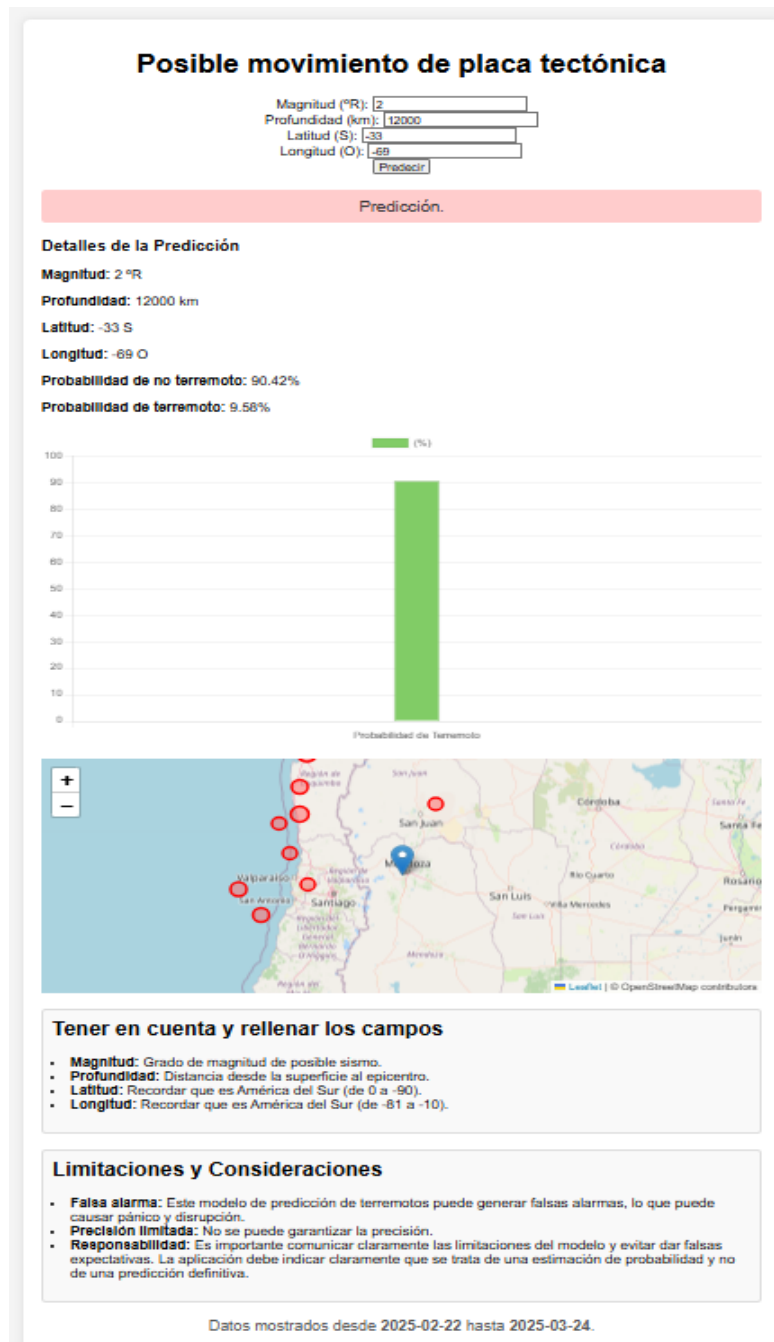
Procedimiento back end:

- Cargar el modelo: Carga el modelo XGBoost guardado en la aplicación.
- Obtener datos en tiempo real: Utiliza la API del USGS para obtener datos de terremotos en tiempo real cerca de la ubicación del usuario.
- Preprocesar los datos: Aplica las mismas transformaciones que se realizan durante el entrenamiento (cálculo de densidad sísmica, etc.).
- Realizar predicciones: Utiliza el modelo para predecir la probabilidad de un terremoto.
- Mostrar resultados: Muestra la probabilidad en la interfaz de usuario y envía alertas si es necesario.

Limitaciones

- Falsa alarma: este modelo de predicción de terremotos puede generar falsas alarmas, lo que puede causar pánico y interrupción.
- Precisión limitada: no se puede garantizar la precisión.
- Responsabilidad: Es importante comunicar claramente las limitaciones del modelo y evitar dar falsas expectativas. La aplicación debe indicar claramente que se trata de una estimación de probabilidad y no de una predicción definitiva.

Figura-19 Aplicativo página web



Fuente: Elaboración propia

Conclusiones

La integración de diversas fuentes de datos provenientes de disciplinas como la geofísica, hidrología, meteorología y astronomía ha demostrado ser efectiva para mejorar la capacidad de predicción sísmica. Esto resalta la importancia de continuar explorando enfoques interdisciplinarios para abordar fenómenos complejos como los terremotos.

Sin embargo, para este estudio los precursores de variación de Aguas Subterráneas y datos meteorológicos extremos analizados preliminarmente, no arrojaron información concluyente respecto a la relación de ocurrencia de terremotos luego de ocurridos eventos significativos en la variación de altura de aguas subterráneas o variaciones extremas de temperatura para las fechas en estudio. Por lo que se desestimaron esos conjuntos de datos para este estudio. Otra limitación que tuvo este análisis es la alta necesidad de recurso de procesador CPU y memoria RAM para ejecutar correctamente los modelos.

Los datos históricos de movimientos sísmicos y microsismos en la zona especifican de Cuyo y en general de Sud América, fueron extraídos de las bases de datos de USGS Earthquake, en el periodo comprendido entre 2004 y 2024, registrados antes de un evento de mayor magnitud, el estudio de estos arrojaron resultados que permitieron hacer validaciones de los modelos de predicciones con valores aceptables para asegurar que luego de una serie de sucesos con frecuencia alta existe una probabilidad mayor al 80% de que se produzca un terremoto de magnitud mayor a 5 grados de escala Richter, pero no se pudo identificar con exactitud la localización de tal evento.

Los datos de tormentas geomagnéticas permitieron un estudio de correlación entre eventos sísmicos y ocurrencia de tormentas de índice G3 o superiores, siendo el modelo de GBT el de mejor comportamiento. La métrica dio 89% de accuracy siendo un valor de exactitud elevado por lo que las tormentas geomagnéticas, provocada en los momentos de mayor actividad solar, de `IMF` (campo magnético interplanetario, en nano teslas) mayores a 5 nT y `SW_Plasma_Speed_km/s` (vientos solares) mayores a 300Km/hs dan una pista a seguir respecto de la influencia directa en los movimientos telúrico.

Las llegadas de muones de alta energía a la superficie terrestre puede significar cambios en la manera en que la gravedad de nuestro planeta atrae las partículas externas y puede estar relacionado con eventos sísmicos o, los eventos sísmicos y las variaciones que preceden al sismo en lo que a los sistemas complejos, físico geológicos que se interrelacionan, provocan

la atracción de rayos cósmicos con energías de muones que superan la media, este análisis supera el conocimiento del tema en estos momentos.

La aplicación de técnicas avanzadas de *machine learning*, LSTM, modelos basados análisis de series temporales, XGBoost, *Random Forest*, ha permitido mejorar la precisión de los modelos predictivos. Esto demuestra el valor del uso de tecnologías de análisis de datos avanzadas para optimizar la predicción de terremotos, lo cual podría beneficiar las alertas tempranas y, en consecuencia, la gestión del riesgo.

Se presenta el desarrollo en proceso de prueba e implementación de un sistema web de alerta temprana.

A pesar de los avances logrados, persisten limitaciones relacionadas con la variabilidad de los precursores sísmicos y la incertidumbre en la correlación entre tormentas geomagnéticas, rayos cósmicos y la actividad sísmica. Por lo tanto, se enfatiza la necesidad de realizar estudios empíricos adicionales que permitan robustecer y confirmar los patrones observados, aumentando la confiabilidad de estos indicadores.

Si bien este estudio se centra en la región de la cordillera de los Andes, los métodos y hallazgos podrían aplicarse en otras áreas sísmicas del mundo. La metodología podría ser adaptada y replicada en otras regiones para evaluar si los mismos precursores y modelos predictivos son efectivos en contextos geológicos distintos, expandiendo el alcance de este tipo de investigación.

Bibliografía

- aquabook, D. d. (2016). https://aquabook.irrigacion.gov.ar/417_0. aquabook:
https://aquabook.irrigacion.gov.ar/417_0
- Centro Sismológico Nacional, U. (2024). <https://www.sismologia.cl/>. ONEMI.
- Consortium, E. (2024). <https://www.earthscope.org/>
- Defensa Civil Mendoza. (s.f.). <https://www.mendoza.gov.ar/defensacivil/sismo/>.
- Galban Rodriguez, L. (2021). Aspectos teórico-metodológicos sobre la predicción de terremotos. *Boletín de Ciencias de la Tierra*, 8. <https://doi.org/https://doi.org/10.15446/rbct,n49.93823>
- Gèron, A. (2023). *Aprende Machine Learning con Scikit-Learn, Keras y TensorFlow* (3 ed.). (O'Reilly, Ed.) Boston, Estados Unidos de América.: Anaya. Retrieved 28 de 09 de 2024, from https://www.academia.edu/121831108/Aprende_Machine_Learning_Con_Scikit_Learn_Keras_y_TensorFlow
- GIL, L. (22 de 5 de 2024). *IAEA Organismo Internacional de Energía Atómica*. <https://www.iaea.org/es/newscenter/news/radiacion-cosmica-por-que-no-deberia-ser-motivo-de-preocupacion-en-ingles>
- Homola, P. (06 de 2023). Observation of large scale precursor correlations between cosmic rays and earthquakes with a periodicity similar to the solar cycle. *Journal of Atmospheric and Solar-Terrestrial Physics*, 247, 35. <https://doi.org/https://doi.org/10.1016/j.jastp.2023.106068>
- INPRES, I. (2024). <https://www.inpres.gob.ar/desktop/>. <https://www.inpres.gob.ar/>
- López González, P. (2021). *Búsqueda de fotones de ultra-alta*. Universidad de Buenos Aires, Facultad de Ciencias Exactas y Naturales.
- Matzka, J., Stolle, C., Yamazaki, ., Y., Bronkalla, O., & Morschhauser, A. (2024). *spaceweatherlive*. <https://www.spaceweatherlive.com/es/actividad-auroral/las-50-principales-tormentas-geomagneticas.html>
- Matzka, J., Stolle, C., Yamazaki, ., Y., Bronkalla, O., & Morschhauser, A. (2024). *SpaceWeatherlive*. <https://www.spaceweatherlive.com/es/actividad-auroral/las-50-principales-tormentas-geomagneticas/ano/2024.html>: <https://www.spaceweatherlive.com/es/actividad-auroral/las-50-principales-tormentas-geomagneticas/ano/2024.html>

- Murillo, J., Gámez, E., Hernández, M., Gutiérrez, F., & Rodríguez, A. (03 de 2023). <https://ciencialatina.org/>. (C. L. Multidisciplina, Editor) https://doi.org/https://doi.org/10.37811/cl_rcm.v7i1.5150
- Rico, M. d. (2024). <https://ecoexploratorio.org/amenazas-naturales/terremotos/que-son-los-terremotos/#:~:text=Los%20componentes%20f%C3%ADsicos%20de%20un,geol%C3%B3gica%20y%20las%20ondas%20s%C3%ADsmicas.> ecoexploratorio .
- Savarensky, E., & Nersesov, I. (1978). *Terremotos Evaluación y Mitigación de su Peligrosidad*. Blume - UNESCO.
- Servicio Nacional de Prevención y Respuesta ante D, & Oficina Nacional de Emergencia del Ministerio del . (s.f.). <https://senapred.cl/>. ONEMI.
- Statistas. (2024). <https://es.statista.com/estadisticas/635155/numero-de-terremotos-registrados-a-nivel-mundial/>. Statistas.
- Tamashiro, A. (2010). *Espectro Composición de losRayos Cosmicos*.
- Tapia Hernández, E. (2013). OBSERVACIONES SOBRE LA PREDICCIÓN DE SISMOS:. *Revista Internacional de Desastres Naturales, Accidentes e Infraestructura Civil*.
- Tavera, H. (2020). *Análisis y evolución de los patrones de sismicidad y escenarios sísmicos en el borde occidental del Perú*. Instituto Geofísico del Perú. Lima: IGP.
- USA.GOV, E. (s.f.). *Centro de predicción del clima espacial*. <https://www.swpc.noaa.gov/noaa-scales-explanation>.
- USGS, S. (s.f.). <https://www.usgs.gov/programs/earthquake-hazards>. USGS: <https://www.usgs.gov/>
- vzw-ORG, P. (2024). *SpaceWeatherLive*. Retrieved 10 de 2024, from SpaceWeatherLive-actividad solar: <https://www.spaceweatherlive.com/es.html>
- Zamora, J. (5 de 2024). <https://puertodeideas.cl/>. (P. Ramirez, Entrevistador) <https://puertodeideas.cl/es/mediateca/rayos-cosmicos-y-terremotos-2:> <https://www.youtube.com/watch?v=3yWETf3KKSk&list=WL&index=5&t=24s>

Apéndices

A. Script en colab de Google Links:

[1] Eventos sísmicos

[2] Tormentas Geomagnéticas

[3] Rayos Cósmicos

B. Set de datos

Terremotos

Fecha y hora del terremoto: Para correlacionar temporalmente con la actividad de rayos cósmicos.

Mag. Magnitud del terremoto: La magnitud de los terremotos es una variable importante, ya que podría haber una relación entre la actividad sísmica y los rayos cósmicos, especialmente en eventos sísmicos de gran magnitud.

Ubicación geográfica: La latitud, longitud y profundidad del terremoto, lo que puede ayudarte a correlacionar eventos sísmicos con observaciones de rayos cósmicos en regiones específicas.

Tormentas Geomagnéticas

YYYY: año; **Day:** día; **HR:** hora.

IMF_B_Total_nT: valor total del campo magnético interplanetario, medido en nano teslas. Cuando el campo magnético interplanetario se orienta de manera opuesta al campo terrestre, puede generar tormentas geomagnéticas más intensas.

SW_Plasma_Speed_km/s: La velocidad del plasma del viento solar en kilómetros por segundo. (Las velocidades más altas pueden estar asociadas con tormentas solares y aumentos en la actividad geomagnética.).

Índice Kp (índice de actividad geomagnética): mide la perturbación del campo magnético terrestre. Los valores de Kp se miden en una escala de 0 a 9, donde valores más altos indican tormentas geomagnéticas más intensas. A mayor intensidad y componente sur del IMF_B_Total_nT, mayor es la probabilidad de que el índice Kp aumente, indicando una mayor actividad geomagnética. A mayor velocidad del viento solar, más probable es que el índice Kp sea alto

Catalogo Pierre Auger Rayos C3smicos

Datos de 109 lluvias medidas con el conjunto de detectores de agua-Cherenkov⁶

La informaci3n contenida en archivo es:

ID Nombre del evento, PAOaammdd, indicando a3o, mes y d3a de detecci3n

GPSTime coordenadas y horario espacial.

Hora UTC (s) Tiempo Universal Coordinado (UTC)

Energ3a (EeV) Energ3a

θ (grados) 3ngulo cenital

δ (grados) Declinaci3n

ϕ (grados) 3ngulo acimutal

α (grados) Ascensi3n recta

$t_{1/2}$ (1000) (ns) Tiempo de subida de la se3al a 1000 m del n3cleo (para eventos con $\theta \leq 60^\circ$)

Multiplicidad N3mero de estaciones activadas utilizadas en la reconstrucci3n

Sitio FD Sitio del detector de fluorescencia [1=Los Leones, 2=Los Morados, 3=Loma Amarilla, 4=Coihueco] (para eventos h3bridos)

X_{max} (g/cm^2) Profundidad m3xima de la ducha (para eventos h3bridos).

SD_Exposure: Exposici3n acumulada o tiempo de observaci3n del detector de superficie.

sd_energy: Energ3a estimada del rayo c3smico detectado por el SD.

⁶ La “Radiaci3n Cherenkov” es la luz emitida por un medio transparente cuando part3culas cargadas lo cruzan a una velocidad mayor a la de la luz en ese medio. El efecto, descubierto por Pavel Cherenkov en 1934

Reporte del tutor

Título del Proyecto: Modelos de Predicción del Comportamiento de las Fallas Tectónicas

AUTOR: MARCELA ANDREA PALMIERI

TUTOR: PROF. JUANA LÓPEZ

El proyecto presentado aborda un tema de alta relevancia en el campo de la predicción sísmica y tiene un impacto directo en la protección de las comunidades frente a estos desastres naturales. El proyecto busca desarrollar un modelo predictivo capaz de anticipar la ocurrencia, magnitud y localización de terremotos, integrando análisis de datos multidisciplinarios con técnicas avanzadas de modelado y machine learning. Además, se propone diseñar un sistema de alerta temprana basado en este modelo, lo cual representa un aporte relevante al manejo del riesgo sísmico. A continuación, se evalúan los principales aspectos del planteo del trabajo.

Definición e identificación del problema

El problema está claramente identificado y se destaca por su relevancia social y científica. Se enumeran las falencias de los modelos tradicionales y los aportes que se pueden realizar a partir de esta propuesta que contempla integrar datos multidisciplinarios, mejorar la recolección de los datos, ajustar modelos predictivos y desarrollar un sistema de alerta temprana.

La pregunta de investigación: ¿Cómo se pueden mejorar los modelos predictivos de terremotos mediante la integración de datos multidisciplinarios y el uso de técnicas de modelado y machine learning, para anticipar de manera más precisa la ocurrencia, magnitud y localización de los eventos sísmicos? Es precisa y pertinente, está bien alineada con el problema planteado.

Articulación con el estado del conocimiento

En la propuesta se mencionan estudios preliminares de precursores externos con sus alcances y limitaciones, englobando de esta forma el estado del conocimiento en relación con los precursores y se proponen enfoques innovadores como el machine learning para abordar problemas de predicción sísmica a partir de la integración de datos de diversas disciplinas.

Contribución y consistencia respecto al problema

La propuesta tiene un alto potencial de contribución al vincular metodologías avanzadas de machine learning con aplicaciones prácticas en gestión de riesgos de terremotos. Existe una

consistencia notable entre el problema, el objetivo propuesto y el enfoque metodológico utilizado, lo que refuerza la solidez del proyecto. La disponibilidad del sistema de alerta temprana para los decisores será de gran utilidad para los responsables de la toma de decisiones.

Factibilidad

El proyecto parece factible dentro del tiempo previsto y los recursos disponibles, especialmente considerando los conocimientos de la alumna sobre técnicas y herramientas de análisis avanzadas. Se hace mención a la cantidad y calidad de los datos, se realiza un análisis estadístico de las variables que se utilizan en el modelo. El desarrollo del modelo a partir de la integración de diversas fuentes de datos representa un desafío para abordar durante el desarrollo del trabajo y derivará en recomendaciones acerca de la necesidad de contar con set de datos robustos que alimenten estos modelos. Esto último, seguramente será un desafío para abordar durante el desarrollo del trabajo y derivará en recomendaciones acerca de la necesidad de contar con set de datos robustos que alimenten estos modelos.

El proyecto "Modelos de Predicción del Comportamiento de las Fallas Tectónicas" es una propuesta sólida y de gran relevancia científica y social. Con su enfoque en la integración de datos y el uso de machine learning, tiene el potencial de generar un impacto significativo, especialmente en la implementación de un sistema de alerta temprana. Si bien hay buenos resultados preliminares, se enfatiza la necesidad de realizar estudios empíricos adicionales que permitan robustecer y confirmar los patrones observados, aumentando la confiabilidad de los indicadores utilizados.