

TagEQ-CN: Clasificación de Eventos Sísmicos Basado en Redes Complejas

TagEQ-CN: Automatic Classification System for seismic events based on complex networks

Daniel Andres Leon Vargas



Víctor Andrés Bucheli Guerrero



Universidad del Valle, Colombia

Hugo Armando Ordoñez Erazo



Universidad del Cauca, Colombia

OPEN ACCESS

Recibido: 17/12/2020

Aceptado: 25/03/2021

Publicado: 7/05/2021

Correspondencia de autores:

hugoeraso@gmail.com



Copyright 2020
by Investigación e
Innovación en Ingenierías

Resumen

Objetivo: Realizar detección y clasificación de señales sísmicas continua siendo un tema de investigación, dada la diversidad de tipos de señales, sensores y fuentes de vibración. **Metodología:** Para el proceso de clasificación de eventos utiliza información sobre nodos o lugares que aglomeran eventos sísmicos, así como también comunidades de eventos. **Resultados:** El sistema se testeó con señales provenientes de la estación La Rusia que pertenece a la Red Sismológica Nacional de Colombia, con resultados prometedores. La aplicabilidad de este sistema, permite incluir información nueva para la anotación automática de sismos, así como también reconocer automáticamente eventos de otras fuentes. **Conclusiones:** El sistema desarrollado se basa en el paradigma supervisado, el usuario no escoge directamente cuál es el conjunto de señales que se utilizan para el entrenamiento y prueba del clasificador.

Palabras clave: Redes complejas, aprendizaje de máquina, etiquetado semi-automático de señales, eventos sísmicos, modelos de clasificación.

Abstract

Objective: Performing detection and classification of seismic signals continues to be a topic of research, given the diversity of types of signals, sensors and sources of vibration. **Methodology:** For the event classification process, it uses information about nodes or places that agglomerate seismic events, as well as event communities. **Results:** The system was tested with signals from La Russia station that belongs to the National Seismological Network of Colombia, with promising results. The applicability of this system allows including new information for the automatic annotation of earthquakes, as well as automatically recognizing events from other sources. **Conclusions:** The developed system is based on the supervised paradigm, the user does not directly choose the set of signals used for the training and testing of the classifier.

Keywords: Complex networks, machine learning, semi-automatic labeling of signals, seismic events, classification models.

Introducción

En el área de la sismología constantemente se presentan desarrollos tanto en el procesamiento de señales como en la detección y clasificación de señales sísmicas [1,2,3, 4]. El rango de tipos de señales, sensores y fuentes de vibración es amplio y esto ha llevado a que sea una área activa de investigación [5].

Un sismograma puede describirse como el resultado de la convolución de 3 funciones de transferencia diferentes: La función de la fuente de vibración, el efecto del material en el que la onda se ha propagado, y la respuesta del sensor ante la vibración. Por otro lado, diferentes fenómenos pueden ser fuentes de vibración en un mismo lapso, entre las cuales se tienen los procesos tectónicos, atmosféricos, antrópicos, o de cualquier otra naturaleza [6]. Existen muchas implementaciones de algoritmos para hacer detección de eventos, sin embargo, hay limitaciones en cuanto a la generalidad de estos sistemas, debido a la naturaleza tan heterogénea de las señales registradas. Esto representa un tema de interés en las ciencias de la computación, para tratar de encontrar algoritmos que sean cada vez más generales en cuanto a la clasificación de señales.

Los sismos se pueden entender como ondas P y S, donde sus valores de velocidad de propagación permiten estudiar este tipo de eventos. Sin embargo, la detección es un problema abierto de investigación, debido al gran volumen de datos y señales que genera una red sismológica, así, se hace necesario contar con un sistema automático de detección. Al respecto se han desarrollado diferentes trabajos en el área de procesamiento de señales, así como también, en el área de la detección de eventos. Estas dos áreas son de interés especial para el presente trabajo. Existen actualmente muchas aproximaciones a la solución de la detección automática de sismos usando esquemas de aprendizaje de máquina, que son una rama de la inteligencia artificial. Sin embargo, hay una brecha debido a la heterogeneidad y la cantidad de información que contienen las ondas sísmicas. Así, los diferentes tipos de sensores que hacen el registro de eventos recolectan información de los diferentes tipos de estructuras de la tierra que atraviesan las ondas hasta llegar a tales sensores, los diferentes tipos de eventos sísmicos que se presentan tales como volcanes, entre otros. Entonces, la brecha abierta se puede relacionar con el problema de predecir algún tipo de estos eventos, lo cual puede salvar la vida de muchas personas.

Este artículo propone un sistema prototipo de clasificación de eventos sísmicos a partir de redes complejas, el sistema hace parte de una arquitectura más general que basa la clasificación de eventos sísmicos en inteligencia artificial (TagEQ), una descripción general de dicho fue presentada por [7]. En el sistema prototipo propuesto los eventos sísmicos se representan como una red, lo que permite obtener mayor información para la clasificación automática de eventos, así es posible utilizar información sobre nodos o lugares que aglomeran eventos sísmicos, así como también comunidades de eventos sísmicos, entre otras características topológicas de una red compleja. El artículo presenta TagEQ-CN como un sistema de etiquetado semi-automático de señales sísmicas, que toma sismogramas continuos de una estación y, a partir de un catálogo de eventos sísmicos y una representación de los eventos como red, clasifica automáticamente las señales. Se propone un tipo de anotación a partir de características de los eventos respecto a la topología de la red de sismos previamente construida. En este sistema se integraron algoritmos de aprendizaje de máquina supervisados. De igual manera, se desarrolló un corpus de señales a partir de los datos recopilados de La Rusia (estación que pertenece a la Red Sismológica Nacional de Colombia), de tal manera que se puedan aplicar los algoritmos de aprendizaje de máquina. Para ello, se creó un sistema modular para crear y anotar vectores de características tomadas en formas de onda de eventos sísmicos y características de la red de sismos construida. (módulo ETL), y entrenar un clasificador automático a partir de un conjunto de señales anotadas (módulo de entrenamiento). El etiquetado automático se hace frente a

características propias de un nodo, como el grado o la intermediación (betweenness), o frente a si hace parte de un grupo de nodos como una comunidad.

Métodología

En sismología se han implementado muchos tipos de clasificadores, desde Mapas Auto-Organizados [8, 9], Máquinas de Soporte Vectorial [10], o Redes Neuronales [11], buscando clasificar entre pocos tipos de señales (ruido-sismo, sismos locales-sismos regionales-telesismos, voladuras-sismos).

La búsqueda de patrones en la distribución espacial y temporal de eventos sísmicos ha permitido encontrar límites de placas tectónicas, describir sus movimientos sobre el manto terrestre, y evaluar el riesgo sísmico [6]. Existen muchos estudios que tratan de encontrar precursores de eventos grandes usando sismos premonitorios (foreshocks) [12], variaciones magnéticas [13], o emisiones de gas [14]; entre otros. Aunque son muy interesantes, la mayoría de estos estudios proveen resultados de pronóstico no concluyentes, y hasta ahora los estudios sugieren la posibilidad de pronosticar un evento de manera confiable dentro de un rango temporal de unos pocos años en el mejor de los casos [15].

Hay muchos estudios acerca de los patrones espaciales en la distribución espacial de eventos sísmicos. Abe y Suzuki [16] estudian la complejidad espacial de la distribución de eventos sísmicos en el sur de California, llevando a una geometría fractal que se encuentra con frecuencia en sistemas complejos no equilibrados. El uso de la construcción de redes de sismos se ha conFigurado como una manera novedosa de estudiar la complejidad espacial y temporal de la sismicidad. Por ejemplo, Baiesi y Paczuski [17] crearon redes de sismos de sismos principales y réplicas enlazando eventos que estuvieran altamente correlacionados, encontrando una estructura libre de escala en cada cúmulo identificado. De manera similar, en [18] se crearon redes de sismos para estudiar el efecto del sismo del 2015 de Mw=8.3 en Illapel, Chile, en donde se hallaron cambios en parámetros como la conectividad promedio y la intermediación que varían por la ocurrencia de eventos grandes, evidenciando que eventos grandes afectan la estructura de las redes de sismos creadas. Así mismo, Chorozoglou [19] usaron redes complejas para detectar eventos premonitorios antes de dos sismos en Grecia y encontraron que el método podría ser aplicado, junto con otras medidas, para tareas de riesgo sísmico.

En Abe y Suzuki [20] se dice que “una red de pequeño mundo reside entre la regularidad y la aleatoriedad, análogo al borde del caos en dinámicas no lineales”, lo cual indica que estos tipos de redes tienen un aspecto aleatorio, así como uno estructurado en su interconexión. De acuerdo a León [21], se encontró que una red de sismos para Colombia puede caracterizarse como una red de pequeño mundo, lo cual concuerda con estudios similares en otras regiones del mundo [20].

El uso de características de redes complejas en tareas de machine learning se puede revisar en [22]. En 8, 9 y 10 se muestran casos de estudio en el que se realizan tareas de clasificación automática de datos usando aprendizaje supervisado, semi-supervisado y no supervisado a partir de características estimadas de representaciones de datos como redes complejas. El caso que nosotros proponemos con TagEQ-CN está inmerso en el marco semi-supervisado.

Existen paquetes como SNAP, Gephi y GraphViz que permiten analizar y graficar redes complejas, o librerías de Python como Networkx para estos fines. desarrollado en la universidad de Stanford, o Networkx. Sin embargo, hasta la fecha no se ha encontrado paquetes de software ni frameworks computacionales que construyan redes de sismos.

Este artículo tiene como propósito mostrar una arquitectura modular que pueda usarse para clasificar eventos usando sismogramas de una estación y un catálogo sísmico, aplicando directivas de alto nivel para anotar los eventos, implementando varios algoritmos de extracción de características de redes complejas, detección y clasificación, mostrando cómo se pueden integrar en un sistema automático de clasificación.

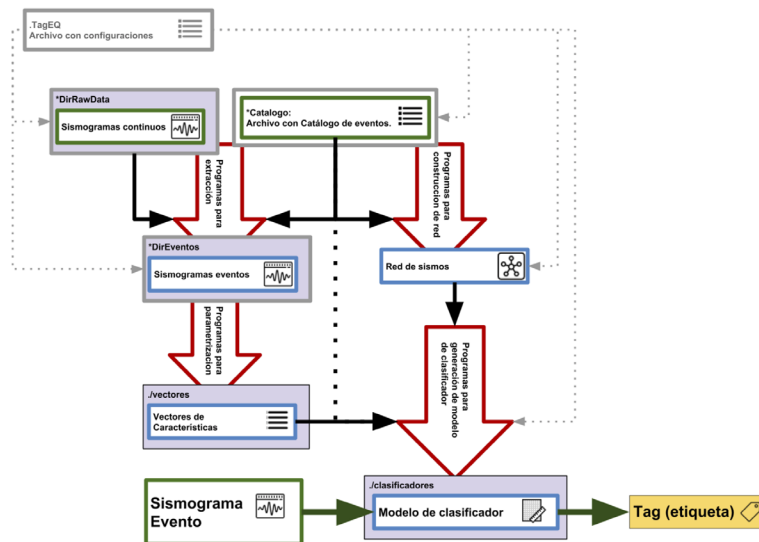
Arquitectura TagEQ-CN

TagEQ-CN recibe un catálogo anotado de eventos sísmicos y los sismogramas de una estación para un tiempo dado. Estos son los datos utilizados para el entrenamiento de un algoritmo de aprendizaje de máquina. A partir del catálogo de sismicidad, se busca en los sismogramas de manera automática las señales que correspondan a cada evento y se parametrizan, creando vectores de características de dichas señales, a partir de la información de una red compleja de sismos. Dicha red se construye de acuerdo con León [21], dividiendo una región en celdas cuadradas, seleccionando como nodos las celdas donde ocurren eventos sísmicos, y enlazando estas celdas siguiendo la secuencia temporal de los eventos. Esta información puede ser utilizada con cualquier algoritmo de aprendizaje que se desee aplicar: máquinas de soporte vectorial (SVM) o bosques de decisión (RF). El proyecto está disponible en <https://gitlab.com/danieleon1/TagEQ>.

Flujo de datos para el sistema TagEQ-CN

Para el funcionamiento del sistema se usa un archivo de configuración que funciona como un mapa para que el sistema sepa dónde están los datos de las señales, los parámetros para los algoritmos de clasificación; los parámetros con los que se asignan las etiquetas, el tipo de clasificación que se desea hacer y las reglas con las que se deben aplicar las etiquetas. En la Figura 1 se presenta el flujo de datos y la arquitectura del sistema.

Figura 1. Flujo de datos y arquitectura del sistema



Fuente: elaboración propia

Las tareas representadas en la Figura 1 son:

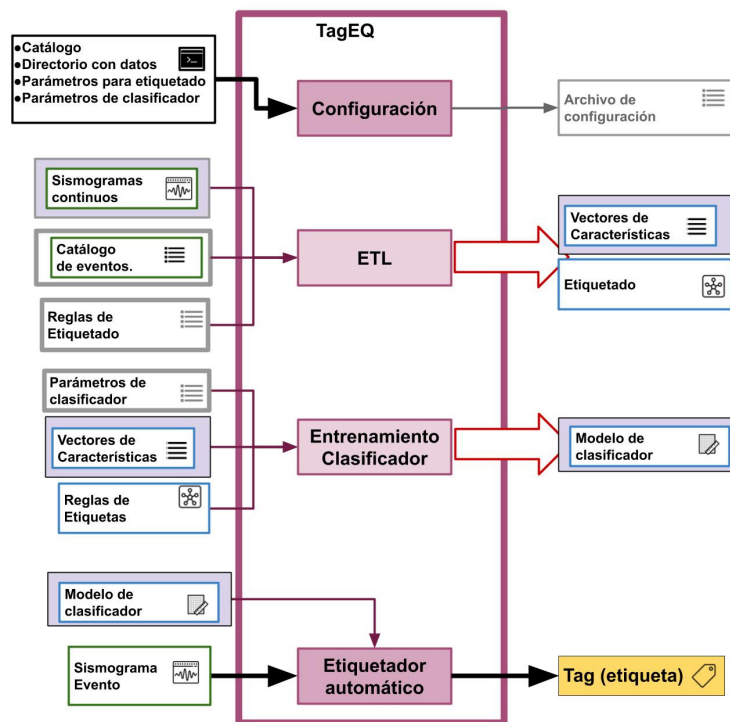
- Ejecución de las tareas de pre-procesamiento de los sismogramas continuos, extracción de las señales de los eventos que hacen parte del catálogo; y definición de las reglas con las que se asignan las etiquetas a los eventos.
- Creación de vectores de características a partir de los sismogramas de los eventos.
- Creación de modelos de clasificadores a partir de los vectores y las reglas definidas para etiquetar los eventos.
- Ya con los modelos construidos, se realiza la lectura del sismograma de un evento para asignarle la etiqueta correspondiente.

Módulos del sistema TagEQ-CN

La Figura 2 muestra los principales módulos del sistema. En ella se presentan las entradas y salidas y la estructura modular del sistema TagEQ-CN. Así se presentan los cuatro módulos principales: ConFiguración, ETL (Extracción, Transformación y Carga), Entrenamiento de clasificador y Etiquetado automático. Cada módulo se ejecuta de manera automática cuando el usuario lo indica, sin embargo, solo los módulos de ConFiguración y Etiquetado automático precisan de interacción con el

usuario para poder entregar su respectiva salida. A continuación, se describe en detalle cada módulo del sistema.

Figura 2. Módulos del sistema TagEQ-CN

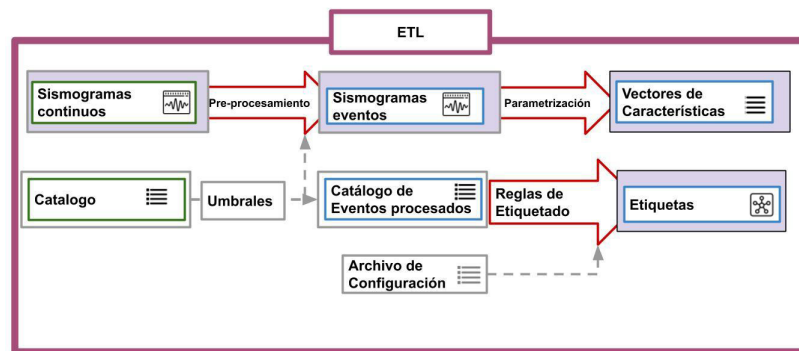


Fuente: Elaboración propia

Módulo de configuración: El módulo de configuración tiene como propósito que el usuario haga explícitas las directivas con las que desea que el sistema realice la clasificación de las señales. Hay dos clases de directivas para el sistema; las directivas generales y las directivas de Machine Learning. En las directivas generales se describe el lugar en que están los sismogramas, cuál es el catálogo con el que se trabaja, dónde se almacenan los datos generados (sismogramas de eventos y catálogos anotados), y qué reglas se usan para anotar los datos. En las directivas de Machine Learning se define el tipo de clasificador y los parámetros con los que se sintonizan tales clasificadores.

Módulo de Extracción, Transformación y Carga (ETL): Realiza todos los procedimientos de pre-procesamiento de datos y parametrización de sismogramas de los eventos. La Figura 3 presenta el esquema general de funcionamiento de este módulo. El módulo ETL toma las entradas (sismogramas continuos y catálogo de sismicidad) y genera los vectores de características que posteriormente se usarán para clasificar eventos. Usando los tiempos de origen de los eventos relacionados en el catálogo de sismicidad, se buscan en los sismogramas continuos las señales que correspondan a los eventos para posteriormente parametrizarlas usando diferentes técnicas, y luego se almacenan estos vectores de características. Para la arquitectura propuesta en el sistema TagEQ, se crearon programas para generar vectores según los siguientes criterios:

Figura 3. Módulo de Extracción, Transformación y Carga (ETL)

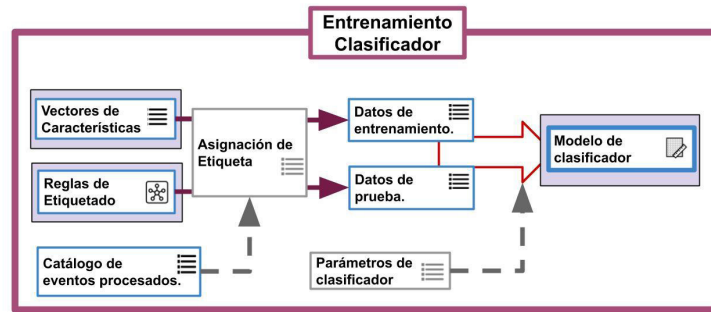


Fuente: elaboración propia

- *Estadísticos:* Se calcula promedio, varianza, asimetría estadística y curtosis en ventanas de 50 segundos para los 3 canales del sismograma.
- *Sonograma:* Calcula el promedio en lapsos de 50 segundos de la energía de 9 bandas de frecuencia, a partir del algoritmo propuesto por [23].
- *Dimensión fractal de la señal:* Calcula la dimensión fractal de la componente vertical para una ventana definida.
- *Variación de la dimensión fractal:* Calcula la varianza de la dimensión fractal calculada en diferentes ventanas.
- *Covarianzas:* Calcula la matriz de covarianzas, rectilinealidad y planaridad de la señal en una definida.

Módulo entrenamiento del clasificador: Para realizar el entrenamiento del clasificador, se toman los vectores de características y se asigna una etiqueta correspondiente. Esta asignación se hace revisando la información consignada en el catálogo de eventos procesados y resolviendo la etiqueta a partir de las reglas que se consignen para la red de sismos, y luego se etiquetan los datos resolviendo la directiva usando el catálogo de sismicidad. El esquema del flujo de información en este módulo se muestra en la Figura 4.

Figura 4. Módulo de entrenamiento del clasificador




Fuente: elaboración propia

Para crear el modelo de clasificador, se usa una parte del set de datos como entrenamiento y restante como datos de prueba. Para cada caso de algoritmo de clasificación se usan los parámetros introducidos en el archivo de configuración ya sea para generar un solo modelo o para generar muchos modelos y escoger el que mejor desempeño tenga. Para el sistema TagEQ-CN se usaron las librerías LibSVM para las máquinas de soporte vectorial [24]; y para los bosques aleatorios de decisión el programa Ranger [25, 26, 27].

Módulo etiquetador de eventos: el módulo requiere que manualmente se le diga al sistema cuál es el sismograma del evento a clasificar, tras lo cual se parametriza el sismograma, se construye un vector de características, y luego se le ingresa al modelo construido anteriormente. Al ejecutar la predicción del clasificador entrenado se tiene la etiqueta del evento. La Figura 5 muestra el esquema en que funciona el módulo del etiquetador.

Figura 5. Módulo etiquetador de eventos



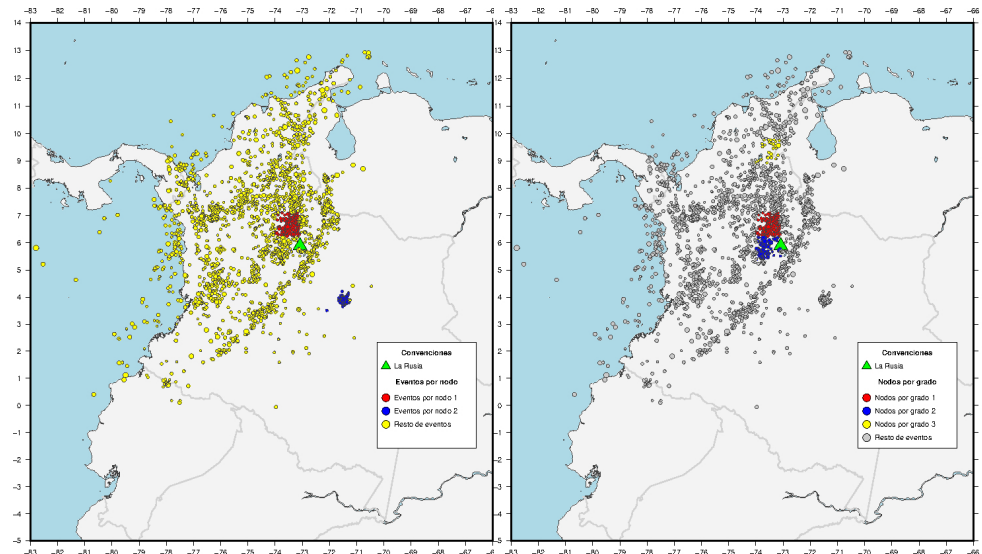
Fuente: elaboración propia

Resultados

El catálogo con el que se trabajó consta de 51520 eventos. De estos eventos, se trabajó solamente los que tenían magnitud $M > 2$, y que tuvieran suficiente energía sísmica en la estación La Rusia; aunque en algunos casos se realizó la prueba con los eventos con magnitud $M > 3$. El conjunto de prueba final consta de 8151 eventos con $M > 2$, y de 502 para $M > 3$, y se probaron algoritmos para realizar clasificación en escenarios según la pertenencia a comunidades de eventos, según el grado del nodo, según la centralidad y según el número de eventos por nodo.

La Figura 6 muestra los eventos etiquetados según la cantidad de eventos por nodo y según el grado del nodo. Para el caso de cantidad de eventos se etiquetaron los eventos que hacían parte de las dos celdas con mayor cantidad y una tercera clase para etiquetar el resto. Para el caso de grado de eventos, se etiquetaron los eventos de los tres nodos con mayor grado, y una cuarta clase para etiquetar el resto de eventos.

Figura 6. Mapas de clasificación de eventos por pertenencia a nodos con mayor cantidad de eventos (izquierda) y por grado (derecha)

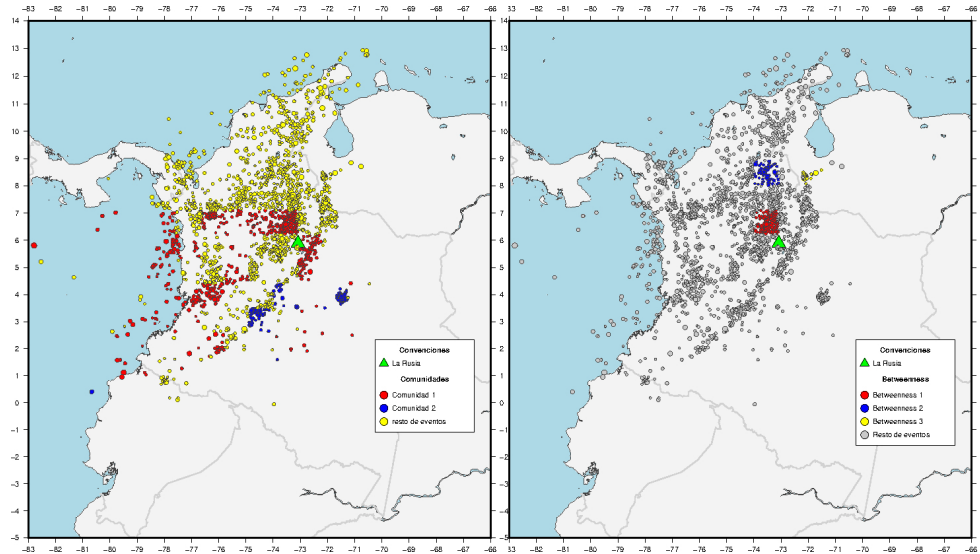


Fuente: elaboración propia

Vale la pena comentar que el etiquetado que se hace muestra en ambos casos la importancia de los eventos que ocurren en el nido de Bucaramanga. Se puede ver también que en el oriente colombiano hay una pequeña región en la que ocurren muchos eventos en un nodo. Y respecto al grado de las celdas, se puede ver que las celdas cerca de Bucaramanga se enlazan mucho con las demás, así como eventos que ocurren más al norte, entre los departamentos de Cesar y Norte de Santander, en la frontera con Venezuela.

La Figura 7 muestra el etiquetado de eventos que pertenecen a las dos comunidades con mayor cantidad de nodos, además una tercera clase para el resto de eventos (izquierda); y etiquetado de eventos que pertenecen a los 3 nodos con mayor índice de centralidad en la red de sismos, además de una cuarta clase para el resto de eventos (derecha).

Figura 7. Mapas de clasificación de eventos por pertenencia a nodos de las mayores comunidades de eventos (izquierda) y a los nodos más centrales de la red de sismos (derecha)




Fuente: elaboración propia

La Figura 7 muestra que el nivel de abstracción necesario para diferenciar eventos de categorías diferentes es elevado. Para el caso de las comunidades (Figura 7 izquierda), se puede ver que los miembros de la misma categoría, por ejemplo, la roja, están localizados en diferentes lugares y muy cerca de miembros de otras categorías; lo cual es un reto para una única estación tratando de diferenciar todos los eventos. Esto mismo sucede para la otra comunidad.


Con los esquemas de anotación mostrados en las Figuras 6 y 7, se entrenaron clasificadores del tipo Máquina de Soporte Vectorial (SVM) y Random Forest (RF); eligiendo aleatoriamente un 80% del conjunto de eventos anotados para entrenamiento y un 20% como conjunto de test. Para las precisiones y sensibilidades mostradas en las Figuras 8 y 9 se usó el mejor clasificador SVM al variar los parámetros, y un clasificador RF con 500 árboles.

Figura 8. Precisión de los clasificadores usando SVM y RF



Fuente: elaboración propia

Figura 9. Sensitividad de los clasificadores usando SVM y RF



Fuente: elaboración propia

De las Figuras 8 y 9 se puede apreciar que el rendimiento es mejor con los RF respecto a las SVM. Esta misma conclusión se encontró en [26], en la que se compararon los rendimientos de SVM, RF y un clasificador Bayesiano. Esto, sumado a que se entrena más rápido y más sencillo, lo ponen con un rendimiento superior a las SVM. De todas maneras, cabe anotar que ambos clasificadores presentan una diferencia pequeña en la precisión y que podría usarse cualquiera de los dos; indicando que la parametrización realizada de las formas de onda tiene información suficiente para crear un buen clasificador a pesar de no tener muchos datos para entrenar (hasta 8151 discriminando con magnitud $M > 2$). De los 51520 eventos, no se revisaron eventos más pequeños porque la energía de estos es muy pequeña y solo podría verse en esta estación si ocurren muy cerca de ella.

Finalmente, los niveles de precisión y sensitividad superan casi siempre el 70% (excepto para las SVM que se acercan bastante a este nivel). La sensitividad para este caso multi-clases tiene que ver con cuántos elementos de una categoría pueden ser etiquetados como de otra categoría, por lo que el elevado porcentaje indica que son pocos los elementos que se etiquetan erróneamente.

Conclusiones

El sistema desarrollado se basa en el paradigma supervisado, aunque buena parte del sistema funciona de manera automática en el sentido de que el usuario no escoge directamente cuál es el conjunto de señales que se utilizan para el entrenamiento y prueba del clasificador; ni asigna las etiquetas a los eventos, sino que se asignan a partir de un catálogo de sismos previo, es decir, de una anotación inicial que un analista ha hecho de la sismicidad; y a partir de reglas de alto nivel que defina el usuario. Dado el nivel de abstracción que el clasificador alcanzó, es posible que pueda usarse también con otro tipo de señales, como señales de deslizamientos, explosiones, o movimiento de fluidos. Sin embargo, para poder usar esta técnica se debe crear un catálogo de tiempos de eventos y algún tipo de identificación de la señal.

La clasificación de eventos sísmicos con una sola estación puede ser de gran ayuda cuando no se tiene una red de sensores amplia. Utilizar una única estación para clasificar eventos podría ayudar a un analista a generar una alarma para revisar alguna situación a partir de una única señal adquirida, sin necesidad de

esperar que se tengan las señales de otras estaciones, entregando un reporte preliminar que ponga en “estado de alerta” a un operador de datos sismológicos, con una información preliminar más completa que simplemente decir que una señal superó un nivel de energía.

El sistema desarrollado posee un nivel de modularidad que podría permitir la adición de nuevas características a los vectores desarrollando nuevos programas que extraigan información analizada de un sismograma.

El resultado de las precisiones indica que los parámetros escogidos para representar los eventos en los vectores de características pueden considerarse adecuados; aunque para mejorar el nivel de abstracción con eventos de tantas partes diferentes, con formas de onda diferentes, se podrían necesitar otras características.

Se pudo evidenciar que tanto para los clasificadores Random Forest como para las Support Vector Machine los resultados son buenos. El resultado que se halló también indica que los Random Forest son más adecuados para hacer la clasificación de señales sísmicas.

La clasificación de nuevas señales a partir de las reglas de alto nivel implementadas en el catálogo podría permitir a un analista encontrar rápidamente señales candidatas de algún tipo (eventos profundos/someros, grandes/pequeños, pertenecen/no pertenece) de cierto interés, implementando en conjunto un algoritmo de detección con uno de clasificación.

Como trabajo futuro, dado que este es un prototipo de clasificador, se propone tener un ambiente amigable con el usuario, y definir un marco amplio en el que se puedan definir directivas de alto nivel para asignar etiquetas.

Referencias Bibliográficas

1. J. Akram and D. Eaton, “Adaptive microseismic event detection and automatic time picking.”
2. M. Beyreuther and J. Wassermann, “Continuous earthquake detection and classification using discrete Hidden Markov Models,” *Geophys. J. Int.*, vol. 175, no. 3, pp. 1055–1066, Dec. 2008, doi: <https://doi.org/10.1111/j.1365-246X.2008.03921.x>.
3. P. Bui Quang, P. Gaillard, Y. Cano, and M. Ulzibat, “Detection and classification of seismic events with progressive multi-channel correlation and hidden Markov models,” *Comput. Geosci.*, vol. 83, pp. 110–119, Oct. 2015, DOI: <https://doi.org/10.1016/j.cageo.2015.07.002>.
4. O. Lindenbaum, N. Rabin, Y. Bregman, and A. Averbuch, “Multi-channel fusion for seismic event detection and classification,” Nov. 2016, pp. 1–5, DOI: <https://doi.org/10.1109/ICSEE.2016.7806088>.
5. J. Havskov and L. Ottemöller, *Routine data processing in earthquake seismology: with sample data, exercises and software*. Dordrecht ; New York: Springer, 2010.
6. T. Lay and T. C. Wallace, *Modern global seismology*. San Diego: Academic Press, 1995.
7. D. Leon, H. Ordoñez, and V. Bucheli, “TagEQ: Sistema de Clasificación de Eventos Sísmicos Basado en Inteligencia Artificial,” *RISTI - Rev. Iber. Sist. E Technol. Inf.*, vol. e27, pp. 359–370, 2020.
8. B. Sick, M. Guggenmos, and M. Joswig, “Chances and limits of single-station seismic event clustering by unsupervised pattern recognition,” *Geophys. J. Int.*, vol. 201, no. 3, pp. 1801–1813, Apr. 2015, DOI: <https://doi.org/10.1093/gji/ggv126>.

9. A. Köhler, M. Ohrnberger, and F. Scherbaum, "Unsupervised pattern recognition in continuous seismic wavefield records using Self-Organizing Maps: Unsupervised seismic pattern recognition," *Geophys. J. Int.*, vol. 182, no. 3, pp. 1619–1630, Sep. 2010, DOI: <https://doi.org/10.1111/j.1365-246X.2010.04709.x>.
10. A. E. Ruano, G. Madureira, O. Barros, H. R. Khosravani, M. G. Ruano, and P. M. Ferreira, "Seismic detection using support vector machines," *Neurocomputing*, vol. 135, pp. 273–283, Jul. 2014, DOI: <https://doi.org/10.1016/j.neucom.2013.12.020>.
11. S. Gentili and P. Bragato, "A neural-tree-based system for automatic location of earthquakes in Northeastern Italy," *J. Seismol.*, vol. 10, no. 1, pp. 73–89, Jan. 2006, DOI: <https://doi.org/10.1007/s10950-005-9001-z>.
12. J. McGuire, M. S. Boettcher, and T. H. Jordan, "Foreshock sequences and short-term earthquake predictability on East Pacific Rise transform faults," *Nature*, vol. 434, no. 7032, pp. 457–461, Mar. 2005, DOI: <https://doi.org/10.1038/nature03377>.
13. L. N. Doda, V. L. Natyaganov, and I. V. Stepanov, "An empirical scheme of short-term earthquake prediction," *Dokl. Earth Sci.*, vol. 453, no. 2, pp. 1257–1263, Dec. 2013, DOI: <https://doi.org/10.1134/S1028334X1312009X>.
14. P. E. Nikolopoulos D, "Radon-222: A Potential Short-Term Earthquake Precursor," *J. Earth Sci. Clim. Change*, vol. 06, no. 06, 2015, DOI: <https://doi.org/10.4172/2157-7617.1000282>.
15. A. Donnellan *et al.*, "Potential for a large earthquake near Los Angeles inferred from the 2014 La Habra earthquake: POTENTIAL FOR A LARGE EARTHQUAKE NEAR LA," *Earth Space Sci.*, vol. 2, no. 9, pp. 378–385, Sep. 2015, DOI: <https://doi.org/10.1002/2015EA000113>.
16. S. Abe and N. Suzuki, "Law for the distance between successive earthquakes: A NEW LAW FOR DISTANCE BETWEEN EARTHQUAKES," *J. Geophys. Res. Solid Earth*, vol. 108, no. B2, Feb. 2003, DOI: <https://doi.org/10.1029/2002JB002220>.
17. M. Baiesi and M. Paczuski, "Scale-free networks of earthquakes and aftershocks," *Phys. Rev. E*, vol. 69, no. 6, p. 066106, 2004.
18. D. Pastén, F. Torres, B. Toledo, V. Muñoz, J. Rogan, and J. A. Valdivia, "Time-Based Network Analysis Before and After the \$M_w\$ 8.3 Illapel Earthquake 2015 Chile," *Pure Appl. Geophys.*, vol. 173, no. 7, pp. 2267–2275, Jul. 2016, DOI: <https://doi.org/10.1007/s00024-016-1335-7>.
19. D. Chorozoglou, D. Kugiumtzis, and E. Papadimitriou, "Application of complex network theory to the recent foreshock sequences of Methoni (2008) and Kefalonia (2014) in Greece," *Acta Geophys.*, vol. 65, no. 3, pp. 543–553, Jun. 2017, DOI: <https://doi.org/10.1007/s11600-017-0039-4>.
20. S. Abe and N. Suzuki, "Earthquake networks, Complex," in *Extreme Environmental Events*, R. A. Meyers, Ed. New York, NY: Springer New York, 2011, pp. 312–319.
21. D. A. León, J. A. Valdivia, and V. A. Bucheli, "Modeling of Colombian Seismicity as Small World Networks," *Seismol. Res. Lett.*, vol. 89, no. 5, pp. 1807–1816, Sep. 2018, DOI: <https://doi.org/10.1785/0220180076>.
22. T. Christiano Silva and L. Zhao, *Machine Learning in Complex Networks*. Cham: Springer International Publishing, 2016.
23. M. Joswig, "Knowledge-based seismogram processing by mental images," *IEEE Trans. Syst. Man Cybern.*, vol. 24, no. 3, pp. 429–439, Mar. 1994, DOI: <https://doi.org/10.1109/21.278992>.
24. C.-C. Chang and C.-J. Lin, "LIBSVM: A library for support vector machines," *ACM Trans. Intell. Syst. Technol.*, vol. 2, no. 3, pp. 1–27, Apr. 2011, DOI: <https://doi.org/10.1145/1961189.1961199>.

25. M. N. Wright and A. Ziegler, "textbfranger : A Fast Implementation of Random Forests for High Dimensional Data in textitC++ and textitR," *J. Stat. Softw.*, vol. 77, no. 1, 2017, DOI: <https://doi.org/10.18637/jss.v077.i01>.
26. D. Henao - león, A. Camilo Báez - Alarcón, y J. Bethsaid Pedroza - Rojas, "Metodología para determinar la viabilidad de generación de energía eléctrica por medio del recurso eólico", *Revista Investigación e Innovación en Ingenierías*, vol. 6, n°. 2, 2018. DOI: <https://doi.org/10.17081/invinno.6.2.3108>
27. R. Avellaneda, S. Cabrera, P. A. Martínez, y C. G. Donoso Albarracín, "Apoyo tecnológico para la fidelización y captación de nuevos clientes por medio de una aplicación móvil", *Investigación e Innovación en Ingenierías*, vol. 5, n.º 1, pp. 92-101, 2017. DOI: <https://doi.org/10.17081/invinno.5.1.2618>
28. L. Dong, X. Li, and G. Xie, "Nonlinear Methodologies for Identifying Seismic Event and Nuclear Explosion Using Random Forest, Support Vector Machine, and Naive Bayes Classification," *Abstr. Appl. Anal.*, vol. 2014, pp. 1–8, 2014, DOI: <https://doi.org/10.1155/2014/459137>.