



UNIVERSIDAD NACIONAL DE COLOMBIA

**Metodología para el reconocimiento de patrones
sísmico-volcánicos no estacionarios mediante técnicas de
aprendizaje adaptativo**

Paola Alexandra Castro Cabrera

Universidad Nacional de Colombia
Facultad de Ingeniería y Arquitectura
Departamento de Ingeniería Eléctrica, Electrónica y Computación
Manizales, Colombia
2023

Metodología para el reconocimiento de patrones sísmico-volcánicos no estacionarios mediante técnicas de aprendizaje adaptativo

Paola Alexandra Castro Cabrera

Tesis presentada como requisito parcial para optar al título de:
Doctora en Ingeniería - Línea de Automática

Director:

Dr. Ing. Mauricio Orozco Alzate

Co-Director:

PhD. John Makario Londoño Bonilla

Línea de Investigación:

Automática - Identificación de patrones sísmicos

Grupo de Investigación:

Grupo de Procesamiento y Reconocimiento de Señales

Universidad Nacional de Colombia
Departamento de Ingeniería Eléctrica, Electrónica y Computación
Manizales, Colombia

2023

A mi hijita adorada, por ser la luz de mi vida y mi gran inspiración para lograrlo.

A mi esposo, por ser la voz de aliento que siempre me reconforta.

A mis padres y hermanas, por nunca perder la fe y regalarme sus oraciones.

Agradecimientos

A puertas de dar por concluido un peldaño académico de gran envergadura, que ha costado considerables sacrificios (pero que también ha suscitado agradables satisfacciones), quisiera hacer un sencillo reconocimiento a aquellas personas que de una u otra manera han intervenido en la construcción de este proceso investigativo, que no solo ha contribuido a mi formación académica, sino que de manera especial ha forjado un crecimiento personal en la integralidad, la emocionalidad y la fe. A ustedes (a quienes menciono y a aquellos que tal vez olvide nombrar pero que saben hicieron parte de este andar), deseo expresar mis más sinceros agradecimientos, porque sin su apoyo difícilmente hubiese alcanzado este objetivo.

Antes que nada, quiero elevar una acción de gracias al Padre Santo por su eterna generosidad, porque me ha dado una vida privilegiada, repleta de bendiciones, que constituyeron mi diario transcurrir durante el curso de este posgrado. Gracias a Dios por poner en mi camino a las personas indicadas y proveerme de las herramientas adecuadas para trabajar en pro de este logro. Gracias por no permitirme desfallecer, porque a pesar de los continuos tropezones, siempre tendió su mano y multiplicó mis alientos para dar lo mejor de mí, pese a mis debilidades.

En el ámbito académico, quisiera agradecer muy sinceramente a mi tutor y director de tesis, el profesor Mauricio Orozo Alzate, quien con una inagotable paciencia, guió con sabiduría y orden cada paso que daba en este peregrinar investigativo. Su estricta rigurosidad en cada proceso experimental y de escritura académica, fortalecieron mis competencias científicas en la ingeniería. Gracias a su perseverancia en la dirección de mi estudio doctoral, logré encaminar este trabajo que en varias ocasiones se vio desfigurado; gracias por hacer de cada desacierto, una oportunidad de crecimiento profesional.

No puedo pasar por alto expresar mi gratitud a cada uno de los estudiantes y profesores que conforman el Grupo de Control y Reconocimiento de Señales, en especial a su director, el profesor César Germán Castellanos Domínguez, quien a fuerza de alcanzar la excelencia, me ayudó a redefinir perspectivas y consolidar logros. A los demás miembros, muchas gracias; cada uno de ellos contribuyeron de alguna manera a la construcción de este escalafón.

También quisiera extender mis agradecimientos a los grupos de investigación e instituciones educativas que hicieron parte del desarrollo de esta trabajo investigativo. Gracias a los profesores y estudiantes del grupo de investigación del Departamento de Eléctrica de la Universidad de la Frontera (de Temuco-Chile), el cual me acogió durante el desarrollo de la primera parte de mi pasantía internacional y realizó importantes aporte experimentales a este trabajo. Así mismo, agradezco sinceramente al profesor Carlos Andrés Mera, perteneciente al Departamento de Sistemas de Información del Instituto Tecnológico Metropolitano (en Medellín-Colombia) por sus valiosos aportes y

orientación durante la segunda parte de mi pasantía; su contribución fue decisiva en la constitución de la esencia de esta tesis.

De igual manera, debo agradecer el apoyo financiero recibido durante el transcurso del doctorado, lo cual facilitó enormemente el desarrollo y ejecución de este trabajo. Gracias al Programa Nacional de Formación de Investigadores, modalidad Doctorado Nacional, Convocatoria 617, de MINCIENCIAS (antes COLCIENCIAS), por la financiación de esta tesis doctoral.

En última instancia pero no menos importante, quisiera manifestar mi más sentido agradecimiento a quienes tienen el verdadero mérito de este culmen: mi familia, mi motor, mi razón de ser. Ustedes hicieron de este trajinar, un recorrido llevadero, a pesar de la carga tan pesada que tantas veces quise soltar. A mi hijita Mariana, mi tesoro invaluable, mi mayor bendición: gracias por ser la mayor inspiración de mi vida; su sonrisa ha endulzado mi día a día desde su llegada a este mundo. A mi esposo Andrés Mauricio, gracias por alentarme a no desfallecer, por ser mi co-equipero idóneo y el soporte en mi ardua lucha por lograrlo. A mis padres, Álvaro Iván y Flor Aydee, muchas gracias por el desbordante amor que siempre me han brindado, por su apoyo incondicional en cada decisión que he tomado, y por recordarme continuamente que los sueños se logran con esfuerzo, siempre de la mano del Señor y la Santísima Virgen. A mis hermanas Carolina y Sandra, gracias por su buena energía, por ser un ejemplo de valentía y perseverancia; los retos que ustedes han asumido me han enseñado a ser más aguerrida y a afrontar la vida con tesón y decisión. ¡Gracias familia! Esto es de ustedes.

Paola Alexandra Castro C.

Resumen

Metodología para el reconocimiento de patrones sísmico-volcánicos no estacionarios mediante técnicas de aprendizaje adaptativo

El monitoreo volcánico constituye una tarea imprescindible en el contexto de prevención y gestión del riesgo; en este sentido, los observatorios vulcanológicos y sismológicos cumplen una misión trascendental en la declaración de alertas tempranas de erupción volcánica. Y dentro de esta labor, la correcta clasificación de la sismicidad representa un insumo indispensable para la interpretación del fenómeno volcánico y la caracterización de dinámicas eruptivas; por tal motivo, es necesario que la clasificación se lleve a cabo de manera ágil y confiable. A través de la sismicidad correctamente etiquetada, los expertos analistas pueden caracterizar los procesos que estarían ocurriendo al interior de un volcán, e identificar precursores de una erupción. Sin embargo, la acertada discriminación de eventos sísmicos suele verse afectada por la migración de fuentes sísmicas, alteraciones en la dinámica de fluidos, cambios en los mecanismos de generación de grietas, entre otras situaciones, que pueden modificar la distribución de probabilidad de los registros sísmicos (cambios de concepto), y por tanto, incrementar la no estacionariedad de estas señales.

Durante las últimas dos décadas, en las áreas de Aprendizaje Automático y Reconocimiento de Patrones se han desarrollado múltiples técnicas y herramientas aplicadas a enfoques de representación y clasificación de sismos volcánicos, entre las cuales destacan las redes neuronales, las máquinas de vectores de soporte, los modelos ocultos de Markov, entre otros, enmarcados (incluso) en contexto muy actuales como el Aprendizaje Profundo. En general, los estudios hallados al respecto en el estado del arte muestran resultados optimistas; sin embargo, se detalla que éstos son consecuencia de configuraciones experimentales restrictivas que disminuyen la complejidad del problema de clasificación planteado; una condición común es el uso de datos procedentes de periodos cortos de registro y poco representativos de la actividad volcánica. Esta limitación simula un entorno estacionario donde los modelos predictivos tradicionales funcionan eficazmente, pero que van en detrimento al actuar por un tiempo prolongado cuando los cambios de concepto se hacen evidentes.

Siendo notable la necesidad de disponer de sistemas automáticos de clasificación que satisfagan las “condiciones realistas” del problema, como requerimiento esencial en la vigilancia volcánica, en esta tesis se propone el desarrollo de una metodología de reconocimiento de patrones sísmicos, a partir de registros de eventos volcánicos, que considere la adaptación de la clasificación a entornos y condiciones realistas y cambiantes. Para ello, se diseñó un modelo de clasificación centrado en el área del aprendizaje adaptativo y basado en aprendizaje incremental (aún no explorados en datos sísmicos), con el cual se trata el paradigma del cambio del concepto, de tal manera que algunas propiedades como la recurrencia continua de datos adquiridos, la naturaleza multiclase de los registros, los efectos geológicos y las restricciones de generalización en la clasificación, sean contempladas, aprovechadas y eventualmente contrarrestadas al momento de hacer la clasificación automática de los sismos.

Palabras clave:

Aprendizaje incremental, Cambio de concepto, Detección de cambios, Flujo de datos, Monitoreo volcánico, Reconocimiento de Patrones, Señal sísmica.

Abstract

Methodology for the recognition of non-stationary seismic-volcanic patterns using adaptive learning techniques

Volcanic monitoring is an essential task in the context of prevention and risk management; in this sense, the volcanological and seismological observatories fulfill a transcendental mission in the declaration of early warnings of volcanic eruptions. And within this labor, the correct classification of seismicity represents an indispensable supply for the interpretation of the volcanic phenomenon and the characterization of eruptive dynamics; for this reason, it is necessary to carry out the classification in an agile and reliable manner. Through correctly labeled seismicity, expert analysts may characterize the processes that would be taking place inside a volcano, and identify precursors of an eruption. However, the accurate discrimination of seismic events is usually affected by the migration of seismic sources, alterations in fluid dynamics, changes in crack generation mechanisms, among other situations. These conditions may modify the probability distribution of seismic records (concept drifts), and therefore, strengthen the non-stationarity of these signals.

During the last two decades, multiple techniques and tools have been developed in Machine Learning and Pattern Recognition areas, and applied to representation and classification approaches of volcanic earthquakes. Neural networks, support vector machines, hidden Markov models are the most outstanding methods that have even been framed in very current contexts such as Deep Learning. In general, the studies found in this regard in the state of the art show optimistic results, however, they are the consequence of restrictive experimental configurations that decrease the complexity of the posed classification problem. A common condition is data usage from short periods of registration and unrepresentative of the volcanic activity. This limitation simulates a stationary environment where traditional predictive models work effectively, but their performance deteriorates when acting for a long time because concept changes become evident.

The need to have automatic classification systems that satisfy the “realistic conditions” of the problem becomes evident, as an essential requirement in volcanic monitoring and eruption prediction. Therefore, this thesis proposes the development of a seismic pattern recognition methodology, based on records of volcanic events, which considers the adaptation of the classification to realistic and changing environments and conditions. For this, a classification model focused on the area of adaptive learning and based on incremental learning (not yet explored in seismic data) was designed, with which the concept drift paradigm is treated. This way, some properties such as the continuous arrival of acquired data, the multiclass nature of the records, the geological effects and the generalization restrictions in the classification are considered, exploited and eventually counteracted when automatically classifying the volcanic earthquakes.

Keywords:

Incremental learning, Concept drift, Change detection, Data stream, Volcanic monitoring, Pattern recognition, Seismic signal.

Declaración

Me permito afirmar que he realizado la presente tesis de manera autónoma y con la única ayuda de los medios permitidos y no diferentes a los mencionados en la propia tesis. Todos los pasajes que se han tomado de manera textual o figurativa de textos publicados y no publicados, los he reconocido en el presente trabajo. Ninguna parte del presente trabajo se ha empleado en ningún otro tipo de tesis.

Manizales, diciembre de 2023

Paola Alexandra Castro Cabrera

“Even the recognition of an individual whom we see every day is only possible as the result of an abstract idea of him formed by generalisation from his appearances in the past.”

—James G. Frazer

Índice general

Agradecimientos	VII
Resumen	IX
Abstract	X
Lista de figuras	XVII
Lista de tablas	XIX
I. Introducción y Conceptualización	1
1. Preliminares	3
1.1. Motivación	3
1.2. Planteamiento del problema	6
1.3. Revisión general de la literatura	8
1.3.1. Enfoques de representación aplicados al reconocimiento automático de eventos sísmicos	9
1.3.2. Enfoques de clasificación automática aplicados al reconocimiento de eventos sísmicos	10
1.4. Objetivos	12
1.4.1. Objetivo general	12
1.4.2. Objetivos específicos	12
1.5. Alcances	13

1.6. Contribución de la tesis	14
1.7. Estructura del documento	15
1.8. Resumen del capítulo	17
2. Conceptualización sobre vulcanismo	18
2.1. Vulcanismo y amenaza volcánica	18
2.1.1. Metodologías de vigilancia volcánica	21
2.2. Monitoreo sísmico volcánico	23
2.2.1. Adquisición y transmisión de datos	23
2.2.2. Clases de sismos	25
2.3. Evolución espacio-temporal de la sismicidad	28
2.4. Aplicación de AI, ML y PR en el monitoreo volcánico	28
2.4.1. Aprendizaje automatizado en clasificación de señales sísmicas	29
2.5. Evaluación de los sistemas automatizados	31
2.5.1. Medidas de desempeño básicas	31
2.6. Resumen del capítulo	32
3. Propuesta metodológica de un sistema adaptativo	34
3.1. Generalidades de los sistemas de reconocimiento de patrones	35
3.2. Metodología orientada al reconocimiento de patrones sísmicos empleando técnicas adaptativas e incrementales	38
3.3. Bases de datos empleadas	40
3.3.1. Base de datos del Volcán Nevado del Ruiz	40
3.3.2. Base de datos del Volcán Villarrica	41
3.4. Pre-procesamiento de señales sísmicas	43
3.4.1. Depuración de datos	43
3.4.2. Segmentación de sismos	45
3.5. Resumen del capítulo	45

II. Identificación de sismos volcánicos mediante aprendizaje incremental	46
4. Estimación de representaciones	48
4.1. Trascendencia de la representación	49
4.1.1. Tipos de representación	50
4.2. Modelos de representación para señales sísmicas	51
4.2.1. Análisis temporal de características	56
4.2.2. Análisis espectral	57
4.2.3. Transformada wavelet y análisis multiresolución	63
4.3. Extracción de medidas de representación	65
4.4. Marco experimental	70
4.5. Resultados y discusión	73
4.6. Resumen del capítulo	76
5. Identificación del cambio de concepto	78
5.1. Problema del <i>cambio de concepto</i>	79
5.1.1. Tipos de cambios de concepto	80
5.1.2. Flujo de datos en contextos cambiantes	81
5.2. Detección del <i>cambio de concepto</i>	82
5.3. Algoritmos de detección	83
5.3.1. Consideraciones algorítmicas	83
5.3.2. Métodos aplicados	84
5.4. Marco experimental	86
5.4.1. Pre-procesamiento de datos	86
5.4.2. Diseño de conjunto de datos: selección de observaciones	88
5.4.3. Experimentos diseñados	89
5.5. Resultados y discusión	91
5.6. Resumen del capítulo	94

6. Clasificación adaptativa de sismos	96
6.1. Aprendizaje adaptativo en entornos no-estacionarios	97
6.1.1. Exigencia de sistemas adaptativos en entorno sismo-volcánico	98
6.2. Aprendizaje incremental	98
6.3. Estrategias usadas para el aprendizaje en entornos no-estacionarios	100
6.4. Algoritmo incremental adaptativo para el manejo del cambio de concepto en registros sísmicos volcánicos	102
6.5. Marco experimental	105
6.5.1. Base de datos y pre-procesamiento	106
6.5.2. Experimentos diseñados	108
6.6. Resultados y discusión	110
6.6.1. Experimento 1: Elección de la estrategia de normalización	110
6.6.2. Experimento 2: Ajuste de la longitud de la ventana de datos	112
6.6.3. Experimento 3: Comparación de estrategia adaptativa vs. aprendizaje tradicional	114
6.6.4. Experimento 4:	116
6.7. Resumen del capítulo	118
III. Conclusiones, Anexos y Bibliografía	119
7. Conclusiones	121
7.1. Conclusiones	121
7.2. Trabajo futuro	122
A. Algoritmo STA/LTA	124
B. Algoritmo ReliefF	126
C. Algoritmo Learn++	128
Bibliografía	131

Índice de figuras

1-1.	Diagrama de bloques de un sistema tradicional de reconocimiento de patrones	8
2-1.	Localización de los volcanes activos en Colombia. Tomado de [García and Mendez-Fajury, 2017]	20
2-2.	Estación típica de monitoreo sísmico (perteneciente al OVSM). Imagen tomada de [Orozco-Alzate et al., 2012]	25
2-3.	Formas de onda y espectrogramas de los cuatros principales tipo de sismos volcánicos (señales provenientes del volcán Nevado del Ruiz).	27
3-1.	Esquema de clasificación adaptativa de eventos sísmicos basada en algoritmos de aprendizaje incremental	39
4-1.	Sismo volcánico de la clase VT con parámetros marcados.	57
4-2.	Ejemplo de espectrograma de un sismo volcánico perteneciente a la clase VT.	60
4-3.	Esquema del proceso de generación de los MFCCs	62
4-4.	Gráfica de dispersión del conjunto de datos del VNR. Los ejes corresponden a las tres mejores características seleccionadas del conjunto de características concatenadas tras aplicar SFS: C.ca1: frecuencia correspondiente al centroide del contorno espectral; C.ca2: derivada de primer orden de los primeros MFCC; C.ca3: la desviación estándar de la señal sísmica.	76
5-1.	Deterioro de la precisión del clasificador al pasar por diferentes periodos de actividad volcánica, volcán Villarrica. Se indica el nivel de las alertas asignado por el OVDAS (de mayor a menor: rojo, naranja, amarillo, verde [SERNAGEOMIN et al., 2015].)	92
5-2.	Definición de un entorno cambiante, según el criterio SPLL, sobre la dinámica del volcán Villarrica.	93
5-3.	Identificación de cambios significativos en la actividad volcánica a través de la suma de las distancias 1-NN, volcán Villarrica.	94

6-1. Esquema de clasificación adaptativa de eventos sísmicos usando el algoritmo incremental Learn++.SIMC.	106
6-2. Número de eventos sísmicos ocurridos en orden cronológico.	107
6-3. Influencia de la estrategia de normalización de datos en el rendimiento de la clasificación.	111
6-4. Selección de longitud de la ventana deslizante.	113
6-5. Comparación del rendimiento del clasificador 3-NN entrenado y probado dentro de un marco de aprendizaje incremental contra el mismo clasificador que trabaja bajo un enfoque de aprendizaje tradicional.	115
6-6. Comparación de rendimiento del clasificador 3-NN entrenado y probado dentro de un marco de aprendizaje incremental contra el mismo clasificador que es adaptativo pero no incremental.	117

Índice de tablas

4-1. Compendio de principales estudios revisados y resumen de sus configuraciones experimentales. Tabla creada mediante la ampliación y actualización de la contenida en [Orozco-Alzate et al., 2012].	53
4-2. Sub-bandas de frecuencias de acuerdo a niveles wavelet	69
4-3. Matrices de confusión y medidas de desempeño para los cuatro conjuntos de representaciones bajo comparación, con datos del VNR.	74
4-4. Matrices de confusión y medidas de desempeño para (a) la combinación/concatenación de los cuatro conjuntos de representación evaluados, y (b) mejor subconjunto de características seleccionado por <i>Selección hacia Adelante</i> , con datos del VNR.	75
4-5. Matrices de confusión y medidas de desempeño para los cuatro conjuntos de representaciones bajo comparación, con datos del volcán Villarrica.	77
4-6. Matrices de confusión y medidas de desempeño para (a) la combinación/concatenación de los cuatro conjuntos de representación evaluados, y (b) mejor subconjunto de características seleccionado por SFS, con datos del volcán Villarrica.	77

Parte I.

Introducción y Conceptualización

1. Preliminares

Este capítulo introductorio está destinado a exponer de manera clara y directa el problema investigativo que motivó esta tesis de doctorado, al tiempo que se define la trascendencia del trabajo experimental desarrollado, de conformidad con el estado del arte. En este sentido, inicialmente se presenta la motivación de este trabajo y el planteamiento del problema, vistos desde la gestión del riesgo y el monitoreo volcánico. De igual forma, se hace la contextualización desde diferentes áreas de la ingeniería automática, partiendo de la identificación de las limitaciones de los actuales sistemas de clasificación de sismos, encontradas en la revisión de literatura acá expuesta. A continuación, se detallan los objetivos de la tesis, seguidos de los alcances y contribuciones de la misma. Finalmente, se expone la estructura ordenada que tendrá el presente documento para dar claridad a la secuencia de su contenido.

1.1. Motivación

La percepción de la gestión del riesgo de desastres por fenómenos naturales, en particular las erupciones volcánicas, ha cobrado mayor importancia debido principalmente al acelerado crecimiento demográfico global que ha llevado al asentamiento de comunidades en zonas de alta vulnerabilidad, lo cual requiere de la declaración de alertas tempranas que favorezcan la prevención de decesos [Loughlin et al., 2015]. El monitoreo volcánico representa una labor indispensable en este contexto, y los observatorios vulcanológicos, como centros de monitoreo que ejecutan la adquisición, almacenamiento y procesamiento de datos volcánicos, son entes fundamentales que contribuyen a la mitigación de amenazas volcánicas. Con base en información extraída de registros sísmicos y estudios provenientes de otras disciplinas que componen el monitoreo volcánico tales como la geofísica, geodesia y geoquímica, entre otras, los analistas expertos de los observatorios vulcanológicos identifican y caracterizan dinámicas eruptivas.

Las señales sísmicas son manifestaciones mecánicas de procesos físicos y químicos particulares dados al interior del sistema de conductos de los volcanes, representando –en conjunto con otras variables geofísicas– diferentes estados de actividad volcánica. Por lo tanto, caracterizar adecuadamente patrones de dinámica sísmica en cada volcán puede conducir a la identificación de precursores de posibles erupciones y, en consecuencia, a la reacción temprana de los organismos encargados para la mitigación del peligro volcánico. Para lograr tal fin, analizar la información procedente de la sismología del volcán resulta concluyente para comprender el fenómeno eruptivo [McNutt, 2002].

Dentro de las tareas principales que debe realizar el personal experto de los observatorios vulcanológicos se encuentra la categorización de las señales sísmicas dentro de los correspondientes tipos

de eventos ¹ sísmico-volcánicos (asignación de etiqueta de clase), la cual se lleva a cabo de manera manual. Esta labor debe realizarse rutinaria y permanentemente, pero suele tornarse compleja y demandante particularmente en periodos de crisis o inestabilidad volcánica, cuando la tasa de ocurrencia de sismos se incrementa dramáticamente [Caudron et al., 2015]. Tal situación conlleva a la falta de disponibilidad inmediata de etiqueta de los sismos registrados, y por ende, supone retrasos en el procesamiento de la información recién adquirida. A la extenuante tarea de clasificación manual, se suma el sesgo asociado al juicio subjetivo de los analistas que asignan las etiquetas, cuya eficiencia está sujeta a su experiencia, e incluso a factores tan humanos e intrínsecos como los emocionales; de ahí que la forma tradicional de identificación de sismos implementada en los observatorios se considere una metodología muy susceptible a errores.

Numerosos estudios que describen el historial de la actividad de diferentes volcanes, han mostrado que los patrones que caracterizan algunos tipos de eventos sísmicos exhiben cambios durante períodos específicos o desde un instante de tiempo en adelante [Sherburn et al., 1999; Roman et al., 2008; Carmona et al., 2012; West, 2013]. Cuando un volcán entra en etapa de reactivación, las fuentes de sismicidad pueden migrar a ubicaciones más próximas del edificio volcánico; tal evolución de las fuentes, junto a las alteraciones que pueden sufrir la dinámica de fluidos y la generación de agrietamientos al interior de la estructura volcánica, puede causar cambios en los procesos subyacentes al sistema de conductos magmáticos y, por lo tanto, conducir a un comportamiento no estacionario de las señales sísmicas [Triastuty et al., 2009; Benson et al., 2010; Sheldrake et al., 2016]. En consecuencia, la acertada discriminación de los eventos sísmicos se ve comprometida debido a la distribución de probabilidad cambiante en el tiempo de un conjunto de registros volcánicos, de diferente tipo, que ahora pueden estar compartiendo características similares.

Durante las dos últimas décadas, la literatura de áreas como reconocimiento de patrones (*pattern recognition - PR*), inteligencia artificial (*artificial intelligence - AI*), minería de datos (*data mining - DM*) y aprendizaje de máquina (*machine learning - ML*), ha propuesto numerosos trabajos sobre la clasificación automática de sismos, proporcionando herramientas y métodos para construir sistemas autónomos de identificación que permitan compensar la alta demanda del etiquetado manual [Orozco-Alzate et al., 2012]. Usualmente, tales sistemas se han implementado mediante dos etapas centrales: la extracción de características (representación) y la clasificación. En el primer caso, las características se extraen principalmente de la señal cruda de los eventos sísmicos, ya sea directamente en el dominio del tiempo o utilizando representaciones basadas en descomposición o transformaciones. Características estadísticas [Curilem et al., 2009], parámetros de forma de onda [Ibs-von Seht, 2008], modelos regresivos variables en el tiempo [Bellahsene and Taleb-Ahmed, 2018], medidas no lineales y de complejidad [Ramírez-Rojas et al., 2018], son algunos de los métodos de extracción de características que se han aplicado.

Asimismo, otras formas de representación han empleado técnicas de transformaciones al dominio de la frecuencia, generalmente mediante el espectro de Fourier [Orozco-Alzate et al., 2015; Soto et al., 2018], que a su vez involucra representaciones derivadas de los coeficientes cepstrales en las frecuencia Mel [Alvarez et al., 2012] y coeficientes predictivos lineales [Giacco et al., 2009]. También

¹En esta tesis se hace referencia a “evento” como la manifestación física de los procesos geofísicos y químicos dados al interior del volcán. Y se denota como “señal” a la serie de tiempo que representa al “evento” volcánico.

se han considerado descomposiciones más robustas para tratar con señales no estacionarias como análisis en tiempo-frecuencia [Chen et al., 2016] y transformada wavelet empírica [Kalra et al., 2020]. En cuanto a la detección y clasificación, los modelos ocultos de Markov (*Hidden Markov Models* - HMM) [Ibáñez et al., 2009; Bicego et al., 2015; Trujillo-Castrillón et al., 2018], las redes neuronales artificiales (*Artificial Neural Networks* - ANN) [Scarpetta et al., 2005; Esposito et al., 2013; Bueno et al., 2019], las máquinas de vectores de soporte (*Support Vector Machine* - SVM) [Curilem et al., 2014; Lara-Cueva et al., 2017], y los clasificadores bayesianos [Dong et al., 2016] son algunas de las técnicas comúnmente empleadas para la identificación de clase de sismos. Algunas extensiones mejoradas de estos métodos ya está siendo empleadas en esta aplicación, como es el caso de las redes neuronales profundas (desarrolladas en los campos de *Deep Learning [DP]* - aprendizaje profundo, y *Transfer Learning [TL]* - aprendizaje por transferencia) [Titos et al., 2018, 2019].

Como consecuencia de la dependencia con la configuración del modelo de aprendizaje, la parametrización del clasificador, el número de clases observadas y el tamaño de la muestra, la precisión de los resultados en los trabajos mencionados se estima altamente variable. Además, la mayoría de estos enfoques se aplican bajo condiciones experimentales muy controladas y sin hacer consideraciones cronológicas de los eventos sísmicos durante el entrenamiento de los modelos, eludiendo así la dinámica cambiante propia de la actividad volcánica [Malfante et al., 2018]. A este aspecto, se suma la adquisición de un alto número de eventos en cortos lapsos de tiempo (que conforman un ‘flujo de datos’ – *data stream* en inglés), lo cual de entrada sugiere la necesidad de hacer aproximaciones experimentales al problema mediante el contexto de *Big Data* (datos masivos) o similares [Yu et al., 2018]. Lo anterior, unido a aspectos previamente señalados como la complejidad de los diferentes mecanismos físicos/químicos que dan lugar a las señales sísmicas y la posible migración de fuentes sismogénicas, contribuyen a la constitución de la dinámica volcánica como un contexto en constante evolución.

Un entorno cambiante como el anteriormente descrito, al igual que la mayoría de aplicaciones del mundo real, tiende a presentar cambios en la distribución de probabilidad subyacente a los datos que produce [Žliobaitė et al., 2016]. En la literatura relacionada este proceso es conocido como *cambio del concepto* (*concept drift* en inglés), el cual podría definirse brevemente como cambios en las propiedades estadísticas de una variable en particular, dados de manera imprevista. Como resultado, los patrones inducidos con base en datos pasados podrían no ser relevantes para la predicción de datos actuales, conllevando al detrimento, a lo largo del tiempo, del desempeño del modelo predictivo usado [Lu et al., 2018].

En contraste a los enfoques supervisados tradicionales para la clasificación de sismos que asumen distribuciones de datos invariables en el tiempo, este trabajo propone una metodología de carácter predictivo, orientada a la identificación de clase de señales sísmicas de origen volcánico que hace frente al problema del cambio de concepto. La metodología se centra en un modelo adaptativo de carácter incremental, basado en ensamble de clasificadores que selecciona y pondera sus componentes dinámicamente para clasificar lotes o *batches* de datos provenientes de contextos no estacionarios. Adicionalmente, la estrategia propuesta hace uso de modelos entrenados en el pasado para confrontar estados recurrentes y para clasificar datos sin etiqueta real disponible. En conjunto, mediante una exploración detallada de las formas de representación de las señales sísmicas, en

combinación con una estrategia de clasificación y evaluación, se ha configurado una metodología adaptativa de identificación de clase de sismos volcánicos capaz de sostener su desempeño a través del tiempo, incluso en periodos de inestabilidad volcánica.

1.2. Planteamiento del problema

La asignación manual de etiquetas de clase, aunque pareciera obsoleta, aún continúa siendo la metodología de clasificación de sismos empleada en los observatorios vulcanológicos y sismológicos de Colombia y en la mayor parte del mundo. En consecuencia, la necesidad de contar con sistemas automatizados de identificación de eventos que permitan soportar y aliviar la labor de los analistas expertos ha motivado un creciente número de investigaciones en las últimas décadas, y la proposición de enfoques tanto en representación de datos como en clasificación aplicados a registros sísmicos (ver revisión de la literatura en la Sección 1.3). Particularmente en la etapa de clasificación, se han planteado múltiples estrategias, entre las cuales se destacan la clasificación basada en densidades de probabilidad o verosimilitudes, sobresaliendo en ellas los HMM, la clasificación basada en disimilitudes, como el clasificador de los k vecinos más cercanos (k -NN), los clasificadores geométricos, como las ANN y las SVM, la combinación de clasificadores, entre otros. No obstante, tales desarrollos metodológicos están sustentados en estudios experimentales llevados a cabo bajo “condiciones de laboratorio”; esto es, bajo restricciones del fenómeno estudiado donde se obvian consideraciones que eventualmente podrían afectar el desempeño de un sistema de reconocimiento de patrones si es puesto a prueba en escenarios reales.

Los resultados optimistas alcanzados por tales aproximaciones son consecuencia de un planteamiento simplificado del problema de clasificación y de los experimentos ejecutados, pasando por alto (en muchas ocasiones) la naturaleza cambiante del contexto volcánico, que podría definirse como un proceso no-estacionario donde el cambio de concepto interviene. Algunas de las limitaciones encontradas son las siguientes:

- Durante los periodos de inestabilidad volcánica, cuando la cantidad de eventos sísmicos presentados en un corto periodo de tiempo aumenta de manera exponencial, el procesamiento y etiquetamiento manual de los registros sísmicos suele retrasarse en días, e incluso, en meses. Tener bases de datos actualizadas, adecuadamente etiquetadas, implica un costo humano extremadamente alto que generalmente no logra suplirse en tiempos de crisis [Orozco-Alzate et al., 2012]. Adicionalmente, se contempla la disminución en la precisión de la tarea de clasificación manual, debido a las extensas jornadas de trabajo a las que se ven expuestos los analistas expertos. Lo anterior se suma a la existencia de un sesgo subjetivo inherente a la tarea de inspección y emisión de juicio humano.
- Las aplicaciones del mundo real requieren de modelos de predicciones que funcionen en tiempo real (valga la redundancia), lo cual implica una serie de configuraciones *on-line* que conlleva a desafíos adicionales. Los sistemas supervisados de aprendizaje tradicionales diseñados para la clasificación automática de sismos, asumen el manejo de datos organizados en bases de

datos estáticas; sin embargo, en aplicaciones reales, usualmente éstos están dispuestos en flujos de datos. De manera análoga, la sismología volcánica se puede considerar como un contexto generador de *data streams*, donde la producción consecutiva de datos –enviados teleméricamente desde las estaciones sísmicas instaladas en los volcanes y almacenados en los observatorios vulcanológicos– crece a medida que las redes de monitoreo se hacen más densas. Lo anterior, sumado al hecho que el volumen de datos suele incrementarse vertiginosamente durante las reactivaciones o crisis volcánicas. En contraste a esta situación, los enfoques propuestos no están partiendo de la presunción de la existencia de *concept drifts* que provoca variaciones en la distribución de los datos; esto es, los datos de prueba o los generados en tiempo real provienen de una distribución diferente a los usados durante el entrenamiento. De ahí que las predicciones de tales modelos vayan en detrimento a lo largo del tiempo.

- Un concepto o variable puede tomar tiempo en hacer evidente los cambios que experimenta durante la ejecución de una aplicación en particular o la evolución de un fenómeno; incluso, tales cambios pueden ser subyacentes al mismo, y por tanto, mantenerse indetectables a una inspección trivial. En el caso del fenómeno volcánico explorado mediante sus registros sísmicos, la actividad del volcán pueden manifestar algún tipo de alteración (y hacerla perceptible) solo tras el análisis de largos periodos de registros. Muchos estudios experimentales aplicados a esta área, han empleado bases de datos de pequeñas proporciones que no son representativas de la dinámica del volcán, o bien, que cuentan con una cantidad de datos cuantiosa pero todos recopilados durante un corto periodo de actividad sísmica, lo cual tampoco resulta representativo. La selección de un período muy corto de monitoreo sísmico podría generar un sesgo durante el entrenamiento de un modelo predictivo, dado que podría ocurrir que los datos empleados pertenezcan a una única etapa ya sea de calma o de reactivación del volcán, y por tanto, el modelo aprenderá de unos patrones muy específicos que seguramente dejarán de ser relevantes para la predicción de nuevos datos adquiridos tiempo después.
- En estudios experimentales del área es usual encontrar que los resultados de sus métodos de clasificación son evaluados empleando técnicas de validación que implican aleatoriedad en la selección de ejemplos², como es el caso de la validación cruzada (*Cross-Validation*) y sus estrategias derivadas *Leave One Out* y *K-Fold Cross-Validation*. Sin embargo, conformar los conjuntos de entrenamiento y prueba de manera aleatoria implica ignorar la cronología de ocurrencia de los eventos sísmicos, un factor trascendental al momento de interpretar la secuencia de las manifestaciones del fenómeno físico/químico dado al interior del volcán. Mezclar eventos del “pasado” con otros del “futuro” durante la etapa de entrenamiento –en aras de mejorar la capacidad de generalización del modelo– induce al clasificador a aprender de patrones que podrían convertirse en irrelevantes con respecto a otros patrones más actuales que sí pudieran aportar discriminancia, creando un efecto adverso en la predicción. Es así como los ejemplos pertenecientes a cada clase van ocupando regiones más amplias en el espacio de características, y como consecuencia las fronteras de decisión, al ser estáticas, van perdiendo capacidad de discriminación.

²Los términos “objeto” e “instancia” se emplean de manera indistinta a lo largo de este trabajo con la misma denotación de “ejemplo”, el cual se define en el siguiente capítulo.

- Los métodos tradicionales de reconocimiento de patrones emplean algoritmos de aprendizaje supervisados que no contemplan evoluciones en conceptos involucrados en procesos no estacionarios como los dados en un escenario volcánico real. Tales estrategias crean una única base de conocimiento durante la etapa de entrenamiento del modelo, que permanece estática en el tiempo, y por tanto, solo funcionan adecuadamente al ser aplicados en entornos estacionarios. Tratar entornos que implican procesos de generación de *data streams*, inevitablemente conlleva a enfrentar el problema de *concept drift*, lo cual nos ubica en un contexto de aprendizaje supervisado en línea que demanda el uso de un almacenamiento reducido y la aplicación de un enfoque de aprendizaje adaptativo e incremental. Los algoritmos de clasificación usualmente empleados para la identificación de sismos no están enmarcados dentro de dicho paradigma, y por tanto, no cuentan con mecanismos que les permita adaptarse y responder adecuadamente a las exigencias de un entorno voluble.

En resumen, la falta de “condiciones realistas” exigidas dentro del contexto sísmico-volcánico de los modelos de aprendizaje hasta ahora propuestos, nos ha permitido identificar una serie de problemas conceptuales y metodológicos que han motivado el planteamiento y desarrollo de este trabajo. A partir de tales limitaciones, se ha propuesto una metodología de clasificación adaptativa basada en aprendizaje incremental, la cual identifica y aprende cambios de conceptos presentes en datos procedentes de registros sísmicos que evolucionan en el tiempo, y que actualiza constantemente su base de conocimiento para crear fronteras de decisión adaptativas.

1.3. Revisión general de la literatura

De acuerdo al esquema clásico de un sistema automático de clasificación, como el propuesto en [Duin and Pekalska, 2007] y que se muestra en la Figura 1-1, se ha llevado a cabo una revisión de la literatura general que destaca algunos trabajos relacionados al reconocimiento de patrones sísmicos, centrados principalmente en la etapa de Clasificación. No obstante, siendo conscientes de la importancia de las fases previas a la clasificación –principalmente de la Representación, como un paso crucial para optimizar la capacidad de generalización de un modelo de aprendizaje– vale la pena mencionar algunas propuestas que han concentrado esfuerzos en representar adecuadamente las señales sísmicas:

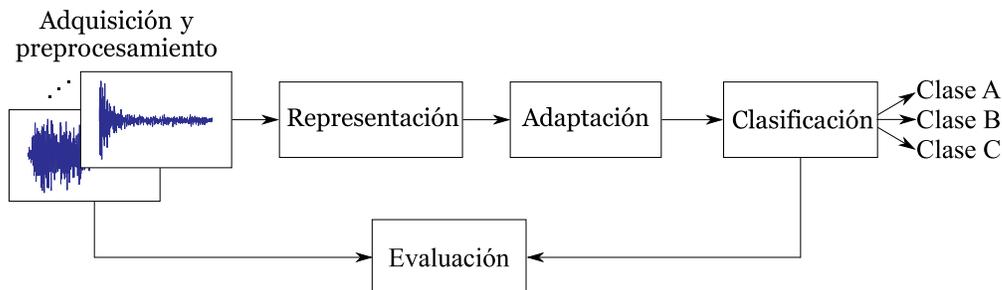


Figura 1-1.: Diagrama de bloques de un sistema tradicional de reconocimiento de patrones

1.3.1. Enfoques de representación aplicados al reconocimiento automático de eventos sísmicos

La forma tradicional de representar objetos, a fin de clasificarlos en categorías, es mediante características, que pueden definirse como mediciones de ciertos atributos o propiedades de tales objetos. En el estado del arte se encuentran numerosos trabajos que emplean características absolutas para hacer la representación de sismos, generadas a partir de atributos morfológicos, espectrales, o por transformaciones realizadas en el tiempo o en la frecuencia. En este sentido, algunas metodologías propuestas han empleado cálculos que involucran la detección de las ondas P y S (ondas primarias y secundarias, propias de las señales sísmicas [McNutt, 2002]): este es el caso de Rouland et al. [2009], quienes llevan a cabo la discriminación entre sismos tectónicos y tremor volcánico, únicamente determinando la presencia o ausencia de la onda S; mientras que en [Yıldırım et al., 2011], se usaron tales ondas para estimar características discriminantes, como por ejemplo la razón entre la amplitud de las ondas P y S, y un valor de complejidad, definido como la integral del cuadrado de la velocidad del sismograma, con el fin de distinguir sismos tectónicos de explosiones de canteras.

En otros trabajos se obtienen características de las señales sísmicas a partir de la morfología de la señal y su espectro: en el estudio realizado por Ibs-von Seht [2008], por ejemplo, se calcula la impulsividad y duración del evento sísmico, así como otras características espectrales —frecuencia dominante, rango de frecuencias del contorno espectral, frecuencia de la energía máxima del espectrograma, entre otras. De igual manera, en [Curilem et al., 2009] se llevan a cabo cálculos sobre la señal en el tiempo: valor máximo, curtosis, media, desviación estándar, entre otras características; mientras que la frecuencia media de ciertos picos del espectro y la energía en determinada banda de frecuencia, se han calculado en el dominio de la frecuencia.

Otra metodología de caracterización de las señales sísmicas, explorada principalmente por un grupo de autores de la Universidad de Granada - España, está basada en una técnica particular aplicada en reconocimiento de voz, aprovechando las semejanzas existentes entre ambos tipos de señales. En sus publicaciones [Benítez et al., 2006; Ibáñez et al., 2009; Alvarez et al., 2012; Cortés et al., 2014], los autores hacen uso de los coeficientes cepstrales en frecuencias Mel (MFCC - *Mel Frequency Cepstral Coefficients*), además de sus derivadas de primer y —en algunos estudios— de segundo orden, para formar el vector de características que alimenta al clasificador. Tales coeficientes son el resultado de un modelo de análisis espectral por banco de filtros, en el que, básicamente, se aplica la transformada inversa de Fourier del logaritmo de la señal sísmica ventaneada. Esta forma de caracterización ha mostrado resultados satisfactorios en los estudios mencionados, aunque cabe advertir que las bondades de tal representación se ven potenciadas por los efectos de los HMM —clasificador que también ha mostrado resultados muy favorables con una amplia variedad de representaciones.

Por otro lado, algunas publicaciones han demostrado las ventajas de emplear un aprendizaje basado en representaciones relativas como las disimilitudes, en comparación a uno basado en representaciones absolutas (patrones representados como puntos en el espacio de características). Esto, debido a que en algunas aplicaciones reales resulta más práctico derivar una medida relacional que extraer características —también llamados descriptores— creando un espacio de disimilitud que propone

una formulación directa y que permite el uso de clasificadores tan básicos como el k -NN para obtener resultados satisfactorios. Una representación por disimilitudes consiste en hacer comparaciones de objetos (señales sísmicas, en nuestro caso particular) por parejas, empleando alguna medida de disimilitud, como por ejemplo la distancia euclidiana. Estas comparaciones no necesariamente deben hacerse sobre las señales crudas; también pueden lograrse a partir de otras mediciones que se hacen sobre las series de tiempo, como imágenes, histogramas, espectrogramas, entre otros.

En [Orozco-Alzate et al., 2006], por ejemplo, se emplea el cálculo del espectro de las señales, usando dos enfoques diferentes: la transformada rápida de Fourier (FFT - *fast Fourier transform*) y la densidad espectral de potencia, y a partir de estas dos estimaciones, se forma la matriz de disimilitudes, usando dos métricas: la distancia euclidiana y la diferencia de áreas. Finalmente, se emplean clasificadores simples como el k -NN y otros basados en densidad de probabilidad, aplicados en el espacio de disimilitudes, para probar la capacidad de generalización aportada por la representación basada en disimilitudes. Asimismo, en [Porro-Muñoz et al., 2011], se muestran las ventajas de la representación por disimilitudes en el tratamiento de señales sísmicas, como una forma de representar datos, los cuales originalmente estaban presentados en una y dos dimensiones (FFT y espectrogramas, respectivamente); además, en este estudio se propone una medida bidimensional de disimilitud que permite tener en cuenta información sobre la forma y continuidad en todas las direcciones de los datos espectrales.

1.3.2. Enfoques de clasificación automática aplicados al reconocimiento de eventos sísmicos

La clasificación manual y el análisis de las señales sísmicas son tareas fundamentales en el monitoreo rutinario realizado por los observatorios vulcanológicos. Las metodologías que se han desarrollado para llevar a cabo la automatización de esta labor incluyen técnicas que abarcan desde análisis estadísticos básicos [Rouland et al., 2009] hasta la aplicación de lógica difusa [Akhouayri et al., 2015]. Las limitaciones de los modelos determinísticos han llevado a la proposición de métodos más sofisticados en las áreas de reconocimiento de patrones y aprendizaje de máquina, aplicables a datos sísmicos; dentro de aquellos ampliamente difundidos e implementados en el estado del arte se encuentran las ANN y los HMM, por su versatilidad y fácil adaptabilidad a distintos problemas de discriminación automática.

La literatura referencia numerosos trabajos que emplean las ANN para lograr la discriminación de sismos, alcanzando rendimientos destacables [Falsaperla et al., 1996; Del Pezzo et al., 2003; Scarpetta et al., 2005; Langer et al., 2006; Ibs-von Seht, 2008; Diersen et al., 2011; Agliz et al., 2013]. Los estudios que emplean las ANN como enfoque metodológico, si bien coinciden en los resultados satisfactorios, también comparten restricciones y desventajas similares: tanto la definición de las arquitecturas de entrada y salida (número de neuronas por capa), así como la selección del método de entrenamiento apropiado, se determinan por ensayo y error o ajustándose a parámetros sugeridos en publicaciones anteriores. Sin embargo, en [Curilem et al., 2009] compensan este inconveniente haciendo uso de algoritmos genéticos, mediante los cuales optimizan el proceso de entrenamiento (Levenberg-Marquardt), al igual que el número de neuronas de la capa oculta de la ANN.

Por su parte, los HMM, tradicionalmente usados en reconocimiento de voz, también registran un amplio estudio en el estado del arte de la clasificación automática de sismos [Ohrnberger, 2001; Gutiérrez et al., 2006; Ibáñez et al., 2009; Avesani et al., 2012; Bicego et al., 2012; Bhatti et al., 2016; Trujillo-Castrillón et al., 2018], debido a la analogía que existe entre las señales de voz y las sísmicas. Al igual que las ANN, los HMM son modelos paramétricos, por lo tanto, se debe definir aspectos como la topología del modelo, la cantidad de estados del mismo, el número de funciones de densidad de probabilidad gaussiana multivariante y las iteraciones necesarias del algoritmo de Baum-Welch para su entrenamiento. Así pues, aún continúa abierta la discusión sobre cuáles son los parámetros adecuados (en particular, la topología y el número de estados), para alcanzar los mejores resultados. Adicionalmente, aunque en un principio entrenar los HMM resultaba costoso e impreciso, en particular con el popular algoritmo de Maximización de la Esperanza (*Expectation Maximization - EM*), el surgimiento de nuevos y mejores algoritmos como el de Baum-Welch y sus posteriores variantes, ha solucionado —al menos parcialmente— esos problemas [Dymarski, 2011].

Las SVM son otra alternativa explorada por algunos autores para ser aplicada a datos sísmicos. Un ejemplo es el estudio realizado por Ruano et al. [2014], quienes implementan un sistema de detección de eventos sísmicos sobre trazas continuas, para lo cual el problema de clasificación definido es bi-clase: clase 1 \rightarrow evento sísmico, clase 2 \rightarrow evento no sísmico (ruido de fondo). En este trabajo se lleva a cabo un experimento importante que consiste en validar el clasificador (entrenado con datos de una primera estación sísmica) en una segunda estación, obteniendo resultados destacables en términos de sensibilidad y selectividad (mas no de precisión o exactitud). Por su parte, en [Curilem et al., 2014] se hace uso de las SVM para identificar señales sísmicas entre cuatro clases. Empleando características estadísticas y espectrales —las cuales mostraron un buen desempeño en sus trabajos previos realizados con registros del volcán Villarrica— los autores llevan a cabo el entrenamiento de las SVM con señales sísmicas de un segundo volcán (Llaima), obteniendo un rendimiento de clasificación aceptable (alrededor del 80 %). En general, con respecto al desempeño de las SVM en la clasificación de señales sísmicas, aunque la adecuada selección de la función kernel y de los parámetros de regularización conducen a resultados destacados, como los mostrados en los dos trabajos previamente mencionados, la principal desventaja de este método continúa siendo justamente la necesidad de una sintonización metódica para tales parámetros.

Otros autores han optado por esquemas no supervisados [Esposito et al., 2008; Ansari et al., 2009; Messina and Langer, 2011], aprovechando así las bondades de estos métodos para comprender e interpretar mejor la relación entre los datos y la naturaleza de las clases de sismos que resultan identificadas. En relación a esto, un estudio interesante es llevado a cabo en [Langer et al., 2009], donde se presentan resultados de métodos de clasificación supervisada y no supervisada, aplicados a señales sísmicas del volcán Mt. Etna. Cabe anotar que en este estudio solo se emplea un tipo de señal sísmica (tremor volcánico); y que, además, la tarea de clasificación no consiste en asignar una etiqueta de clase a cada sismo volcánico sino en determinar a qué etapa eruptiva pertenece cada ejemplo. Por un lado, en el caso supervisado, se emplearon dos alternativas: ANN (de arquitectura perceptrón multicapa) y SVM, alcanzando desempeños satisfactorios que se aproximan al 82 % y 95 %, respectivamente; en cuanto a los métodos no supervisados, se usó análisis de agrupamiento (CA - *Cluster Analysis*) y mapas auto-organizados (SOM - *Self-Organizing maps*), cuyas

estimaciones de desempeño son básicamente visuales (subjetivas). Puesto que no es posible hacer una comparación directa entre los métodos supervisados y los no supervisados, los autores concluyen que ambos tipos de métodos pueden ser implementados convenientemente pero de forma complementaria (más no disyuntiva), a fin de alcanzar una comprensión más precisa de la relación existente entre el tremor volcánico y el fenómeno eruptivo.

Una alternativa que ha sido tímidamente aplicada al problema planteado en esta tesis, es el denominado *ensamble de clasificadores*, que consiste en esquemas de combinación de clasificadores, y que resulta especialmente útil cuando la aplicación o situación del mundo real permite disponer de más de un clasificador y cada uno de ellos tiene un buen desempeño en determinadas áreas del espacio de características. Un ejemplo relacionado a este método es el estudio realizado por [Duin et al. \[2010\]](#), en cuyo trabajo se consideraron 2100 eventos, “observados” desde cinco diferentes estaciones, y distribuidos equilibradamente en tres clases de eventos: sismos tectónicos, fractura de capa glaciaria y tremor (continuo). El marco experimental consiste en disponer de cinco clasificadores basados en *plantillas de decisión*, cada uno de ellos entrenado con señales provenientes de una de las cinco estaciones, y posteriormente, configura diferentes combinaciones de tales clasificadores. Los autores muestran que, aunque los resultados obtenidos por cada clasificador —que ha sido entrenado para una estación en específico, y validado con señales de otras estaciones— no son muy satisfactorios, combinar todas las observaciones de todas las estaciones produce mejores resultados. Como éste, en el estado del arte se encuentran pocos trabajos aplicados a datos sísmicos usando combinación de clasificadores; no obstante, los estudios en *ensamble de clasificadores* comprenden un área de investigación muy activa y en auge, que ha motivado la creación de espacios de discusión muy productivos, donde constantemente se presentan novedosas propuestas (ver, por ejemplo [[Orozco-Alzate et al., 2019](#)]) que podrían ser probadas en el problema de interés acá planteado.

1.4. Objetivos

1.4.1. Objetivo general

Desarrollar una metodología predictiva para la identificación de eventos sísmico-volcánicos que contrarreste el cambio de concepto inherente a entornos no-estacionarios como el volcánico, empleando técnicas de aprendizaje adaptativo e incremental que permitan una compensación continua en el tiempo del desempeño del modelo predictivo.

1.4.2. Objetivos específicos

1. Definir un esquema de representación de las señales sísmico-volcánicas, orientado a la predicción de clase de tales registros, el cual genere un espacio de características favorable para la detección de cambios en la dinámica volcánica a través del tiempo.

2. Comprobar la existencia de cambios de conceptos asumidos en la dinámica de un volcán mediante el uso de estrategias que detecten cambios en el tiempo, aplicadas a patrones sísmicos caracterizados.
3. Construir una estrategia predictiva supervisada basada en aprendizaje adaptativo e incremental, diseñada bajo la presunción de distribuciones de probabilidad de clase cambiantes en el tiempo, que permita la adaptación del modelo de aprendizaje a condiciones realistas y cambiantes del contexto volcánico.
4. Integrar la estrategia de clasificación propuesta a una metodología de reconocimiento de patrones sísmico-volcánicos, que permita evaluar el desempeño del clasificador a través del tiempo mediante medidas apropiadas para flujo de datos.

1.5. Alcances

De acuerdo a la taxonomía propuesta en [Kuncheva, 2010] sobre las áreas enfocadas a emular las tareas y procesos ejecutados por el cerebro humano, esta tesis la enmarcamos en el área del reconocimiento de patrones, y más específicamente, del *machine learning*, que recientemente se ha fortalecido en estudios teóricos sobre clasificación. La presente investigación, en términos generales, está orientada a resolver el problema metodológico de incrementar –y mantener a través del tiempo– la precisión de los modelos predictivos usados para la identificación de clase de sismos volcánicos, los cuales son altamente proclives a cambios de concepto. Dicho esto, cabe precisar que este trabajo tiene únicamente un alcance metodológico, y por lo mismo, no contempla implementaciones de prototipos de software, debido a la complejidad que precisa la creación de arquitecturas computacionales, que no es el foco de la presente investigación. No obstante, se ha considerado un proceso de validación mediante la simulación de contextos *on-line* que permitan poner a prueba el funcionamiento de las estrategias propuestas en tiempo real.

Continuando con las delimitaciones metodológicas demarcadas, cabe señalar que este trabajo se ha enfocado fundamentalmente en la implementación y estudio de la etapa de clasificación del sistema de identificación de sismos mencionado. Sin embargo, en el capítulo 4, se hace una profundización en la etapa de representación, en virtud del impacto de la definición de una apropiada caracterización en la subsecuente clasificación. De igual forma, se describen etapas previas como la adquisición y pre-procesamiento aunque de manera general, sin desconocer la importancia de las mismas.

Por otra parte, vale la pena puntualizar que la falta de conjuntos de datos de señales sísmicas volcánicas estándar y sin restricción de acceso público, también ha supuesto una limitante predefinida para el desarrollo de este trabajo. Las bases de datos de esta naturaleza, aunque son adquiridas y administradas por instituciones pertenecientes al Gobierno Nacional, no son de dominio público. El suministro de tales bases de datos ha implicado el cumplimiento de estrictos protocolos de adquisición de datos, o en determinado caso, la utilización de convenios entre observatorios vulcanológicos y universidades, como ocurrió en nuestro caso. Lo anterior explica por qué los investigadores uti-

lizan datos de diferentes volcanes, e incluso, distintos conjuntos de datos de un mismo volcán, lo cual limita la evaluación comparativa entre los estudios.

Adicional a lo anteriormente expuesto, existen otros condicionamientos impuestos por la naturaleza propia de las señales sismo-volcánicas y por la metodología de estudio, que impactan en la valoración de las bondades de una estrategia con respecto a otra. Por una parte, el uso de diferentes tipos de medidas de desempeño en los estudios hallados en el estado del arte, dificulta las comparaciones directas entre los resultados de los mismos. Por otra, dependiendo del volcán escogido para la investigación y del periodo de tiempo de la actividad volcánica a analizar, puede variar el número de registros y de clases disponibles para el estudio. Sin embargo, pese a las variables que dificultan el análisis comparativo entre los estudio previos y el nuestro, en este trabajo hemos expuesto una evaluación justa entre las estrategias tradicionales y la acá propuesta que permite destacar las fortalezas de cada caso.

1.6. Contribución de la tesis

De acuerdo a los resultados obtenidos con la implementación de la metodología propuesta, a continuación destacamos las contribuciones de esta tesis en el campo del monitoreo volcánico y del aprendizaje automático para el reconocimiento de sismos:

- Como herramienta básica empleada durante la etapa del pre-procesamiento de las señales sísmicas, se desarrolla un aplicativo de software que permite hacer la segmentación semi-automática de cada evento sísmico-volcánico en cada una de las estaciones en las cuales fue registrado.
- Se presenta un esquema de representación de los registros sísmicos, basada en parámetros calculados sobre la señal o sobre transformaciones de la misma a otros dominios. Este esquema es el compendio de las características que mostraron mayor poder discriminante entre los principales métodos de caracterización encontrados en el estado del arte en el área de clasificación automática de sismos.
- Se introduce el problema de *concept drift* como un componente inherente a la naturaleza de los sismos, derivado de la dinámica propia de un volcán. Mediante el análisis de la evolución de los registros en largos periodos de tiempo, se identifican y se ponen en evidencia los cambios en la distribución de probabilidad de los datos provenientes de los eventos sísmicos. Asimismo, se discute la incidencia de este factor en el proceso de aprendizaje de un sistema automático de reconocimiento de sismos volcánicos.
- En contraste a los algoritmos tradicionales para clasificación automática de sismos volcánicos referidos en la literatura, se propone un modelo adaptativo de aprendizaje incremental, de carácter predictivo, que contrarresta el cambio de concepto propio de un entorno no-estacionario como el involucrado en el fenómeno volcánico, orientado a la asignación de etiquetas de clase de los registros sísmicos.

Dado que las contribuciones mencionadas se generaron a lo largo del trabajo investigativo realizado, la divulgación de sus resultados se ha venido llevando a cabo en publicaciones científicas de *journals* y eventos académicos internacionales, las cuales se relacionan a continuación:

- Castro-Cabrera, P. A., Orozco-Alzate, M., Adami, A., Bicego, M., Londono-Bonilla, J. M., and Castellanos-Domínguez, G. (2014, November). A comparison between time-frequency and cepstral feature representations for the classification of seismic-volcanic signals. In *Iberoamerican Congress on Pattern Recognition* (pp. 440-447). Springer, Cham.
- Orozco-Alzate, M., Castro-Cabrera, P. A., Bicego, M., and Londoño-Bonilla, J. M. (2015). The DTW-based representation space for seismic pattern classification. *Computers & Geosciences*, 85, 86-95.
- Castro-Cabrera, P. A., Orozco-Alzate, M., Castellanos-Domínguez, C. G., Huenupán, F., and Franco, L. E. (2018, November). Supervised and unsupervised identification of concept drifts in data streams of seismic-volcanic signals. In *Ibero-American Conference on Artificial Intelligence* (pp. 193-205). Springer, Cham.
- Bravo, Y. E., Narváez, E. R., Castro-Cabrera, P. A., Bonilla, J. L., and Ordoñez, D. P. (2020). Evaluación de técnicas de extracción de características orientado a la clasificación de señales sísmico-volcánicas del volcán Nevado del Ruiz. *Revista Ibérica de Sistemas e Tecnologías de Informação*, (E25), 147-158.
- Castro-Cabrera, P. A., Castellanos-Domínguez, C. G., Mera-Banguero, C., Franco-Marín, L., and Orozco-Alzate, M. (2021). Adaptive classification using incremental learning for seismic-volcanic signals with concept drift. *Journal of Volcanology and Geothermal Research*. Vol. 413, p. 107211.

1.7. Estructura del documento

Esta tesis se encuentra dividida en tres partes, cada una de ellas subdividida en capítulos, ordenados de la siguiente manera:

La Parte I, denominada *Introducción y Conceptualización*, está compuesta por tres capítulos que conjuntamente hacen una completa contextualización del problema, los propósitos de este trabajo en miras a la resolución del mismo, sus fundamentos teóricos, y una revisión general del estado del arte de las áreas concernientes:

El presente capítulo (el 1) ha mostrado una introducción concreta del problema que centra este trabajo investigativo y la motivación para proponer una solución alternativa. El planteamiento del trabajo desarrollado se enmarca dentro de los objetivos general y específicos propuestos, al igual que en los alcances y contribuciones de la tesis, presentados en este capítulo.

El Capítulo 2 presenta el trasfondo conceptual sobre el vulcanismo en Colombia y la importancia del monitoreo volcánico para la mitigación de desastres por erupción, desde sus diferentes técnicas de vigilancia. Adicionalmente, se definen las clases usuales de sismicidad volcánica empleadas en observatorios vulcanológicos, y se introduce el aprendizaje de máquina y reconocimiento de patrones como medios para la generación de sistemas tecnológicos y autónomos que soporten las funciones del monitoreo volcánico.

En la segunda parte de la tesis, titulada *Identificación de sismos volcánicos mediante aprendizaje incremental*, se describe a lo largo de cuatro capítulos el desarrollo metodológico y experimental del aporte de este trabajo. En este apartado se concentra la contribución de esta tesis.

En el Capítulo 3, se expone de manera general los fundamentos de los sistemas de reconocimiento de patrones como base para la propuesta metodológica de esta tesis de un sistema autónomo adaptativo con técnicas incrementales, la cual se expone y justifica ampliamente. Asimismo, se describen las bases de datos empleadas en este trabajo de investigación y el procesamiento previo que se ha aplicado a la señales adquiridas antes de iniciar las etapas de Representación y Clasificación.

El Capítulo 4 está enfocado en la etapa de Representación del sistema de reconocimiento de patrones sísmicos, configurado como metodología de investigación. En él, se describen brevemente las principales representaciones de las señales sísmico-volcánicas que se encuentran difundidas en la literatura, y se evalúan experimentalmente bajo las mismas condiciones y términos de desempeño. La definición de un espacio de características adecuado se hace con el fin de garantizar el mejor punto de partida para la optimización de un consecuente modelo de aprendizaje.

En el Capítulo 5 se introduce el cambio de concepto como un factor subyacente al proceso de generación de datos sísmico-volcánicos. Para tal fin, se define conceptualmente el problema de *concept drift* y se analiza de manera experimental la repercusión de la no-estacionariedad del fenómeno volcánico, vista a través de medidas de desempeño de clasificación de largos periodos de tiempo de datos sísmicos.

El Capítulo 6 presenta una aproximación al aprendizaje adaptativo, y en particular, al aprendizaje incremental, como método para contrarrestar el problema del cambio de concepto implicado en la generación de señales sísmicas de origen volcánico. Se propone un modelo predictivo basado en ensamble, que selecciona dinámicamente los clasificadores (del pasado) que serán miembros del modelo, de tal manera que pueda manejar estados recurrentes y clasificar datos nuevos sin requerir la etiqueta verdadera de datos antecesores.

La Parte III, presenta el cierre de este trabajo investigativo con las conclusiones y proposición de trabajos futuros relacionados a las áreas temáticas abordadas (Capítulo 7), junto a los anexos y referencias empleadas a lo largo de este documento.

Créditos

Este trabajo se ha llevado a cabo gracias al patrocinio económico del Programa Nacional de Formación de Investigadores, modalidad Doctorado Nacional, Convocatoria 617, de MINCIENCIAS (antes COLCIENCIAS).

Esta tesis contiene material publicado o presentado previamente en *journals* y eventos académicos internacionales, de carácter científico, de los cuales he sido autora principal o co-autora. Los demás autores participantes, fueron puestos en conocimiento que dichos artículos son productos derivados de la presente investigación y han dado su consentimiento para el uso de tales publicaciones como parte integral de esta tesis.

1.8. Resumen del capítulo

El presente capítulo ha expuesto la estructura que siguió el trabajo investigativo desarrollado a lo largo del doctorado. Inicialmente, se plantearon la motivación y la justificación del tema de investigación, seguidas de la definición concreta del problema a tratar. Posteriormente, se hizo la revisión de literatura, centrada en los aspectos tanto de representación como de clasificación de sismos de origen volcánico, identificando las ventajas y falencias de los trabajos más destacados; de esta manera se concretaron con mayor claridad los objetivos general y específicos —acá expuestos— que delimitaron esta investigación. Adicionalmente, se han precisado los alcances de la tesis y se especificaron las contribuciones de la misma. Se cierra el capítulo con la explicación de la distribución ordenada de este documento y la exposición de los créditos.

2. Conceptualización sobre vulcanismo y la operación de sistemas de monitoreo volcánico

El pronóstico de las erupciones volcánicas y desastres derivados ha venido centrando la atención de diferentes comunidades científicas, debido a las numerosas pérdidas de vidas que a lo largo de la historia han provocado, además de los dramáticos trastornos económicos y sociales que pueden ocasionar a nivel local, regional e incluso, global. Teniendo en mente la necesidad de contextualizar el problema investigativo que nos atañe, el presente capítulo contempla las generalidades sobre vulcanismo, el monitoreo volcánico y la importancia de la mitigación de riesgos. En particular, se profundiza sobre la técnica de sismología como metodología que aporta información de alto valor sobre la actividad volcánica, definiendo conceptos básicos como las diferentes clases de sismos que suelen registrarse, así como el proceso de adquisición y transmisión de datos desde el campo abierto. De igual forma, se exponen las bondades que la aplicación de ciencias computacionales ha traído en la generación de nuevas técnicas y tecnologías de apoyo en el área de la vigilancia volcánica.

2.1. Vulcanismo y amenaza volcánica

Las erupciones volcánicas son uno de los fenómenos naturales más devastadores que se pueden originar sobre la superficie terrestre, en comparación con otros tipos de manifestaciones adversas de la naturaleza como los huracanes, tsunamis o terremotos [Favereau et al., 2018]. Sin embargo, debido a sus condiciones de intensidad intermitente y a la baja frecuencia de ocurrencia frente a las demás catástrofes, (en un ámbito general, a nivel mundial) se dificulta mantener una conciencia pública sobre sus riesgos [Heiken, 2016].

A lo largo de la historia, se han registrado numerosos episodios eruptivos que han llevado a cuantiosas fatalidades por desastres volcánicos, entre los cuales se destacan por su magnitud catastrófica: la erupción en el año 1815 del volcán Tambora, en Indonesia, que dejó como saldo cerca de 60.000 fatalidades; por su parte, el volcán Krakatoa, en la erupción de 1883, provocó el fallecimiento de aproximadamente 36.000 personas; y en nuestro país, Colombia, la erupción del volcán Nevado del Ruiz en 1985, que causó la muerte a 23.187 personas [Favereau et al., 2018]. Decesos como los mencionados, además de otro tipo de repercusiones regionales que los desastres volcánicos traen consigo, siguen motivando la investigación en vulcanología; no obstante, aún existen muchas regiones volcánicas sin estudios y sin la adecuada vigilancia debido, entre otros factores, a limitaciones logísticas y financieras [Ashenden et al., 2011].

Se estima que alrededor del 10 % de la población mundial tiene asentamientos dentro de las áreas designadas (por los organismos correspondientes de cada región) como zonas de potencial riesgo volcánico, ubicadas a cortas distancias dentro de las cuales existen peligros eruptivos previsiblemente devastadores: aproximadamente 800 millones de personas viven a menos de 100 km de volcanes activos, y más de 29 millones, a una distancia cercana a los 10 km [Brown et al., 2017]. Incluso, ciudades enteras como Ciudad de México (México), Nápoles (Italia), Shimabara (Japón) y Jogjakarta (Indonesia), están expuestas y muy vulnerables a los efectos potencialmente destructores de una erupción volcánica [Ashenden et al., 2011]; por tanto, la evaluación de los peligros volcánicos y sus riesgos sigue siendo un desafío importante para los vulcanólogos.

Según el Programa de Vulcanismo Global [Venzke, 2013], en el mundo existen cerca de 1508 volcanes activos —localizados en aproximadamente 86 países alrededor del mundo; se consideran “activos” aquellos que durante los últimos 10.000 años han tenido actividad eruptiva confirmada o sospechosa. En [Heiken, 2016], por su parte, se estima que cada año entran en erupción entre 50 y 70 volcanes, de los 1.000 volcanes identificados como “activos” que podrían entrar en erupción en un futuro cercano. Esta estadística indica que una porción de población relativamente grande podría verse eventualmente perjudicada, y por lo cual, cualquier esfuerzo realizado por los profesionales pertinentes para contribuir a la reducción del riesgo, nunca resultaría excesivo.

En Colombia, aproximadamente el 20 % de los habitantes de la zona Andina se encuentra expuesto a amenaza volcánica; una estadística considerable partiendo del hecho que el 70 % de la población colombiana reside en tal región [Duque Escobar, 2012]. El anterior escenario se debe a la existencia de más de 20 volcanes activos que se ubican a lo largo de la cordillera de Los Andes que atraviesa el país de sur a norte (ver Figura 2-1), los cuales se originaron como consecuencia de la colisión e interacción entre la placa de Nazca y la corteza continental emergida (cinturón de fuego del Pacífico). La geología de los volcanes en Colombia es de naturaleza andesítica y dacítica, lo que explica la generación de lavas viscosas y la formación de domos que taponan los conductos volcánicos. Esto facilita la generación de erupciones piroclásticas violentas y la creación de grandes columnas de gases magmáticos [Zobin, 2012]; de igual forma, promueve la formación de lahares, debido a los afluentes de agua que de ellos suele originarse, la altura de los picos montañosos y las capas glaciares de la que algunos volcanes están provistos [Alarcón et al., 2000].

Durante las erupciones (o debido a procesos geofísicos y químicos que se dan previos a éstas) se generan amenazas que afectan directa o indirectamente la vida, salud e integridad humana al igual que la de animales, así como el estado de cultivos y el entorno ambiental en general. Algunos de los efectos desencadenados durante una erupción incluyen (para obtener más información sobre estos efectos, ver en [Wilson et al., 2014; Loughlin et al., 2015]):

- *I) Sismos:* son liberaciones de energía súbitas que se propagan mediante vibraciones, y son transmitidas a través de la tierra; se generan a partir de movimientos de fluidos (magma y gases) al interior de los conductos volcánicos, o por fracturamiento de rocas, y pueden provocar afectaciones de consideración en el edificio volcánico y zonas proximales.

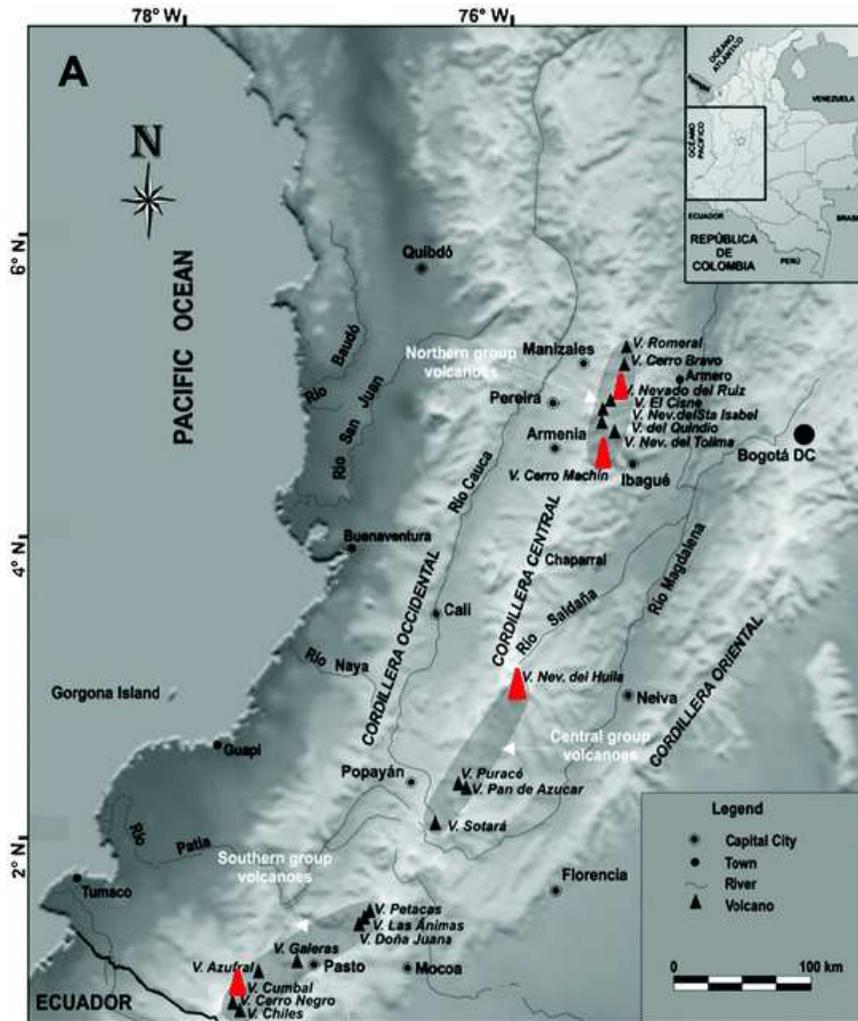


Figura 2-1.: Localización de los volcanes activos en Colombia. Tomado de [García and Mendez-Fajury, 2017]

- II) *Gases volcánicos*: los cuales son emanados en grandes cantidades a las atmósfera durante una erupción y, en general, a lo largo de un periodo eruptivo; y dependiendo de su concentración y tiempo de exposición, pueden causar daños en ojos, piel, vías respiratorias (incluso asfixia y envenenamiento).
- III) *Flujo y caída de piroclastos*: es una oleada de material incandescente (gases, ceniza, piroclastos) que recorre el edificio volcánico, junto a la caída en forma de proyectiles de fragmentos de rocas a altísimas temperaturas que generan destrucción por arrasamiento, aplastamientos, colapsos estructurales, incendios forestales, entre otros.
- IV) *Flujo de lava*: es el derrame de magma “no volátil”, el cual, debido a sus temperaturas extremas (entre 700 y 1250°C), puede ocasionar inundaciones (al mezclarse con nieve y hielo), flujo de escombros e incendios forestales.

- V) *Lahares*: consisten en corrientes de lodo que combinan sedimentos, escombros volcánicos, flujo de piroclastos y agua (proveniente de lagos superficiales, picos glaciares, o del sistema hidrotermal del volcán), que desciende por el edificio volcánico a altas velocidades (ocasionalmente vertiéndose en ríos y quebradas) y arrasando con cualquier obstáculo a su paso.
- VI) *Tsumanis*: son enormes ondas marinas, provocadas por el desplazamiento de grandes volúmenes de agua oceánica, el cual, a su vez, suele ser causado por dinámica tectónica en el fondo del mar o sismos volcánicos de gran magnitud. Las olas se mueven a altas velocidades y ganan altura mientras arriban a las costas, causando desastres catastróficos por inundaciones en ciudades costeras.

2.1.1. Metodologías de vigilancia volcánica

El monitoreo o vigilancia volcánica se implementa en Colombia como consecuencia de la necesidad de obtener información confiable y oportuna sobre la actividad volcánica, con el fin de hacer un control eficaz de crisis eruptivas, y anticipar erupciones volcánicas y sus devastadoras consecuencias [Alarcón et al., 2000]. Tras el proceso de reactivación del volcán Nevado del Ruiz (VNR), en 1984, y su posterior catastrófica erupción del 13 de noviembre de 1985 que destruyó al municipio de Armero, nace el Observatorio Vulcanológico Nacional, hoy conocido como el Observatorio Vulcanológico y Sismológico de Manizales (OVSM). Su propósito principal fue vigilar la actividad del VNR y de otros volcanes de la región andina central como el Cerro Machín, Cerro Bravo y volcanes nevados como el Tolima y el Santa Isabel. De manera similar, se crean los Observatorios Vulcanológicos y Sismológicos de la ciudad de Pasto (después de la reactivación del volcán Galeras en 1989) y el de Popayán, en 1993, los cuales se han encargado de la vigilancia de los volcanes activos del Sur y Suroccidente del país. Estos tres observatorios pertenecen al Servicio Geológico Colombiano (SGC), institución gubernamental especializada en investigaciones en Ciencias de la Tierra [Vargas et al., 2018].

El monitoreo volcánico está integrado por varias metodologías y técnicas provenientes de diferentes áreas de la ciencia —generalmente apoyadas en tecnologías de comunicaciones, electrónica e informática—, las cuales aportan diversos tipos de datos e información que, en conjunto, permiten analizar el fenómeno volcánico con mayor eficacia y dan más claridad a los expertos sobre las medidas anticipadas que deben tomarse ante una crisis de inestabilidad volcánica y posible erupción. Entre las más empleadas en la mayoría de observatorios vulcanológicos en el mundo, se encuentran [Alarcón et al., 2000]:

Geofísica. Abarca estudios de diferente naturaleza, de áreas estrechamente relacionadas como la gravimetría, magnetometría y la sismología. A esta última se le da preferencia sobre las demás, dado que sus técnicas y métodos aplicados aportan información contundente, continua y en tiempo real sobre la dinámica que se está generando al interior del volcán. Esto lo hace mediante registros sísmicos característicos que permiten identificar, o por lo menos tener un acercamiento, al tipo de proceso que se está dando internamente en ese momento. Para tal fin, se emplean instrumentos como los sismómetros, que captan las señales que viajan

a través de la tierra hasta la superficie, para luego transferir la información registrada a los observatorios, haciendo uso de tecnologías electrónicas y de telecomunicaciones. Dada la importancia de esta metodología, en la Sección 2.2 se profundizará más acerca del proceso de adquisición, transmisión y procesamiento de los datos sísmicos generados.

Geodesia. Las observaciones geodésicas permiten medir la deformación de la superficie de los volcanes, causada por la dinámica interna de gases y fluidos. Además, proporcionan datos valiosos mediante los cuales se hacen aproximaciones del volumen y geometría de los conductos magmáticos [Fernández et al., 2017]. Entre las técnicas usualmente empleadas para obtener dicha información, se desatacan: la *inclinometría seca*, la *inclinometría electrónica*, la *medición electrónica de distancias (E.D.M.)* y las *líneas cortas de nivelación*, las cuales, en términos generales, cuantifican la inflación o deflación del edificio volcánico mediante planos, líneas o puntos, haciendo uso de distintos instrumentos de medición que aportan diferentes grados de precisión. Existen otros métodos más avanzados que contribuyen al mismo fin, como los basados en sistemas de navegación satelital, en particular, el *GNSS (Global Navigation Satellite System)*, que permite obtener vectores de desplazamiento en zonas de alta deformación y difícil acceso como las áreas cercanas a los cráteres.

Geoquímica. Estudia la composición química de las emanaciones sólidas, líquidas y gaseosas de un volcán. La geoquímica involucra muestreos periódicos de gases difusos en el suelo, como el radón y el dióxido de carbono, y de otro tipo de gases inmersos en el campo fumarólico (columna de gases y vapor), como el dióxido de azufre. Estos gases son monitoreados mediante muestras *in situ*, en algunos casos, y con espectrómetros en otros (en años recientes se ha difundido el uso de técnicas más avanzadas como la espectroscopía de absorción óptica diferencial, también conocido como DOAS). De igual forma, se hace seguimiento a las fuentes termales (aguas que surgen de las laderas del volcán o montañas cercanas a éste), a través de mediciones de su pH, temperatura, conductividad, composición química, entre otras. Tales mediciones son analizadas en laboratorio y comparadas con la línea base de comportamiento del volcán, con el fin de detectar alteraciones importantes de determinados parámetros físico-químicos, como los mencionados.

Geología. Esta ciencia aporta en el estudio de un volcán mediante el análisis de composición de las rocas y depósitos eruptivos que se hallan sobre la superficie del edificio volcánico y áreas aledañas. De esta manera se puede conocer la historia eruptiva de un volcán: fechas aproximadas de erupciones pasadas, posibles escenarios de ocurrencia y eventual comportamiento que puedan tener futuras erupciones. Todos estos estudios componen los insumos necesarios para construir lo que los vulcanólogos denomina un “mapa de amenaza”, que determina las zonas y los niveles de afectación en los que impactaría un fenómeno eruptivo, lo cual constituye una herramienta primordial en la gestión del riesgo de desastres provocados por erupciones.

2.2. Monitoreo sísmico volcánico

La gran mayoría de las erupciones volcánicas registradas, han sido precedidas por un incremento en la actividad sísmica bajo el edificio volcánico y en regiones cercanas a éste [Loughlin et al., 2015]; por lo cual, la vigilancia a partir de técnicas propias del área de la sismología es crucial para obtener información confiable y muy aproximada de los procesos físico-químicos que pueden estar ocurriendo al interior del volcán. A esto se debe la preferencia que se le da a la sismología sobre las demás áreas de monitoreo, en especial, durante el aprovisionamiento preliminar de instrumentación en un volcán que recién inicia su vigilancia. Adicionalmente, los avances que durante las tres últimas décadas han tenido las ciencias computacionales aplicadas a la sismología, han sido clave para dar mayor confiabilidad al aporte informativo de esta área al momento de tomar decisiones trascendentales en la gestión del riesgos [McNutt, 2002].

Mediante la sismología se lleva a cabo la adquisición y estudio de las señales sísmicas asociadas a la actividad volcánica; se efectúa la identificación del tipo de actividad volcánica al que determinada señal está asociada, y además, permite hacer la localización precisa de los puntos donde se generan los eventos sísmicos. Para tal fin, un volcán adecuadamente monitoreado debe tener un mínimo de 3 estaciones sísmicas (o más, idealmente) ubicadas en los flancos o inmediaciones del edificio volcánico y distribuidas de manera conveniente [McNutt, 1996]. Apoyándose en tecnologías informáticas y de telecomunicaciones, los datos capturados en las estaciones sísmicas son transmitidos a un solo punto de acopio de información (como se detalla en la Sección 2.2.1), donde también se reciben y procesan datos enviados teleméricamente (y los recogidos *in-situ*) de las demás áreas de monitoreo.

Tales centros de recepción y procesamiento de datos son los observatorios vulcanológicos y sismológicos, que en Colombia son tres, ubicados en las ciudades de Manizales, Pasto y Popayán, que a excepción del último, fueron creados tras la reactivación de volcanes potencialmente peligrosos (ver Sección 2.1.1). Estos son dependencias del SGC y su principal función es realizar el monitoreo de los volcanes activos del país para suministrar información oportuna y confiable sobre su actividad volcánica, especialmente en lo referente al pronóstico de crisis y erupciones, así como en la elaboración de escenarios potenciales para dichas crisis y erupciones.

2.2.1. Adquisición y transmisión de datos

En Colombia, los volcanes activos monitoreados por los observatorios vulcanológicos cuentan con completas redes de vigilancia instaladas en campo, conformadas por estaciones sismológicas que se encuentran distribuidas dentro un radio no mayor de 15 km alrededor del cráter del volcán, y con un pequeño distanciamiento entre ellas ($< 1km$) para una mejor detección de sismos menores y la minimización de errores de localización. Las redes sísmicas actuales cuentan con procesos de recopilación de datos completamente automatizados y telemetrizados, con el fin de garantizar una vigilancia continua (24 horas, 7 días a la semana), en tiempo real, y de áreas de difícil acceso donde la recopilación manual de datos es poco factible.

La primera etapa del proceso de recolección de datos consiste en la adquisición de los mismos, labor que se lleva a cabo mediante sensores sísmicos, también conocidos como sismómetros. Estos dispositivos eléctricos y electrónicos detectan y convierten las vibraciones que llegan a la superficie de la tierra en señales medibles como corriente y voltaje [Havskov and Ottemoller, 2010]. Para la implementación de una estación sísmica típica con fines de monitoreo volcánico, usualmente se emplean dos tipo de sismómetros:

- I) *Los sensores de periodo corto*, son dispositivos mecánicos provisto de una masa magnética suspendida de un resorte (péndulo) junto a un sistema de amortiguamiento, mediante el cual las oscilaciones (inducidas por un movimiento sísmico) son transducidas por una bobina a corriente eléctrica. Este tipo de sismómetros presenta una relación lineal entre la velocidad del movimiento del suelo y la señal inducida, dentro de un ancho de banda típico entre 1.0 y 100 Hz, por lo que son ideales para captar movimientos débiles o cercanos.
- II) *Los sensores de banda ancha*, por su parte, cuentan con un mayor rango dinámico (superior a 145 dB) cubren un espectro de frecuencias más amplio (usualmente entre 0.01 y 50 Hz), lo cual se logra al incluir un circuito de retroalimentación que limita el movimiento de la masa en el rango de frecuencias deseado; esto permite registrar sismos de magnitudes moderadas a distancias regionales. Dado que las ondas sísmicas se pueden dar en planos verticales u horizontales, los sismómetros actualmente usados tanto de periodo corto como los de banda ancha son triaxiales: un eje vertical (componente Z), uno horizontal en sentido Norte-Sur (componente NS) y otro horizontal en sentido Este-Oeste (componente EW). Aunque existen sismómetros de una sola componente, no suelen incluirse en redes sismológicas modernas.

Una vez los eventos sísmicos son detectados por el sismómetro, los datos adquiridos deben ser almacenados para su posterior procesamiento. Algunas estaciones sísmicas son temporales y están dotadas de sensores portátiles que cuentan con memoria interna o externa para la grabación local de datos, lo que implica la visita periódica de personal competente para extraerlos. Por tal motivo, la mayoría de estaciones de una red sismológica eficiente son permanentes (como la mostrada en la Figura 2-2), y por lo tanto, requieren de la transmisión continua de datos hacia una central de registro (telemetría). Un sistema telemétrico de radio-enlace generalmente consta de un modulador, un radio y una antena —por el lado de la transmisión—, y una antena, un radio, un demodulador, un conversor análogo-digital (A/D) y un dispositivos de almacenamiento —por el lado de la recepción.

La digitalización de los datos se puede llevar a cabo de manera previa o posterior a la transmisión; en cualquiera de los dos casos se requiere inicialmente de un acondicionamiento de las señales con amplificadores y banco de filtros. Posteriormente, se procede a la modulación/demodulación de la señal (según corresponda al caso de transmisión o recepción) que se efectúa mediante un oscilador de voltaje con modulación de frecuencias que permita transmitir la señal a muy altas frecuencias (VHF o UHF). Los conversores A/D que generalmente se emplean para la digitalización son de frecuencias de muestreo de 50, 100 o 200 Hz y resoluciones entre 12 y 24 bits. Los observatorios usualmente respaldan el sistema de transmisión de datos por varias metodologías simultáneamente (además del sistema de radio-enlace mencionado), de ahí que hayan estaciones conectadas al centro de recepción de datos mediante redes móviles, wifi, satelitalmente, microondas e incluso fibra óptica. Los lectores que deseen profundizar sobre instrumentación y procesos de transmisión de datos en el contexto sísmico pueden encontrar más información en [Havskov and Alguacil, 2016].



Figura 2-2.: Estación típica de monitoreo sísmico (perteneciente al OVSM). Imagen tomada de [Orozco-Alzate et al., 2012]

2.2.2. Clases de sismos

Las señales sísmicas de origen volcánico son manifestaciones de procesos geofísicos generados en la estructura volcánica o capas terrestres subyacentes; por tal motivo, éstas son ampliamente estudiadas en los observatorios vulcanológicos para la caracterización de la actividad volcánica y el pronóstico de erupciones. De acuerdo a las características del proceso que se esté dando al interior del volcán, tales manifestaciones suelen clasificarse en un determinado tipo de evento sísmico. Aunque algunas variaciones (bien sea en la forma de onda y/o en sus componentes frecuenciales) dadas entre sismos de una misma clase podrían evidenciarse entre un volcán y otro, los mecanismos que los generan son iguales —por definición— para cualquier volcán; de aquí que la sismología volcánica pueda precisar una categorización de los registros sísmico-volcánicos más comunes en los volcanes activos, la cual fue originalmente propuesta por Minakami [1974]. En este trabajo investigativo se ha adoptado la clasificación planteada en [Trombly, 2006], puesto que corresponde a la que actualmente se emplea en los Observatorios Vulcanológicos y Sismológicos de Colombia, y en general, en

gran parte de los observatorios del mundo, y la cual se define a continuación (ver en la Figura 2-3 la morfología de la señal sísmica y su correspondiente espectrograma de 4 de los principales sismos de origen volcánico):

- *Eventos volcano-tectónicos (VT)*: Son eventos atribuidos a fracturamiento de rocas al interior de la estructura volcánica, provocados por presión o movimientos magmáticos u otros fluidos. Su contenido frecuencial es relativamente alto, comprendiendo un ancho de banda que puede variar entre 1 y 5 Hz (según Trombley [2006]), aunque en la práctica, su espectro podría extenderse hasta los 15 Hz Chouet and Matoza [2013]; sin embargo, en la práctica, algunos volcanes muestran un rango de frecuencia mayor, que puede alcanzar hasta los 10 Hz . La forma de onda de los sismos VT es muy similar a la de los sismos tectónicos, aunque la manera como se producen ambos tipos de sismos es diferente.
- *Eventos de largo período (LP)*: Estos eventos son una manifestación del tránsito de magma u otros fluidos al interior de los conductos volcánicos. Generalmente, las frecuencias dominantes de este tipo de eventos ocurren entre 1 y 3 Hz .
- *Eventos híbridos (HB)*: Corresponden a una mezcla entre eventos VT y LP, bien sea que ocurra primero un VT que desencadena un LP, o viceversa. Debido a la similitud ocurrida al inicio de los eventos LP y HB, es usualmente complicado para el experto distinguir entre un tipo de evento y otro.
- *Eventos tipo tremor (TR)*: Los eventos tipo tremor o pulsos de tremores tienen un mecanismo de generación similar al de los eventos LP, incluso se mantienen en el mismo rango de frecuencias; se diferencian básicamente porque los TR tienen una mayor duración que los LP, la cual puede extenderse desde unos cuantos minutos hasta días, e incluso, meses.

Otro importante tipo de sismo volcánico, propio de las etapas eruptivas, corresponde a las denominadas “explosiones”:

- *Eventos tipo explosiones (EX)*: La forma de onda, la duración y el contenido frecuencial de este tipo de eventos varían dependiendo de la profundidad, proporciones y fase en la que se encuentre la erupción. Además, por lo general, las explosiones volcánicas están acompañadas por onda sonoras de gran magnitud que, al expandirse por el aire y llegar a la tierra, son captadas por los instrumentos de registro (sismómetros), de tal forma que estas ondas mecánicas resultan involucradas y combinadas en los registros sísmicos de una erupción [McNutt, 2005].

Además de la clasificación tradicional de los sismos volcánicos, en esta tesis se incluirán otros tipos de sismos, dado que suelen presentarse con relativa frecuencia en algunos volcanes colombianos:

- *Eventos tipo tornillo (TO)*: Este tipo de eventos corresponde a un sismo de naturaleza de largo período; por tanto, contiene bajas frecuencias dominantes y se caracteriza por tener una forma de onda monocromática (similar a un tornillo - pieza metálica), de larga duración

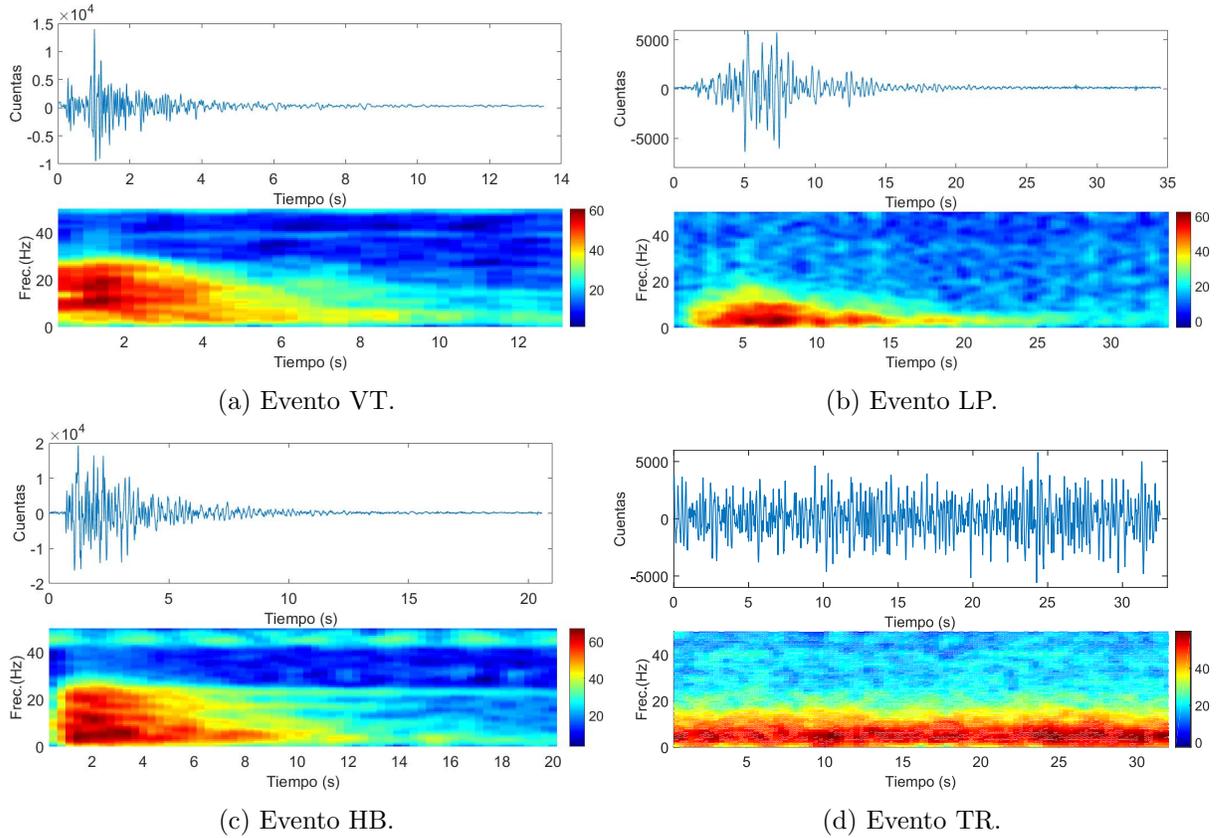


Figura 2-3.: Formas de onda y espectrogramas de los cuatro principales tipo de sismos volcánicos (señales provenientes del volcán Nevado del Ruiz).

en comparación a su amplitud, además de un lento decaimiento de coda cuasi-lineal [Torres et al., 1996].

- *Eventos de fractura de hielo (IC)*: Se presentan en volcanes que poseen capa glacial y ocurren debido a fracturas ocurridas en tal capa, las cuales comparten el mismo mecanismo de generación de los eventos VT, por tal motivo, también suele ser complicado distinguir entre ambos tipos de eventos.

Otros tipos de eventos sísmicos, que son captados por los sismómetros instalados en los volcanes, también son tenidos en cuenta en la asignación de etiquetas de clase llevada a cabo en los observatorios del SGC. Algunos de ellos se deben a agentes externos ambientales o artificiales, como tormentas, fuertes vientos, explosiones sintéticas (como las usadas en minería), tránsito cercano a los sismómetros de personas o animales, desprendimiento y deslizamiento de tierra (LS), desprendimiento de rocas (ROF), entre otros. Adicionalmente, los sismos de origen tectónico también son registrados, tales como los sismos locales (TL), los sismos regionales (RE), y los telesismos (TS). Un caso particular de evento se presenta en algunos volcanes, en el cual se da una ocurrencia simultánea o subsecuente en el tiempo de dos o más sismos de la misma clase o de clases diferentes;

es decir, se dan eventos superpuestos o muy seguidos, que forman lo que podría parecer un único evento; a este caso se le denomina *Multievento* o *Multifase (MP)*.

2.3. Evolución espacio-temporal de la sismicidad

Numerosos estudios en el área de vulcanología y geofísica describen las alteraciones más comunes que manifiestan los volcanes cuando entran a una etapa de reactivación, después de haber permanecido cierto tiempo en una dinámica básica de reposo o leve actividad [Vila et al., 2006; Lokmer et al., 2008; Triastuty et al., 2009; Carmona et al., 2012; Lamb et al., 2014; Sheldrake et al., 2016]. Altas variaciones en el número de determinada clase de sismo, cambios importantes en las concentraciones de energía dentro de una banda de frecuencias diferente a la de base, convergencia de localizaciones de sismos en ciertos puntos en inmediaciones del edificio volcánico, son algunos de los cambios señalados por los autores a través de los cuales se expone y cuantifica la naturaleza evolutiva e inherente de un volcán.

La revisión del estado del arte relacionada al aprendizaje automático aplicado a sismos nos ha permitido identificar que el carácter cambiante/evolutivo de la sismicidad, no ha sido considerado como una condición trascendental en el sostenimiento en el tiempo del desempeño de clasificación dentro de los métodos propuestos, de tal manera que difícilmente pudiere esbozarse un sistema de PR de sismos volcánicos realmente autónomo. En el Capítulo 5, se profundizará con mayor detalle en este aspecto, y como contribución, se mostrará experimentalmente en el Capítulo 6 el impacto directo en el rendimiento de un clasificador incorporado en una estrategia que metódicamente va expandiendo su base de conocimiento para responder favorablemente ante la evolución del fenómeno volcánico, expresada en su sismicidad cambiante.

2.4. Aplicación de AI, ML y PR en el monitoreo volcánico

El desarrollo tecnológico que se ha generado durante las dos últimas décadas en las diferentes áreas del monitoreo volcánico —y de las Ciencias de la Tierra, en general—, ha originado un impacto positivo de la percepción del riesgo en los entes gubernamentales competentes y en las comunidades potencialmente vulnerables. Hoy en día son más comunes los proyectos investigativos multidisciplinarios con cooperación internacional, y mayores las inversiones de los respectivos gobiernos para su financiación, los cuales confluyen en la creación de nuevos observatorios vulcanológicos y la generación de nuevas herramientas tecnológicas empleadas para el cumplimiento misional de tales centros de monitoreo e investigación [Donovan et al., 2012]. La innovación se ha venido dando en todas las áreas involucradas en la vigilancia volcánica, presentando aportes trascendentales que incluyen desde la implementación de sensores de infrasonido de bajo costo [Grangeon and Lesage, 2019], pasando por avances en protocolos de comunicación de equipos instalados en campo [Awadallah et al., 2019], hasta la prospección de estaciones de vigilancia autónomas energizadas mediante generadores termo-eléctricos que aprovecha las propiedades físico-químicas de las fumarolas [Catalan et al., 2020].

La aplicación de áreas del conocimiento como AI, ML y PR ha venido encontrando un campo de acción cada vez más amplio en la vulcanología contribuyendo a multiplicar las innovaciones tecnológicas y a acelerar sus procesos de desarrollo [Sparks et al., 2012; Anantrasirichai et al., 2019; Gaddes et al., 2019; Valade et al., 2019]. En la sismología, como campo derivado de la geofísica que estudia las particularidades de los sismos y terremotos (de naturaleza tectónica y volcánica), se proyecta un desafío creciente debido a la necesidad imperiosa de un acercamiento cada vez más realista a la predicción de sismos (que pueda derivar también en predicciones acertadas de erupciones). En este sentido, la AI desempeña un papel importante en los sistemas sísmicos modernos, aumentando la eficiencia de detección, identificando características subyacentes al fenómeno sísmico y sísmico-volcánico, y reduciendo la influencia de datos ruidosos. Mientras que los métodos tradicionales de minería de datos eran la base de los estudios e investigaciones de años atrás en el área, la AI ha proporcionado recientemente estrategias y herramientas eficientes para el procesamiento de datos y la extracción de información útil que conlleve a predicciones y decisiones confiables en sismología [Jiao and Alavi, 2020]. Gracias a la capacidad de la AI para identificar relaciones funcionales latentes entre variables sin que deba existir una suposición *a priori* de dicha relación, es posible hacer la extracción de información compleja en medio de factores comunes de los sismos como el tiempo, ubicación, magnitud y posibles daños [Kong et al., 2019].

El área de ML, considerándose como una subdivisión de la AI inspirada en procesos de aprendizajes biológicos, ha hecho aportes aún más concretos a aplicaciones de las geociencias, y sismología en particular, favoreciendo, por ejemplo, la detección y selección de fase, alertas tempranas, predicción del movimiento del suelo, tomografía y geodesia [Karpadne et al., 2018]. De igual forma, el PR, aunque con orígenes distintos a los de ML pero con fines y alcances similares, ha contribuido al estado del arte de tales aplicaciones. Desde sus principales paradigmas de regresión y clasificación (supervisada y no supervisada), ML y PR han propuesto una amplia gama de algoritmos y estrategias, entre las cuales las ANN, las SVM, los mapas auto-organizados (*Self-Organizing Map* - SOM) y los árboles de decisión (*Decision Tree* - DT) se destacan como técnicas comúnmente usadas en aplicaciones de las geociencias (una revisión detallada sobre el uso de estas técnicas se puede encontrar en [Lary, 2010; Lary et al., 2016; Maxwell et al., 2018; Kong et al., 2019]).

Con el fin de comprender la trascendencia de los aportes derivados de las áreas del conocimiento de AI, ML y PR en la aplicación en que se enfoca este trabajo, vale la pena definir y ampliar algunos conceptos alrededor de ellas. En el Capítulo 3 se detallan términos y etapas del proceso general de un sistema automatizado, al igual que se expone la propuesta metodológica aplicada en el sistema adaptativo que se propone en esta tesis.

2.4.1. Aprendizaje automatizado en clasificación de señales sísmicas

Gran parte de las investigaciones aplicadas a la clasificación automática de sismos (ver trabajos referenciados en la Sec. 1.3) han enmarcado sus planteamientos metodológicos dentro la estructura del aprendizaje supervisado. Esta metodología, ampliamente estudiada en ML, en términos generales relaciona variables de entrada de un sistema¹ con las variables de salida del mismo, mediante

¹Para profundizar sobre el concepto de *sistemas* y otros términos relacionados, consultar [Ogata and Yang, 2002].

la construcción de un modelo (el clasificador) que predice los valores de salida de datos nunca antes vistos, a partir del aprendizaje de ejemplos con etiqueta que indican el verdadero valor de su salida. En clasificación aplicada al monitoreo volcánico, el aprendizaje supervisado se ha empleado principalmente para hacer detección de eventos, es decir, distinguir el evento sísmico de la traza con ruido de fondo [Withers et al., 1998; Sharma et al., 2010; Zhu et al., 2018]; y para identificar el tipo de sismo que ha ocurrido y asignar la etiqueta de clase correspondiente, que es el campo que en esta investigación nos concierne.

La anterior definición, se puede precisar formalmente como sigue:

sea $T_{train} = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\}$ un conjunto de ejemplos, proveniente de una colección mayor de ejemplos T . Cada ejemplo está conformado por una pareja de variables representadas por el vector de características $\mathbf{x}_i \in \mathbb{R}^d$ —proyectado en un espacio de características d -dimensional— y su respectiva etiqueta de clase $y_i \in Y \in \Omega = \{\omega_1, \dots, \omega_c\}$ que conforma el conjunto Y de las etiquetas de T , el cual, a su vez, hace parte del conjunto de variables discretas Ω abarcado entre 1 y las c clases definidas. El conjunto Y representa las etiquetas de clase que han sido asignadas por un experto humano con dominio en el área del problema y se denominan *etiquetas verdaderas* o *reales*. Cada pareja de variables (\mathbf{x}_i, y_i) ahora tomará el nombre de *observación* y $T_{train} \subset T$ se denominará *conjunto de entrenamiento*. Por consiguiente, la tarea del paradigma del aprendizaje supervisado consiste en inferir una función f que transforme las representaciones de T_{test} en etiquetas de clase asignadas, como sigue:

$$f : T_{test} \longrightarrow \hat{Y} \quad (2-1)$$

Así, la función f hará la estimación de clase del j -ésimo ejemplo (nunca antes visto) representado por \mathbf{x}_j (que pertenece al denominado *conjunto de prueba* $T_{test} \in T$), con etiqueta de clase inicialmente desconocida: $\hat{y}_j = f(\mathbf{x}_j)$.

En contraste al marco metodológico del aprendizaje supervisado, en PR existen otros igualmente efectivos como lo es el aprendizaje no supervisado, el cual, a diferencia del primero, no requiere de ejemplos etiquetados para aprender de ellos. En su lugar, los sistemas no supervisados aprenden a representar patrones de entrada particulares de tal manera que se refleje la estructura estadística general de la colección de dichos patrones; esto lo hace generando agrupamientos de los mismos de manera “natural”, de acuerdo a su representación. En consecuencia, un sistema no supervisado no produce una salida *target* en específico sino que aporta un sesgo o preferencia sobre qué aspectos de la estructura de la entrada debe capturarse en la salida [Dayan et al., 1999].

En la última década se han desarrollado nuevas vertientes del aprendizaje supervisado que han ido respondiendo a las necesidades del mundo actual, en especial, las relacionadas al vertiginoso crecimiento de las aplicaciones digitales y sus limitantes en el almacenamiento de datos; el aprendizaje incremental (*incremental learning*) y el aprendizaje en línea (*online learning*) son algunas de ellas [Gepperth and Hammer, 2016]. Investigaciones en estas metodologías han generado estrategias que permiten el tratamiento de altos flujos de datos (también conocidos como *data stream* o *streaming data*) dentro del paradigma del aprendizaje supervisado. En el Capítulo 6 se ampliará la revisión bibliográfica sobre el aprendizaje incremental y se profundizará sobre sus bondades mediante un

estudio experimental de la aplicación que nos concierne, referente a la identificación de señales sísmicas de origen volcánico.

2.5. Evaluación de los sistemas automatizados

Los sistemas supervisados requieren de una validación de la correcta asignación de etiqueta de los nuevos datos, una vez finalizada la etapa de clasificación; es decir, se precisa medir el rendimiento o desempeño de un clasificador y su capacidad de generalización. Esta fase de evaluación es indispensable durante la construcción del algoritmo de aprendizaje, al igual que en la sintonización de parámetros de un clasificador cuando éste se está implementando. Diversas medidas y métodos de evaluación han sido desarrollados para cumplir con requisitos prácticos de aplicaciones específicas, sin embargo, existen algunas métricas de desempeño básicas y comúnmente usadas en la comunidad de PR y similares, las cuales se exponen brevemente a continuación [Japkowicz and Shah, 2011].

2.5.1. Medidas de desempeño básicas

La evaluación de un clasificador o modelo de aprendizaje se puede definir matemáticamente como sigue:

$$\rho(\delta, \hat{T}_{test}) = \vartheta \quad (2-2)$$

donde $\delta \in \Delta$ es un clasificador que corresponde a la función f de la Ec. 2-1, y que hace parte de un *espacio de clasificadores* Δ ; \hat{T}_{test} es el conjunto de ejemplos nuevos con etiqueta asignada por el clasificador δ . De esta manera, la función de evaluación de clasificación ρ asigna un valor ϑ que describe el rendimiento del clasificador δ con respecto a \hat{T}_{test} ; valor que dependerá de la medida de desempeño seleccionada.

El *error del clasificación* es una medida de desempeño usualmente empleada en la evaluación de clasificación, y se define como la probabilidad de que el clasificador δ asigne equivocadamente la etiqueta de clase al ejemplo \mathbf{x}_j , en comparación con la etiqueta verdadera y_j ; esto es, $Err = p(\delta(\mathbf{x}_j) \neq y_j)$. Dado que las densidades de probabilidad no son conocidas y solo se analiza una muestra del universo de objetos, el tipo de medida de desempeño que se estima es el *error empírico*, el cual denominaremos simplemente *error*, y se calcula como la razón entre la cantidad de ejemplos erróneamente etiquetados (n_{test}^{err}) y el número total de ejemplos del conjunto de validación (n_{test}):

$$err(\delta) = \frac{n_{test}^{err}}{n_{test}} \quad (2-3)$$

La *exactitud (accuracy)* del clasificador es otra alternativa para medir el desempeño de un clasificador que brinda la misma información que el error, aunque expresada en proporción de aciertos;

como es una medida complementaria al error, la exactitud (acc) se calcula como:

$$acc(\delta) = 1 - err(\delta) \quad (2-4)$$

Otras medidas de desempeño se pueden definir a partir de la denominada *matriz de confusión*, a través de la cual se evalúa el número de ejemplos correctamente identificados (verdaderos positivos – TP), y el número de ejemplos reconocidos correctamente como no pertenecientes a la clase (verdaderos negativos – TN), al igual que la cantidad de ejemplos que fueron etiquetados incorrectamente a la clase (falsos positivos – FP) y aquellos ejemplos que no fueron reconocidos como de la clase (falsos negativos – FN).

A partir de estas definiciones, es posible redefinir el error y la exactitud, al igual que la derivación de otras medidas de desempeño relacionadas, también empleadas frecuentemente en la evaluación de clasificadores, las cuales se definen a continuación de manera generalizada para un caso multi-clase:

- *Error*: Estima el error de clasificación promedio por clase:

$$err = \frac{1}{n} \sum_{i=1}^n \frac{FP_i + FN_i}{TP_i + TN_i + FP_i + FN_i}$$

- *Exactitud (accuracy)*: Define la efectividad promedio del clasificado por cada clase:

$$acc = \frac{1}{n} \sum_{i=1}^n \frac{TP_i + TN_i}{TP_i + TN_i + FP_i + FN_i}$$

- *Precisión (precision)*: Cálculo de la coincidencia por clase entre las etiquetas reales y las asignadas por el clasificador:

$$pre = \frac{1}{n} \sum_{i=1}^n \frac{TP_i}{TP_i + FP_i}$$

- *Sensibilidad (recall)*: Estima la efectividad promedio por clase de clasificador, calculando la porción de ejemplos de una clase reconocidos por el clasificador:

$$rec = \frac{1}{n} \sum_{i=1}^n \frac{TP_i}{TP_i + FN_i}$$

En el aprendizaje en línea y el incremental, medir el desempeño resulta igualmente imprescindible no solo durante la implementación del algoritmo de aprendizaje y el clasificador, sino también durante su puesta en marcha y el tiempo en que permanezcan en funcionamiento. En el Capítulo 6 se explican aquellas medidas y métodos empleados en este trabajo investigativo para la evaluación del método de aprendizaje propuesto.

2.6. Resumen del capítulo

En el Capítulo 2 se ha hecho una contextualización general sobre diferentes aspectos relacionados con la solución del problema planteado. En este sentido, se expusieron definiciones básicas sobre vulcanología, técnicas de vigilancia volcánica y procesos físico-químicos vinculados a la sismología volcánica; además, se han descrito los tipos de sismos volcánicos que comúnmente son registrados. Luego, se expusieron las diferentes aplicaciones que AI, ML y PR han tenido en el monitoreo volcánico, en particular, a través del aprendizaje automático para la clasificación de sismos. Por último,

se definieron algunas medidas de desempeño usadas para la evaluación de sistemas enmarcados en el aprendizaje automático, y que fueron empleadas en este trabajo.

3. Propuesta metodológica para la identificación de sismos volcánicos mediante un sistema adaptativo

Al igual que en otras áreas del conocimiento, el vertiginoso crecimiento de las tecnologías aplicadas ha promovido en la vulcanología la ampliación del espectro de sus objetivos, técnicas de procesamiento de información, estrategias de recopilación de datos y aplicaciones. Así pues, la vulcanología vista desde la perspectiva de la predicción y respuesta a las crisis, como función primordial de los observatorios vulcanológicos, está influenciada tanto por avances tecnológicos constantes como por eventos singulares que conducen a cambios rápidos en las metodologías y procedimientos. Los principales avances genéricos a nivel de equipos e instrumentación incluyen la conversión de sistemas analógicos a digitales, al igual que el crecimiento exponencial de la capacidad informática y del almacenamiento de datos.

En sismología, como una de las ramas de la vulcanología que aporta información altamente relevante y concluyente a los expertos, los adelantos se han visto principalmente en paquetes de software que incluyen herramientas para análisis de datos de ondas de superficie, inversión, mecanismos focales, momentos sísmicos, modelos de velocidad, entre otros [Herrmann, 2013]. La identificación de clase de los eventos sísmicos también ha sido ampliamente estudiada por ser clave para determinar el tipo de proceso físico-químico que está ocurriendo al interior del volcán; por lo cual, numerosas investigaciones han centrado sus esfuerzos en la proposición de nuevas técnicas y herramientas que faciliten dicha tarea y la hagan más eficaz y precisa (un compendio interesante de metodologías y técnicas aplicadas se puede encontrar en [Carniel and Guzmán, 2020]). En el presente capítulo, nos centraremos en el área de reconocimiento de patrones, describiendo de manera general los sistemas de clasificación y las fases que los componen; adicionalmente, se ilustra el esquema metodológico propuesto en esta tesis, que enmarca un sistema de clasificación de carácter adaptativo. Por último, se detallan las primeras etapas de dicho esquema, describiendo las bases de datos que se usarán en los experimentos planteados en los capítulos subsecuentes, al igual que el pre-procesamiento aplicado a tales datos.

3.1. Generalidades de los sistemas de reconocimiento de patrones

El ser humano, diariamente y de manera casi permanente, se enfrenta a situaciones del mundo real ante las cuales debe tomar decisiones, lo cual implica accionar los procesos de *percepción*, *reconocimiento* e *identificación* (o *clasificación*). Estos dos últimos requieren de un proceso previo denominado *aprendizaje*, en el cual, a través de información multisensorial y nuestra capacidad cognitiva, creamos conceptos y patrones sobre objetos, personas o contextos, que conformarán nuestro conocimiento *a priori* (lo que sabemos de antemano). La necesidad de dar precisión, objetividad y mayor confiabilidad a las tareas realizadas por nuestra mente o nuestras manos, y de llevar a cabo tareas repetitivas y de mayor complejidad, motivaron el surgimiento de las áreas de AI, ML y PR. El desarrollo de estas comunidades y sus investigaciones han permitido la creación de algoritmos que modelan matemáticamente un problema o entorno del cual se “aprenden” ciertos rasgos, atributos o características, para así poder categorizar los objetos en determinadas clases, es decir, clasificarlos automáticamente.

Algunos autores no consideran que exista distinción alguna entre los fundamentos de las tres áreas mencionadas, mientras algunos otros han señalado ciertas discrepancias en su evolución y aplicaciones. Tal es el caso de Bishop [2006], quien establece diferencias en sus orígenes afirmando que ML surge de las ciencias computacionales, en tanto que PR nace de la ingeniería. Por su parte, Kuncheva [2019] expone que ML se desarrolló con mayor fuerza en Estado Unidos, mientras que PR lo hizo en Europa; y adiciona que en la época que no existía el Internet, ML se enfocó principalmente en teoría de inferencia, mientras que PR generó grandes avances en procesamiento de imagen. Teniendo en cuenta la similitud de sus fundamentos y para efectos de generalidad, desde este punto en adelante, a lo largo de esta tesis se hará mención únicamente de “reconocimiento de patrones” o su abreviación *PR* (*pattern recognition*), haciendo referencia a cualquiera de las tres áreas sin distinción alguna.

En cuanto a definiciones formales que giran en torno al PR, Duda et al. [2006], por ejemplo, la define como “el acto de tomar datos crudos y tomar una acción basada en la categoría del patrón”. De manera similar, en la literatura se pueden encontrar definiciones de diferente índole para PR; sin embargo, considerando su simplicidad e integralidad, en esta tesis nos basaremos en la planteada por Orozco-Alzate [2008]: “*El reconocimiento de patrones es la disciplina que intenta encontrar formas de imitar la capacidad humana de utilizar la información sensorial y el conocimiento de forma inteligente, proporcionando fundamentos matemáticos, modelos y métodos para aprender a partir un número limitado de ejemplos, con el fin de automatizar el proceso de clasificación o categorización*”.

Dado que esta tesis describe la metodología aplicada en el diseño de un sistema de reconocimiento de patrones supervisado, conviene aclarar brevemente las etapas básicas y algunos conceptos generales involucrados en el área de PR (para profundizar al respecto, consultar en [Duda et al., 2006; Kuncheva, 2019]):

- Un *ejemplo*, también llamado *objeto* o *instancia*, puede ser una persona, cosa o concepto definido a partir de ciertos atributos o peculiaridades que lo caracterizan y lo hacen identificable.

Así, un objeto o ejemplo está representado por un vector dentro de un espacio vectorial de características. En adelante, mediante la variable n se indicará el número total de ejemplos del conjunto de datos a estudiar.

- Las *características* son rasgos o atributos físicos (aparentes) o subyacentes (no perceptible a la vista humana o a cuantificación trivial) de un ejemplo, que pueden ser medibles de manera nominal, ordinal, discreta o continua. En este trabajo se empleará la notación m en referencia al número de características usadas.
- Una *clase* es un grupo o colección de ejemplos que comparten una o varias características, mediante las cuales pueden ser reconocidos. En adelante se denotará el número de clases con la variable c . Un problema *multi-clase* hace referencia a un escenario de clasificación de más de dos clases.
- Cada clase definida tiene una *etiqueta* relacionada, que corresponde a un rótulo de tipo ordinal (alfa-numérico: clase 0 o clase 1; clase A o clase B) o nominal (sustantivo: clase 'perro' o clase 'gato'; clase 'rosa' o clase 'orquídea'). Las etiquetas de los ejemplos que serán empleados para entrenar el modelo de aprendizaje, deben ser asignadas por un experto con dominio del tema en el que se centra el problema; a éstas se les denomina *etiquetas de clase 'reales' o 'verdaderas'*.
- El *conjunto de entrenamiento* se le denomina a una colección de instancias utilizada para hacer la sintonización o parametrización de un modelo (entrenar un clasificador); esto es, a partir de los ejemplos de dicho conjunto, el modelo aprende (a partir de características propias de cada clase) lo necesario para identificar en futuros ejemplos nunca antes vistos a qué clase pertenecen. Este conjunto corresponde a una porción o porcentaje del universo de ejemplos adquiridos.
- El *conjunto de prueba* es el grupo de ejemplos nunca antes vistos por el clasificador y con el cual se valida el adecuado desempeño del modelo entrenado. Corresponde al complemento del conjunto de entrenamiento, del total de ejemplos adquiridos (generalmente su tamaño es mucho menor que el de entrenamiento).

Tomando como referencia el esquema definido en la Fig. 1-1, Capítulo 1, el proceso que lleva a cabo un sistema de PR para lograr la identificación de clase de un conjunto de ejemplos, se podría definir de manera global en las siguientes etapas (ver [Duin and Pekalska, 2005] para ampliar estas definiciones):

- El primero de ellos consiste en la *adquisición* de los ejemplos a procesar, las cuales se capturan a través de dispositivos mecánicos y/o electrónicos, denominados sensores, que incorporan transductores que miden una manifestación física y la transforman en ordenamientos numéricos. En nuestra aplicación, los sensores son los sismómetros, que convierten las vibraciones de la tierra generadas por sismos en una variable eléctrica fácilmente medible y cuantificable.
- Después de almacenada la variable numérica, se procede a hacer su *acondicionamiento* (aplica generalmente en casos que el ordenamiento numérico sea una señal —serie de tiempo— o un arreglo matricial). Esta etapa, también conocida como pre-procesamiento, consiste en

hacer las adaptaciones necesarias a la variable para una adecuada extracción de sus características y posterior clasificación; adaptaciones tales como aplicación de filtros (en señales), segmentación (en el caso de imágenes), escalamiento, estandarización y normalización de datos, transformaciones y mapeos numéricos, entre otros.

- Una vez los datos se han acondicionado mediante la estrategia más conveniente de acuerdo a su naturaleza, se ejecuta la **caracterización** de los ejemplos, haciendo una “*representación*” de los mismos mediante la valoración de ciertas propiedades o atributos; esto permite, asimismo, hacer una reducción de la cantidad de datos a procesar en las siguientes etapas.
- Ocasionalmente, el arreglo de los datos en vectores de características no proporciona una reducción suficiente de su tamaño global. En este caso se procede a la **adaptación** de los mismos, la cual consiste en transformaciones que se hacen mediante proyecciones de los datos a dimensiones más bajas. La adaptación también puede obedecer a mapeos matemáticos de los datos que favorecen la posterior extracción de características al hacerlas más ostensibles.
- Después que los datos son presentados en una versión re-dimensionada y/o transformada, se lleva a cabo una categorización de cada ejemplo dentro de una clase previamente establecida. A esta etapa se le conoce como **clasificación**; en la cual un algoritmo asigna una etiqueta de clase o categoría, orientado por los valores de las características de la instancia. En algunos casos, la etapa de clasificación podría determinar o no (dependiendo de la aplicación) una *acción* posterior dentro de un sistema de PR, ejecutada por un actuador, como por ejemplo, retirar de la línea de producción un producto terminado etiquetado como “defectuoso”.
- Finalmente, se lleva a cabo una estimación del desempeño del sistema de reconocimiento mediante la etapa de **evaluación**, en la cual se valida si la etiqueta asignada por el sistema al conjunto de prueba, coincide con la etiqueta verdadera asignada por el experto. Posteriormente veremos cómo una retroalimentación de este paso a la entrada resulta trascendental dentro de un marco adaptativo de un sistema.

El procedimiento previamente detallado describe la emulación sistemática, a través de medios computacionales y mecánicos, del enigmático proceso del aprendizaje humano, basado en el paradigma de aprender a partir de ejemplos representativos. El reconocimiento de patrones, en su propósito de generar sistemas automáticos, plantea una secuencia de pasos que parte de un proceso de bajo nivel en el que objetos individuales son observados y capturados por sensores, y pasa a uno de alto nivel en el que se toman decisiones basadas en el patrón global de una clase de objetos [Duin and Pekalska, 2005]. Las investigaciones en torno a PR mantienen cuestionamientos abiertos y retos desafiantes en cada una de las etapas descritas [Duda et al., 2006], en particular, aquellos que pretenden cerrar la brecha entre el PR estructural y el estadístico, al igual que la brecha existente entre la generación de conocimiento y las instancias (representación adecuada y selección de ejemplos relevantes).

Las recientes tendencias en PR validan la importancia del conocimiento *a priori* para la generación de modelos que ejecuten procesos de aprendizaje especializados (inducción, transducción y abducción [Duda et al., 2006]) y estén en capacidad de generar nuevo conocimiento a partir de recientes observaciones. Esta condición podría intentar mantener un desempeño satisfactorio del modelo a

través del tiempo, en un escenario real. En consecuencia, y de conformidad a este desafío, en el presente trabajo se propone una metodología más robusta que la tradicional —dirigida a una aplicación en particular— orientada a la generación constante de conocimiento mediante la cualidad adaptativa de un sistema automatizado diseñado.

3.2. Metodología orientada al reconocimiento de patrones sísmicos empleando técnicas adaptativas e incrementales

La clasificación de sismos de origen volcánico ha generado, en el estado del arte, un amplio repertorio de alternativas metodológicas para tratar el problema de asignación automática de etiquetas de clase a los eventos sísmicos registrados en los observatorios vulcanológicos (ver Sección 1.3.2); muchos de ellos han mostrado un reporte de desempeño satisfactorio, al menos desde el punto de vista cuantitativo de las medidas de evaluación (sin detallar en la configuración experimental). Sin embargo, las aproximaciones metodológicas de los trabajos hallados, a pesar de ser planteadas con diferentes estrategias y modelos de clasificación, presentan como factor común la presunción de estacionariedad en el contexto de la aplicación; por lo mismo, los marcos experimentales propuestos contemplan una cantidad relativamente pequeña de ejemplos, tomados de periodos muy cortos, lo cual no es representativo de la naturaleza evolutiva del entorno volcánico.

Los contextos dinámicos, como los relacionados a fenómenos naturales, se consideran procesos generadores de datos no estacionarios, que típicamente se han asumido en la práctica como procesos estacionarios, cada uno de los cuales hipotéticamente siempre provendrá de una distribución de probabilidad fija aunque desconocida. Cuando dichos ambientes requieren de monitoreo tecnológico continuo, las pequeñas tasas de muestro generan una vasta cantidad de datos que rápidamente limitan los recursos de almacenamiento físico, por lo que su procesamiento (y en lo posible, su análisis) de manera *en línea* se hace indispensable. Lo anterior sugiere que un contexto con dichas características requiere de tratamientos diferentes a la tradicionales para analizar la información generada, como los formulados desde el enfoque de *Big Data* [Oussous et al., 2018], el cual facilita el manejo de *data streams*.

Ubicándonos puntualmente en el área de la sismología volcánica, ésta podría catalogarse como un entorno cambiante que obedece a características como las anteriormente descritas, complementadas con otras condiciones peculiares del ámbito, como lo son: *i*) la variabilidad introducida en los registros por heterogeneidad en la instrumentación de adquisición en estaciones sísmicas del mismo volcán, o reemplazo de equipos en la estación-fuente de los datos; *ii*) diferencias en la geología de las zonas volcánicas donde están instalados los sismómetros, lo que implica diferentes atenuaciones en las trayectorias de las ondas sísmicas; *iii*) las propiedades y características intra-clase de la variedad de categorías de sismos volcánicos evolucionan a través del tiempo, especialmente comparando períodos de inactividad con etapas eruptivas.

Teniendo en mente esta dinámica cambiante implícita en las señales sísmicas, toma fuerza la hipótesis que un sistema automático de reconocimiento de patrones usado para identificar la clase de

sismos, diseñado bajo la suposición de estacionariedad, mantendrá un rendimiento de clasificación en decadencia conforme el tiempo avanza. Por lo mismo, un nuevo planteamiento de estrategias de modelado enmarcadas en la adaptatividad y orientadas al manejo de flujo de datos que evolucionan en el tiempo, generará modelos de aprendizaje que conserven una base de conocimiento actualizada, y que aprenden permanentemente de instancias producidas en diferentes estados de actividad volcánica, evitando así detrimentos en su desempeño.

Además de proporcionar estabilidad en el rendimiento del modelo a lo largo del tiempo, vale la pena exponer otra cualidad importante del enfoque propuesto, relacionada a la disponibilidad inicial de etiquetas reales para entrenar el modelo. El monitoreo volcánico efectuado por el personal experto de los observatorios vulcanológicos y Sismológico se lleva a cabo las 24 horas del día, al igual que otras tareas primarias, como la categorización o asignación manual de etiquetas a los eventos sísmicos registrados. Esta tarea se ejecuta en tiempo real en períodos de baja actividad volcánica; sin embargo, durante periodos de reactivación, donde son frecuentes los aumentos súbitos de la cantidad de sismos ocurridos a diario, así como los denominados enjambres (gran cantidad de sismos en cortos periodos de tiempo), esta labor se dificulta. El número limitado de expertos en una situación como esta implica que una cantidad creciente de eventos sísmicos permanezcan represados sin ser etiquetados y procesados durante días e incluso semanas. Así pues, la presunción de falta de etiquetas verdaderas durante ciertos períodos de tiempo, considerado como una condición inicial de nuestro enfoque, valida la conveniencia de su uso en aplicaciones como la clasificación automática de sismos.

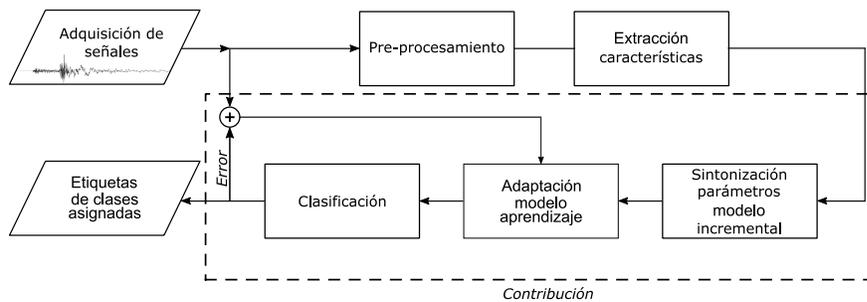


Figura 3-1.: Esquema de clasificación adaptativa de eventos sísmicos basada en algoritmos de aprendizaje incremental

La Figura 3-1 muestra el esquema metodológico propuesto en esta tesis, el cual parte del concepto básico de un sistema de reconocimiento (Fig. 1-1), y es adaptado para incluir procedimientos que hacen inferencia a entornos cambiantes, en particular, el volcánico (cumplimiento del objetivo general de esta tesis). El esquema está compuesto, inicialmente, por las etapas tradicionales de: adquisición de datos, pre-procesamiento y extracción de características; esta última contempla una fase adicional de reducción de dimensión. Posteriormente, se consideran los pasos propios del enfoque adaptativo propuesto —etapas en las cuales se centra la contribución de este trabajo— conformados por una sintonización de parámetros que permite situar la clasificación en un marco adaptativo y de aprendizaje incremental (cumplimiento del objetivo específico 3), que son las etapas sucesivas; éstas son llevadas a cabo por un algoritmo incremental propuesto en este trabajo. Este algoritmo, entre otras cualidades, permitirá compensar la falta de disponibilidad de etiquetas reales, hecho

común en la práctica. La etapa de ‘Evaluación’ (cumplimiento del objetivo específico 4) no figura explícitamente en el diagrama, pero se considera implícita en el lazo de retroalimentación que relaciona la salida del clasificador (etiquetada como ‘Error’) con los bloques de ‘Adquisición de señales’ y el de ‘Adaptación’.

En las siguientes secciones y capítulos profundizaremos en cada una de las etapas planteadas en el diagrama de la metodología propuesta, iniciando por las dos primeras, en lo que resta del presente capítulo. A continuación, se estudiarán las formas de generación de características más idóneas para representar las señales sísmico-volcánicas que serán insumo de las siguientes etapas (Capítulo 4 - cumplimiento del objetivo específico 1). Las etapas ubicadas en la parte inferior del diagrama concentran la contribución de esta tesis (Capítulo 6 - cumplimiento de los objetivos específicos 3 y 4), ejecutadas después de la identificación de la condición del *concept drift* como justificación experimental de la contribución (Capítulo 5 - cumplimiento del objetivo específico 2).

3.3. Bases de datos empleadas

El insumo más importante para el desarrollo de un trabajo experimental con pretensiones como las nuestras es la calidad de los datos, por lo cual fue indispensable tener control y conocimiento pleno de las condiciones de adquisición de las señales sísmicas; de esta manera sería posible definir claros criterios de exclusión de datos. En Internet difícilmente se pueden hallar bases de datos relacionadas a sismos volcánicos de carácter *open access*, con amplios periodos de recolección de datos y que aporten información detallada sobre las condiciones de su adquisición. En razón a lo previamente expuesto, fue necesario gestionar el préstamo de datos directamente con los entes encargados de adquirirlos, es decir, con observatorios vulcanológicos y sismológicos. Generalmente dichas instituciones son gubernamentales, pero no necesariamente ello implica que los datos por ellas adquiridos sean de dominio público; por tal motivo, fue necesario tramitar el préstamo de las bases de datos mediante nuevos convenios o algunos previamente establecidos. A continuación, se describen los detalles de las dos bases de datos empleadas en este trabajo.

3.3.1. Base de datos del Volcán Nevado del Ruiz

El volcán Nevado de Ruiz (VNR) es un complejo volcánico de naturaleza andesítica, ubicado a 5321 m.s.n.m., en la Cordillera Central de Colombia (4° 53' 43"N; 75° 19' 21"W), aproximadamente a 28 km de la ciudad de Manizales y a 140 km de Bogotá, la capital del país. Un número importante de asentamientos poblacionales se han venido estableciendo en inmediaciones del volcán y su área de influencia, lo que lo hace uno de los volcanes más peligrosos del mundo. Su cima está cubierta por una capa glacial que cuenta con un volumen estimado entre los 12000 y 15000 m³, área en la cual se encuentra ubicado su cráter principal y activo, conocido como “Arenas”; los otros dos, “Olleta” y “Piraña”, son cráteres parásito [Castaño et al., 2020]. El VNR es reconocido a nivel mundial por la catástrofe que desató el 13 de noviembre 1985 tras la erupción que deshizo cerca

del 5 % de su capa glacial, provocando enormes lahares y flujos de escombros que arrasaron con la ciudad de Armero, y produjo un saldo mayor a 20000 víctimas mortales.

Este volcán es considerado uno de los volcanes más activos de Colombia y de Latinoamérica, por lo cual es monitoreado de manera continua por el Observatorio Vulcanológico y Sismológico de Manizales (OVSM) —perteneciente al SGC— desde 1985, tras la dramática erupción del 13 de noviembre [Londoño, 2010]. Desde entonces, el VNR ha mostrado cambios importantes en su sismicidad, posiblemente relacionados a intrusión magmática, manteniendo ciclos de actividad alternados, algunos más marcados que otros, entre los cuales se destaca el iniciado desde el 2010, en el que se han presentado pequeñas erupciones de tipo freatomagmática y efusiva que tuvieron lugar en junio de 2012 y octubre de 2015, respectivamente [Londono, 2016].

A lo largo de estas décadas de funcionamiento, el OVSM ha venido fortaleciendo las redes de monitoreo en todas sus metodologías, y actualmente cuenta con una red sismológica dotada con 14 sismómetros de banda ancha y 6 de periodo corto, cuyas señales adquiridas son muestreadas a una frecuencia de 100 Hz y digitalizadas a una resolución de 16 bits. Dado que la finalidad de nuestra investigación no es la integración de toda la información replicada de un mismo evento en sus diferentes estaciones y componentes, para la ejecución de algunos experimentos de este trabajo únicamente se consideraron las señales adquiridas por la estación sísmica denominada “Bis” (sismómetro triaxial de periodo corto), empleando sólo las registradas por su componente Z. La elección se debe a que ésta fue la estación usada como referencia en el OVSM (al menos durante el desarrollo del estudio) para hacer el análisis de los eventos registrados, y se optó por el eje vertical debido a su mejor relación señal-ruido (SNR por su acrónimo en inglés) y porque esta componente suele registrar armónicos que las componentes horizontales ocasionalmente omiten.

La base de datos del VNR empleada en la ejecución de los experimentos del Capítulo 4 fueron capturadas entre enero 2010 y septiembre de 2013, logrando un catálogo de eventos de 2856 registros. El OVSM, durante su tiempo de operación, ha definido categorías de sismos volcánicos y no volcánicos en las cuales es clasificado cada evento registrado por parte del analista experto. Dichas categorías obedecen a las señaladas en la Sección 2.2.2 (VT, LP, HB, TR, EX, TO, IC), más algunas adicionales designadas como AV (avalancha), RY (rayos), SM (sismo múltiple), DS (Distal-tectónico), RE (Regional-tectónico), TL (Telesismo-tectónico). El conjunto de datos original entregado por el OVSM contiene las 13 clases mencionadas; sin embargo, las 6 últimas fueron descartadas de entrada dado que corresponden a clasificación de actividad superficial y tectónica generada en el volcán o áreas aledañas, lo cual se aleja del enfoque de este trabajo dirigido a la clasificación de clases volcánicas de sismos.

3.3.2. Base de datos del Volcán Villarrica

La segunda base de datos empleada en este trabajo corresponde a señales sísmico-volcánicas adquiridas del volcán Villarrica, también considerado como uno de los más activo de Suramérica y uno de los volcanes más peligrosos de Chile. Se encuentra ubicado en la región de la Araucanía, al sur de los Andes chilenos ($71^{\circ} 56' 23''$ W; $39^{\circ} 25' 12''$ S); una región de alta actividad tectónica

(Zona Volcánica Sur) que está limitada por la placa oceánica de Nazca y la placa continental de América del Sur. Su altura máxima es de 2847 m s.n.m. donde se ubica un cráter abierto de 200 m; su cima está cubierta por un casquete glacial de proporciones importantes que se extiende a más de 30 km², y su capa de nieve se eleva a partir de los 1500 m s.n.m., aproximadamente [Van Daele et al., 2014]. A partir de la secuencia eruptiva finalizada en 1985, en la base del cráter se formó un lago de lava con desgasificación permanente y niveles de superficie variables [Richardson et al., 2014].

El Villarrica es un estratovolcán que tiene una composición basáltica y andesítica, por lo que sus erupciones históricas han sido principalmente de carácter efusivo y explosivo, con emisión de material magmático en forma de flujo de lava, caída de piroclastos y lahares. Su registro histórico supera las 54 erupciones en los últimos 450 años; la actividad de los recientes 30 años ha mantenido un nivel eruptivo moderado, que incluye erupciones estrombolianas leves, desgasificación continua y explosiones ocasionales [Lehr et al., 2019]. La última erupción de proporciones mayores ocurrió el 3 de marzo de 2015, en la que se generaron lahares, flujo de lava de 1.5 km, y una columna de ceniza de 3 km de altura. La actividad sísmica de base de este volcán está predominantemente relacionada a eventos de baja frecuencia asociados al sistema de desgasificación continua [Lehr et al., 2019], en particular, a las señales de tremor que se pueden presentar por largos periodos de tiempo de manera continua, variando su amplitud y contenido frecuencial dependiendo de cambios en condiciones de depresurización de gases, entre otros factores.

El volcán Villarrica, al igual que otros 44 volcanes (de los 90 considerados activos en Chile) permanece en monitoreo continuo a través del Observatorio Volcanológico de los Andes del Sur (OVDAS), ubicado en la ciudad de Temuco — Chile, el cual hace parte del Servicio Nacional de Geología y Minería, y es la institución que hace vigilancia en red a la mayor cantidad de volcanes en el mundo. En el área de sismología, la red del volcán Villarrica está compuesta por nueve estaciones, dotadas de 2 sismómetros de periodo corto y 7 de banda ancha que se distribuyen sobre el edificio volcánico. Las señales sensadas son registradas de manera continua a una frecuencia de muestreo de 100 muestras por segundo, utilizando un convertidor analógico-digital de 16 bits en un rango dinámico de 80 dB. Al igual que en la primera base de datos, en ésta se emplearon experimentalmente los datos de una única estación —la referencia, denominada VN2— equipada con un sismómetro banda ancha de 3 componentes, de los cuales solo se emplearon los registros de la componente Z.

Las señales empleadas en este trabajo fueron adquiridas por el OVDAS de manera consecutiva entre enero de 2010 y abril 2017, conformando un catálogo de 350426 registros sísmicos¹. Al igual que el OVSM, el OVDAS ha definido una categorización de sismos, que en términos generales, se ciñe a la genérica definida previamente en la Sección 2.2.2. Dado que la dinámica de este volcán es predominantemente de eventos de baja frecuencia, en esta investigación se delimitó al estudio de las clases LP y TR, que abarcan la mayoría de eventos que se registran en el volcán; se adicionó también la clase VT (la siguiente clase de mayor cantidad de eventos aunque se presenta en muy bajas proporciones) con el fin de hacer el problema multi-clase.

¹El acceso a esta base de datos fue posible mediante un convenio previamente establecido entre el OVDAS y Departamento de Eléctrica de la Universidad de la Frontera (Temuco-Chile), institución en la cual llevé a cabo una pasantía investigativa en 2018.

Como se detallará en los capítulos 5 y 6, la base de datos del volcán Villarrica contempla una mayor robustez en comparación al catálogo adquirido para el VNR, debido a la nutrida cantidad de señales sísmicas que la conforman, la amplia cronología que logra abarcar (7 años de eventos registrados), y el pre-procesamiento en los datos que *a priori* dieron en la Universidad de la Frontera (UFRO), gracias al convenio mencionado. Por tal motivo, en los dos últimos capítulos de esta tesis, se hará uso únicamente de esta base de datos y no se tendrá en cuenta la del VNR, dado que los requerimientos experimentales de los abordajes teóricos de esos capítulos, así lo exigen.

3.4. Pre-procesamiento de señales sísmicas

En la etapa del pre-procesamiento fueron llevadas a cabo las adecuaciones que las señales sísmicas requirieron para mejorar la resolución de la información contenida en las series de tiempo registradas y la calidad de datos que se obtendrían a partir de ellas. Recordemos que previo al pre-procesamiento, se contempla la etapa de la adquisición, la cual depende de consideraciones y condicionamientos de la instrumentación. Esto indica que, en una proporción importante, el pre-procesamiento que deba hacerse a las mediciones captadas por los sensores depende en gran medida de las características del sistema de adquisición de datos, tales como la resolución, la relación señal-ruido y la frecuencia de muestreo.

3.4.1. Depuración de datos

Durante la conformación de bases de datos orientadas al diseño y evaluación de sistemas automatizados, pueden ocurrir inadvertencias que limitan la tarea de clasificación, y por ende, su rendimiento. Algunos de estos errores tienen origen en el etiquetado verdadero manualmente asignado por el experto: para algunas señales de difícil identificación, no es extraño que dos o más analistas no coincidan en la categoría o clase que le asignan, o en otros casos, que los expertos modifiquen a lo largo del tiempo su comprensión respecto a las señales ya registradas, haciendo evolucionar la interpretación de los datos. Por otra parte, ubicándonos más concretamente en el área que nos concierne, la solución de un problema de reconocimiento de patrones no solamente es determinada por la representación en sí misma o la robustez del algoritmo de clasificación, sino también la adecuada elección de conjuntos de entrenamiento y validación; esto es, una buena calidad en los datos usados, también resulta determinante en la obtención de rendimientos satisfactorios.

Del catálogo general de eventos sísmicos almacenados durante los periodos señalados para las dos bases de datos consideradas, en los respectivos observatorios vulcanológicos se hizo una primera depuración de datos mediante inspección visual de mediciones y parámetros demarcados en cada evento sísmico a través de los software de procesamiento primario que usan en cada observatorio. Los criterios aplicados de manera conjunta para la conformación selectiva de un nuevo conjunto de datos fueron:

- Evitar eventos sísmicos demasiado pequeños, por lo cual se definió seleccionar aquellos con amplitud pico a pico superior a $0,4 \mu\text{m/s}$.

- Otra forma de controlar el tamaño de los sismos fue seleccionando eventos sísmicos localizados y con magnitud superior a 0.8 en la escala de Richter.
- Eventos sísmicos que no tuvieran “*gaps*”; esto es, “huecos” en la serie de tiempo debido a pérdidas de señal a lo largo del registro del evento.
- Eventos sísmicos con duración mayor a 5 s. Los eventos demasiado cortos, generalmente también son muy tenues, así que solían ser eliminados por criterio de tamaño; un evento muy corto y muy energético, no es común y es motivo de análisis.
- Eventos sísmicos con morfología y espectro de frecuencias no atípica; esto es, que su etiqueta asignada manualmente no haya generado controversia entre dos o más expertos. Este último criterio aplicó principalmente para la base de datos del OVSM, la cual estaba destinada principalmente para caracterización de eventos sísmicos (experimentos de Capítulo 4), lo cual requería unos conjuntos de entrenamiento más selectos.

Relación señal - ruido (SNR)

Una vez depurados los datos por parte de los analistas de los observatorios y puestos a disposición para los procedimientos experimentales de esta investigación, los registros sísmicos (entregados en formato SUD) fueron sometidos a otro criterio de depuración mediante el cálculo de su relación señal - ruido. La SNR se define como la proporción que existe entre la amplitud o la potencia de la señal sísmica con respecto a la magnitud del ruido [Bormann and Wielandt, 2013]. En la práctica, la estimación de la SNR se llevó a cabo mediante la ecuación 3-1:

$$SNR = \frac{S}{N} \quad (3-1)$$

El anterior cálculo corresponde al cociente entre la magnitud media de una señal sísmica S , compuesta por n datos y muestreada a 100 Hz, y la magnitud media del ruido N , definido como el segmento de ruido sísmico de 3 s tomado desde los 1.5 s previos al inicio de la onda P del evento, tal como se muestra en la definiciones de la ecuación 3-2:

$$S = \frac{1}{n} \sum_{i=1}^n \sqrt{S_i^2}; \quad N = \frac{1}{300} \sum_{i=-450}^{-150} \sqrt{S_i^2} \quad (3-2)$$

Una vez calculada la SNR para cada evento sísmico de la base de datos, se definió el umbral óptimo con respecto al cual se seleccionaron aquellos eventos sísmicos que le sobrepasaran, el cual se estableció en SNR=2. Finalizado este proceso de depuración, la base de datos del OVSM se mantuvo con 2856 registros, mientras que la del OVDAS permaneció con 317648 registros de eventos.

3.4.2. Segmentación de sismos

La segmentación de los eventos sísmicos consiste en su detección y extracción del ruido de fondo, la cual se lleva a cabo mediante la identificación de la onda P y de la coda del evento, y recortando el ruido sísmico previo y posterior a estos dos parámetros identificados, respectivamente. Esta etapa de pre-procesamiento, aunque indispensable para procedimientos posteriores, no hace parte de la contribución central de esta investigación, por lo cual se llevó a cabo mediante la implementación de métodos tradicionales de segmentación o propuestos recientemente en el estado del arte. Para tal fin, se efectuó la colaboración académica de co-dirección en un estudio paralelo al presente, relacionado al tema de segmentación de sismos, cuyos resultados se exponen en [Erazo Bravo, 2019].

En este trabajo, se pone a prueba el conocido algoritmo de detección de sismos denominado STA/LTA (short-time-average through long-time-average trigger), el cual básicamente se define como una razón entre la amplitud o la energía promedio en una ventana de apertura de tiempo corto y la amplitud o la energía promedio de una ventana de seguimiento de tiempo largo (ver en Anexo A el detalle de este algoritmo). Este algoritmo es comparado con el propuesto en [Zimroz et al., 2015], que emplea una descomposición en tiempo-frecuencia a partir del espectrograma de la señal y modelamiento estadístico de la serie de tiempo asociado a cada frecuencia, mediante el cálculo de cuantiles empíricos.

Dado que, de acuerdo a las medidas de desempeño empleadas en la investigación de Erazo Bravo [2019] el rendimiento del segundo algoritmo fue superior, la segmentación llevada a cabo en el presente trabajo se ejecutó mediante la descomposición en tiempo-frecuencia y modelamiento estadístico de la señal.

3.5. Resumen del capítulo

El presente capítulo ha expuesto en detalle la metodología propuesta para afrontar el problema presentado y alcanzar los objetivos planteados. Para tal fin, primero se explicaron algunas generalidades sobre el reconocimiento de patrones aplicado a sistemas de clasificación, incluyendo conceptos básicos y etapas que componen un sistema de reconocimiento genérico. Posteriormente, se definió el esquema metodológico propuesto para lograr una clasificación adaptativa de sismos volcánicos haciendo uso del aprendizaje incremental y, a la vez, identificando en cada etapa el alcance de los objetivos. Seguidamente, se describieron las bases de datos usadas en la fase experimental de este trabajo, para luego dar paso al desarrollo de la fase de pre-procesamiento, explicando los conceptos aplicados en ésta. Las siguientes etapas del esquema serán explicadas y desarrolladas en los siguientes capítulos.

Parte II.

**Identificación de sismos volcánicos
mediante aprendizaje incremental**

4. Estimación de representaciones de señales sísmo-volcánicas

Un desafío permanente en el área de reconocimiento de patrones durante décadas de estudio ha sido la identificación de representaciones efectivas de los fenómenos y problemas físicos del mundo real, dado que un proceso de clasificación o identificación de clases razonablemente exitoso está fuertemente ligado a la representación apropiada de los datos. A través de un modelo de representación se logra la estimación de un conjunto de medidas, las cuales transforman la información de un segmento de señal en valores absolutos o coeficientes. El objetivo final de este procedimiento es representar la señal en un espacio métrico, asociado a una función de distancia que sea minimizada al evaluar objetos de la misma clase y se maximice con ejemplos de diferente clase.

En el presente capítulo, se hace un recorrido por los diferentes tipos de parámetros, características, atributos o descriptores comúnmente usados en el estado del arte para representar las señales sísmicas de origen volcánico, intentando hacer una representación robusta, que cubra la mayor cantidad de dominios posible. Aquí se hace una formalización matemática de las caracterizaciones empleadas en el presente estudio. Se llevaron a cabo pruebas experimentales que permitieran definir la representación más compacta y discriminante para este tipo de señales.

Una parte significativa del compendio de características empleado en el presente trabajo, y del estudio efectuado en este capítulo, está basada en las siguientes publicaciones asociadas a la tesis:

- Castro-Cabrera, P. A., Orozco-Alzate, M., Adami, A., Bicego, M., Londono-Bonilla, J. M., and Castellanos-Domínguez, G. (2014). *A comparison between time-frequency and cepstral feature representations for the classification of seismic-volcanic signals*. In Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications: 19th Iberoamerican Congress, CIARP 2014, Puerto Vallarta, Mexico, November 2-5, 2014. Proceedings 19 (p. 440-447). Springer International Publishing.
DOI: https://doi.org/10.1007/978-3-319-12568-8_54
- Orozco-Alzate, M., Castro-Cabrera, P. A., Bicego, M., and Londoño-Bonilla, J. M. (2015). *The DTW-based representation space for seismic pattern classification*. *Computers & Geosciences*. Vol. 85, p. 86-95. DOI: <https://doi.org/10.1016/j.cageo.2015.06.007>

4.1. Trascendencia de la representación

El asunto de la representación, aunque originalmente debe ser una cuestión esencial en un proceso de reconocimiento de patrones, ha perdido rigor al crearse una dependencia de la calidad de las características al conocimiento del experto y su habilidad para identificar visualmente atributos de un objeto generado a partir de las mediciones de un sensor. Caracterizar series de tiempo, imágenes 2D, objetos 3D, etc., implica el uso de enfoques distintos, de manera combinada o independiente, aunque con un propósito común: lograr una buena representación de las observaciones originales, dado que difícilmente se podrá mejorar el proceso de aprendizaje si la representación —como punto de partida en un problema de PR— no está bien definido. Aún así, algunas guías teóricas sobre PR asumen que los objetos ya están representados de alguna manera y, por tanto, no tratan el tema de la representación. Por tal motivo, en el presente trabajo se ha considerado conveniente no pasar por alto la etapa de la representación, analizando aquellas características que, de las propuestas en estudios previos, hacen mayor aporte a la capacidad de generalización de un clasificador dado.

La búsqueda de una representación adecuada requiere del conocimiento profundo de la aplicación práctica en concreto, al igual que del uso de algunas herramientas matemáticas que conlleven a la optimización de la representación. Entre los métodos más usuales para lograr la optimización de una representación se encuentran la extracción de características, la selección de características, la selección de prototipos mediante criterios generales como la información mutua o el rendimiento de un clasificador 1-NN, entre otros. Adicionalmente, se puede dar el caso en que una representación se pueda llevar a unas condiciones óptimas durante la etapa de generalización, y ello dependerá del modelo de aprendizaje que se emplee. Lo anterior señala la importancia de propender (haciendo uso de los procedimientos necesarios) por una representación de calidad, antes de avanzar en el proceso del reconocimiento de patrones del problema en cuestión.

La representación se puede definir como una codificación de objetos del mundo real mediante una valoración numérica que pueda ser procesada, analizada y comparada usando máquinas (computadoras). Posterior a este punto, se puede proceder a la etapa de la generalización, a través de descriptores que discriminen las diferentes clases de objetos; esto se logra mediante la construcción de clasificadores que dividan el espacio de características en regiones asociadas a cada una de las clases.

Tradicionalmente, se emplean vectores para representar objetos, los cuales son proyectados en espacios —lineales o no lineales— de características, y que en consecuencia se denominan espacios vectoriales de características, o simplemente, espacios de características. A menudo se considera que el proceso de aprendizaje de una máquina comienza en el espacio de características dado; en consecuencia, vale la pena concebir la generalización como un fin en la construcción de un sistema de reconocimiento de patrones que se estudie, diseñe e implemente, en relación directa a la representación, y no de manera aislada. Un espacio vectorial de características puede disponerse

en un arreglo matricial, denominado *matriz de características*, que matemáticamente puede verse como sigue:

$$\mathbf{X} = \begin{bmatrix} x_{1,1} & x_{1,2} & \cdots & x_{1,n} \\ x_{2,1} & x_{2,2} & \cdots & x_{2,n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{p,1} & x_{p,2} & \cdots & x_{p,n} \end{bmatrix} \quad (4-1)$$

donde \mathbf{X} es una matriz de características que representa un espacio vectorial n -dimensional de características, que contiene p vectores de tamaño n ; lo que indica que para resolver un determinado problema de PR se cuenta con p observaciones, cada una con n características que representan un objeto de clase c .

4.1.1. Tipos de representación

Un objeto real puede ser representado de manera numérica o cualitativa. En lo que a la primera respecta, se pueden distinguir varios tipos de representaciones, entre las cuales se destacan las siguientes:

- *Muestreo*: El muestreo es la aproximación más simple y directa de representación de un objeto real. Las muestras en el tiempo, en longitudes de ondas, o los píxeles, componen los tipos de muestreo para las señales (o series de tiempo), espectros e imágenes, respectivamente. Aunque el muestreo ofrece una forma de representación muy completa, suele generar un extenso volumen de datos, difícil de procesar, dado que crearía espacios vectoriales de muy alta dimensión en donde se aumentaría la complejidad para ubicar un punto (objeto) en el espacio vectorial.
- *Características*: La reducción de objetos del mundo real a vectores dentro de un espacio vectorial de características se emplea tradicionalmente para la representación de los mismos, donde son descritos mediante atributos o características que son compactadas en un vector. La caracterización es una forma muy simplificada de representación del objeto que al momento de la generalización resultaría beneficiosa, pero que, paralelamente, también podría desdibujar la naturaleza del objeto: si hay una estructura organizacional entre los objetos, como es el caso de píxeles vecinos, tal relación entre los elementos se perdería. Sin embargo, la generalización sobre conjuntos de vectores está ampliamente estudiada y matemáticamente bien fundamentada, lo que respalda su uso altamente difundido.
- *Similitudes, disimilitudes o proximidad*: En las dos descripciones anteriores, la representación dada es *absoluta*; esto es, que los patrones están representados por valores puntuales, clásicamente por puntos en un espacio vectorial de características. En lugar de esto, puede darse una *representación relativa* de los objetos mediante disimilitudes, las cuales se deri-

van de la comparación de un objeto (mediante algún tipo de distancia) con respecto a un conjunto específico de objetos, que puede ser detalladamente seleccionado como prototipos representativos (aunque, según Pekalska et al. [2006], escogidos de manera aleatoria también podría funcionar bien). Este tipo de representación resulta especialmente útil en aplicaciones reales que implican juicios humanos, donde es más simple generar medidas relacionales que descriptores; se puede producir a partir de muestras en el tiempo, espectros, características, datos sin procesar, imágenes, entre otras.

- *Modelos de probabilidad*: Un objeto pueden ser caracterizado mediante un modelo de probabilidad, cuya generación puede darse a partir del conocimiento del experto o basado en el entrenamiento de un conjunto menor de ejemplos. Sin embargo, no es una forma de caracterización frecuente, dado que la combinación entre el conocimiento y una estimación de probabilidad es compleja, especialmente para modelos robustos.
- *Representación conceptual*: Una forma adicional de representación se puede originar a partir de un conjunto de representaciones. Esto puede darse, por ejemplo, mediante la combinación de clasificadores o *clusters*, cada uno de ellos configurado en base a una representación, modelo o conjunto de entrenamiento diferente.

En relación a la representación de los objetos de manera cualitativa, una alternativa común es hacerlo mediante modelos estructurales o sintácticos, los cuales emplean datos simbólicos para hacer su representación de patrones a través de cadenas, grafos, matrices o árboles gramaticales, principalmente. Estas estructuras de datos describen relaciones entre elementos básicos y generan modelos jerárquicos que muestran cómo se construyen patrones complejos a partir de componentes más simples. Un patrón desconocido se puede identificar mediante la comparación (que calcula una medida de similitud) entre su representación simbólica y unos modelos de objetos predefinidos (prototipos). Más detalles de este tipo de representación, se pueden encontrar en [Bunke, 1993].

4.2. Modelos de representación para señales sísmicas

Cuando de automatizar un proceso se trata, en primer lugar los expertos en cada materia deben disponer de un grupo de atributos o características que le permitan a la máquina (algoritmo de clasificación) establecer límites de decisión bien definidos que distingan claramente una clase de objeto de otra. Algunos de estos atributos o descriptores, están basados en apreciaciones visuales del experto de la forma de onda de la señal o serie de tiempo, y otros están definidos a partir de mediciones hechas mediante equipos e instrumentos especializados. Sin embargo, en ocasiones, dichos atributos no son los suficientemente discriminantes y deben ser trasladados a espacios de características adecuados a través de transformaciones que generen una representación más idónea de las señales de interés.

El estado del arte en el área de clasificación automática de sismos ha registrado una numerosa cantidad de trabajos relacionados con la identificación, caracterización y clasificación de señales sísmicas de origen volcánico; algunos de ellos comparten dominios de representación, técnicas de

extracción de características, o bases de datos (como se puede detallar en la Tabla 4-1), pero difícilmente comparten más de dos de estos aspectos, por lo que hacer comparaciones directas de rendimientos (para determinar las características más destacadas), resulta incierto. En materia de caracterización, la revisión de la literatura muestra que, en principio, varias de las características empleadas para representar las señales sísmicas provienen de métodos y técnicas aplicadas en otras clases de señales como las antrópicas [Tucker and Brown, 2005], la música [Fujinaga and MacMillan, 2000], el habla [Esmaili et al., 2004] y la bioacústica [Fagerlund, 2007; Zaugg et al., 2010; Han et al., 2011].

Así mismo, varios estudios han mostrado que las características definidas para la clasificación de señales de un volcán, no necesariamente funcionan con las mismas bondades en otro volcán; esto se puede explicar en la variabilidad de las fuentes sismogénicas y en las diferencias geológicas de cada terreno, lo que impacta en el recorrido de las señales sísmicas, y por tanto, en la morfología y demás propiedades intrínsecas de las mismas. No obstante, debido a lo anteriormente expuesto, en el estado del arte no se ha logrado consolidar un consenso que defina un conjunto o familia de atributos que proporcionen un desempeño significativo, real y consistente durante una clasificación automática, lo que motiva al planeamiento experimental del presente capítulo.

Dado que el foco de esta tesis no está dirigido hacia la representación de las señales sismo-volcánicas sino hacia su clasificación, esta parte de la investigación no se encaminó hacia la proposición de nuevos descriptores. Por tal motivo, se procedió a determinar experimentalmente los atributos que, procedentes del estado del arte, tuvieran una buena capacidad de generalización y que ofrecieran mayor discriminancia entre las clases de señales evaluadas, lo cual será exhibido en la Secciones 4.4 y 4.5. En los siguientes apartados se detallará acerca de los dominios de las características empleadas y posteriormente se hará la descripción matemática de cada una de ellas. La Tabla 4-1 recopila los estudios revisados más destacados del estado del arte. Acá se establecen los datos utilizados, la cantidad y tipo de clases definidas para la aplicación, y la forma de representación empleada; con este resumen, se logran identificar con facilidad las técnicas de extracción de características principalmente usadas en el estado del arte. Adicionalmente, se relaciona el método de aprendizaje usado en cada estudio, lo cual servirá de guía comparativa en los siguientes capítulos cuando se trate la etapa de clasificación. A continuación, se define la abreviación empleada en la tabla para indicar el sitio en el cual se han adquirido las señales que conforman la base de datos usada para llevar a cabo cada investigación:

Campos Flégreos, Italia (PFV); Complejo volcánico Planchón-Peteroa (PPVC); Volcán Ambrym, Vanuatu (AMV); Volcán Cotopaxi, Ecuador (COV); Volcán de Fuego, Mexico (FUV) Volcán Isla Decepción, Antartica (DIV); Volcán Etna, Italia (ETV); Volcán Las Cañadas, Tenerife, España (LCV); Volcán Llaima, Chile (LLV); Volcán La Soufrière, Guadalupe (LSV); volcán Monte Bezymianny, Rusia (MBV); Volcán Monte Merapi, Indonesia (MMV); Volcán Monte Vesubio, Italia (MVV); Volcán Nevado del Ruiz, Colombia (NRV); Volcán Nevado del Huila, Colombia (NHV) Volcán Piton de la Fournaise, Francia (PFV) Volcán San Cristóbal, Nicaragua (SCV); Volcán Soufrière Hills, Montserrat (SHV); Volcán Stromboli, Italia (STV); Volcán Ubinas, Perú (UBV); y Volcán Villarica, Chile (VRV).

En esta revisión de la literatura también se consideraron estudios aplicados a señales sísmicas tectónicas, teniendo en cuenta su afinidad con los eventos de origen volcánico y valorando el aporte técnico que su abordaje pudiera tener. Los datos considerados en esos estudios provienen de: Red de Banda Ancha Europea (EBN); Red sísmica Mediterránea (MSN); Red de los montes Ibleos (HPN); Red de la región de Mármara (MRN); Red sísmica nacional de Finlandia (FSN); y Red de Los Servicios Sísmicos de Bavaria (BEN).

Se invita al lector a revisar la siguiente tabla para relacionar los detalles de los estudios de sitio y su respectiva publicación. Remitirse, por favor, a la Sección 2.2.2 para identificar fácilmente algunos tipos de sismos no usuales, definidos en la columna *Clases*.

Tabla 4-1.: Compendio de principales estudios revisados y resumen de sus configuraciones experimentales. Tabla creada mediante la ampliación y actualización de la contenida en [Orozco-Alzate et al., 2012].

Publicación	Base de Datos	Clases	Representación	Clasificación
[Avossa et al., 2003]	STV	Dos tipos de EX	Serie de tiempo + PCA	ANN
[Benítez et al., 2006]	DIV	VT, LP, TR y HB	MFCCs	HMM
[Beyreuther et al., 2008]	LCV	VT, RE, ruido de fondo	Atributos morfológicos y espectrogramas	HMM
[Beyreuther and Wassermann, 2008]	BEN	VT, RE, TL, ruido de fondo	Envolvente y atributos espectrales	HMM
[Bueno et al., 2019]	MBV	LF, HF, TR y CO	Espectrogramas	DNN bayesiana
[Canario et al., 2020]	LLV	VT, LP, HB, TR y TC	Coefficientes transformada Wavelet continua	DNN
[Chu-Salgado et al., 2009]	NRV	VT y LP	espectro 1-D + selección de características	NMC, k -NN y LDC, ensamble con reglas combinadas
[Curilem et al., 2009]	VRV	LP, TR y TR energético	Atributos morfológicos espectrales y de forma de onda	ANN
[Del Pezzo et al., 2003]	PFV	VT y EX artificiales	LPCs	ANN
[Duin et al., 2010]	NRV	VT, LP y IC	Espectro 1-D y espectrograma + PCA	QDC y platillas de decisión
[Espinoza Lara et al., 2020]	UBV	VT, LP, HB, TR y EX	Atributos morfológicos de forma de onda, espectrales y MFCCs	SVM
[Esposito et al., 2006]	STV	LS, EX y micro-TR	LPCs y atributos morfológicos	ANN
[Ezin et al., 2002]	MVV	Sismos tectónicos y falsos (truenos, explosiones marina, etc.)	LPCs y atributos morfológicos	ANN
[Falcin et al., 2021]	LSV	VT, LP, HB y TO	Atributos morfológicos de forma de onda, estadísticos y de entropía	RF
[Falsaperla et al., 1996]	STV	Cuatro clases de EX	Función envolvente, función de autocorrelación, y espectro 1-D	ANN
[Firoozabadi et al., 2017]	LLV	VT, LP Y TR	Atributos morfológicos espectrales	DNN

Continúe en la siguiente página

Continuación de la Tabla 4-1

Publicación	Base de Datos	Clases	Representación	Clasificación
[Gutiérrez et al., 2009]	SCV	LP, EX, TR y ruido de fondo	MFCCs	HMM
[Gutiérrez et al., 2006]	STV y ETV	EX y TR	MFCCs	HMM
[Hibert et al., 2017]	PFV	VT y ROF	Atributos morfológicos de forma de onda y espectrales	RF
[Hoogenboezem, 2010]	NRV	LP, RE, TL y VT	Espectrograma + PCA y mapeo de Fisher	Clasificador de Parzen, NMC, HMM, 1-NN, SVM, ANN y combinación de reglas
[Ibáñez et al., 2009]	STV y ETV	EX y ruido de fondo (STV). TR y estallidos de TR (ETV)	MFCCs	HMM
[Kortström et al., 2016]	FSN	Sismos tectónicos y sismos falsos	espectrograma + segmentos ondas P y S	SVM
[Langer and Falsaperla, 2003]	STV	Cuatro clases de EX	Función de autocorrelación, función envolvente y espectro 1-D	ANN
[Langer et al., 2006]	SHV	VT, RE, LP, HB, RF y LP+ RF	Función de autocorrelación; atributos morfológicos y estadísticos	ANN
[Lara-Cueva et al., 2017]	COV	VT, LP y LG	Coefficientes de transformada Wavelet	SVM
[Lara et al., 2021]	COV	LP y VT	Espectrogramas	DNN
[López-Pérez et al., 2020]	FUV	VT, LP, TR, EX, RE, NO y FL	LPCs, atributos morfológicos de forma de onda, estadísticos y espectrales	Clasificadores profundos de procesos gaussianos
[Malfante et al., 2018]	UBV	VT, LP, HB, TR, EX y TO	Atributos morfológicos de forma de onda, estadísticos y de entropía	SVM y RF
[Manley et al., 2022]	NRV y LLV	VT, LP, HB, TR y TC	Serie de tiempo de la señal	DNN
[Martínez et al., 2021]	PPVC	VT, LP, TR, RE y NO	LFCCs y LPCs	DNN
[Ohrnberger, 2001]	MMV	VT, MP y RF	Parámetros espectrales y de campo de onda	HMM
[Orozco-Alzate et al., 2006]	NRV	VT, LP y IC	Espectro 1-D + Disimilitudes	1-NN en espacio de características; LDC y QDC en espacio de disimilitudes
[Orozco-Alzate et al., 2008]	NRV	VT y LP	Espectro 1-D + bandas espectrales	LDC regularizado
[Orozco-Alzate et al., 2015]	NRV	VT, LP, TR, HB y TO	Espectrograma + Disimilitudes con DTW	SVM, Fisher y 1-NN
[Orozco-Alzate et al., 2019]	NRV	VT y LP	Espectrograma + MFCCs	Ensamble con k -NN

Continúe en la siguiente página

Continuación de la Tabla 4-1

Publicación	Base de Datos	Clases	Representación	Clasificación
[Porro-Munoz et al., 2010a]	NRV	VT y LP	Espectro 1-D y espectrogramas + Disimilitudes (multimodo)	Fisher lineal
[Porro-Munoz et al., 2010b]	NRV	VT y LP	Espectrogramas y esca-logramas + Disimilitudes (multimodo)	Fisher lineal
[Porro-Muñoz et al., 2011]	NRV	VT y LP	Espectrogramas + Disimilitudes (multimodo)	LDC regularizado
[Riggelsen et al., 2007]	EBN	NO y sismos tectónicos	Wavelet continua	Redes Bayesianas Dinámicas
[Romeo, 1994]	MSN	RE, TL, TS, sismos empíricamente denominados: 'spike' y 'sausage'	Atributos morfológicos espectrales	ANN
[Romeo et al., 1995]	MSN	RE, TL, TS, NO y sismos empíricamente denominados 'spike'	Atributos morfológicos espectrales	ANN
[Rouland et al., 2009]	AMV	TR y Sismos tectónicos	Atributos morfológicos de forma de onda	Detección de onda S
[Salazar et al., 2020]	COV	LP y VT	Espectrogramas	3 DNN
[Scarpetta et al., 2005]	MVV	Dos problemas: VT y explosión de excavación; EX bajo el agua y truenos	Coefficientes LPC y atributos morfológicos de forma de onda	ANN
[San-Martin et al., 2010]	LLV	LP, TR y VT	Transformada de Hilbert y Wavelet	LDC
[Titos et al., 2018]	FUV	LP, TR, VT, EX, RE y FL	LPCs + atributos estadísticos	DNN
[Titos et al., 2019]	FUV	LP, TR, VT, EX, RE, CO y NO	LPCs + atributos estadísticos	ANN convolucional dentro de TL
[Trujillo-Castrillón et al., 2018]	NHV	VT, LP, HB, TR, RE y NO	Log-Frequency Cepstral Coefficients-LFCCs	HMM
[Ursino et al., 2001]	HPN	Sismos tectónicos y explosión de excavación	Función de autocorrelación y espectro	ANN
[Yıldırım et al., 2011]	MRN	Sismos tectónicos y explosión de excavación	Atributos morfológicos de forma de onda	ANN

Algunas abreviaciones empleadas en la tabla, no definidas previamente, son las siguientes: NMC (*Nearest mean classifier* - clasificador de la media más cercano); LDC (*Bayes-normal-linear classifier* - clasificador bayesiano lineal); QDC (*Bayes-normal-quadratic classifier* - clasificador bayesiano cuadrático); RF (*Random forest* - bosques aleatorios); DNN (*Deep neural networks* - red neuronal profunda); LPC (*Linear predictive coding* - coeficiente de predicción lineal); PCA (*Principal component analysis* - análisis de componentes principales); DTW (Dynamic time warping); LG (*Ligthing* - clase de sismo Relámpago); LF (*low frequency* - eventos de baja frecuencia); HF (*high frequency* - eventos de alta frecuencia); CO (colapsos); TC (*Tectonic* - clase de sismo tectónico sin diferenciar entre local o regional); FL (*Flow lava* - flujo de lava); NO (*Noise* - ruido sísmico).

4.2.1. Análisis temporal de características

La forma más básica y directa de representar una señal en el tiempo es justamente el registro temporal de la misma; esto es, a través del muestreo digital de la señal análoga captada por los sensores y demás transductores. Tomar cada una de estas muestras como un patrón para ser procesado por un algoritmo de clasificación podría ser oportuno para una aplicación si hay suficientes ejemplos de entrenamiento, y además, flexibiliza el trabajo del diseñador al eximirle de encontrar características de muy alta calidad. Si bien lo anterior es conveniente, implicaría imperativamente contar con señales temporalmente alineadas y de igual longitud, escenario que es muy poco factible que se dé, pues cada registro sísmico —ya sea de origen tectónico o volcánico— es diferente a otro debido a su naturaleza (procesos intrínsecos propios), trayectoria, y por ende, duración.

Otro inconveniente que ocasiona el tratar con la señal sin procesar es la generación de espacios de características de muy alta dimensión, lo que suele desencadenar la llamada “Maldición de la dimensión” [Verleysen and François, 2005], originando errores o aciertos de predicción altamente variables. Y aunque este último asunto puede manejarse con técnicas como el análisis de componentes principales (PCA) u otros métodos de selección de características o de reducción de la dimensión, la cantidad limitada de patrones originales o transformados después de la selección puede no ser lo suficientemente representativa para el ejemplo y no aportar al proceso de clasificación.

Además de las muestras provenientes de la señal cruda, existe otro tipo de descriptores que pueden ser extraídos de la señal original en el tiempo, como aquellos que describen la morfología de la forma de onda. En este sentido, algunas metodologías propuestas han empleado cálculos que involucran la detección de las ondas P y S, como es el caso de [Rouland et al., 2009], donde se lleva a cabo la discriminación entre sismos tectónicos y tremor volcánico únicamente determinando la presencia o ausencia de la onda S; mientras que en [Yildirim et al., 2011], se usaron tales ondas para estimar características discriminantes, como por ejemplo la razón entre las amplitudes de las ondas P y S, y un valor de complejidad, definido como la integral del cuadrado de la velocidad del sismograma, con el fin de distinguir sismos tectónicos de explosiones de canteras. En la Figura 4-1 se aprecia la forma de onda de una señal sísmica de origen volcánico con algunos parámetros morfológicos marcados en ella, como los mencionados previamente:

En otros trabajos se obtienen características de las señales sísmicas a partir de parámetros calculados sobre la morfología de la señal: en el estudio realizado por Ibs-von Seht [2008], por ejemplo, se calculó la impulsividad y duración del evento sísmico, características de forma de onda muy comunes en la lectura de sismos. De igual manera, en [Curilem et al., 2009] se llevaron a cabo cálculos sobre la señal en el tiempo: valor máximo, curtosis, media, desviación estándar, media, mediana, entre otras características, las cuales fueron calculadas sobre el valor absoluto de la señal. Una versión suavizada de la señal, generada a partir de su envolvente, ha sido otra de las transformaciones usadas para construir una representación de datos sísmicos [Falsaperla et al., 1996; Langer and Falsaperla, 2003; Beyreuther et al., 2008]. Las funciones de autocorrelación [Falsaperla et al., 1996] y de amplitud [Scarpetta et al., 2005], también han sido empleadas como descriptores de la señal sísmica, generadas a partir de la forma de onda sin procesar.

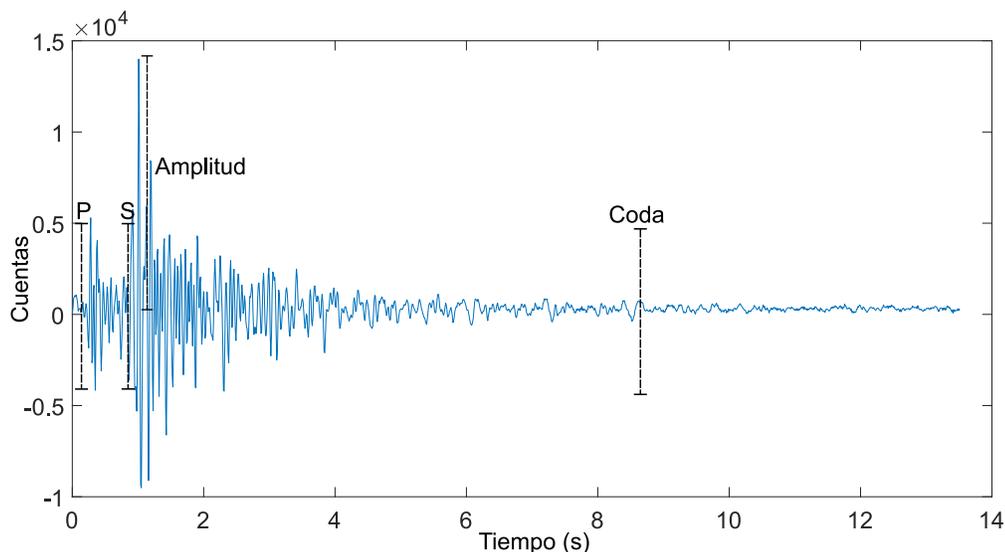


Figura 4-1.: Sismo volcánico de la clase VT con parámetros marcados.

En resumen y de manera generalizada, podría concluirse que la caracterización en el tiempo está dirigida básicamente para explotar la parametrización comúnmente explorada por los analistas expertos para la clasificación (manual en los observatorios) de eventos en volcanes, y tomar ventaja de la interpretación directa que proporciona al reflejar propiedades físicas de la forma de onda de la señal. Por otra parte, la revisión detallada de la literatura nos indica que, aunque en la actualidad se siguen empleando las representaciones en el tiempo, cada vez se hace con más mesura debido a sus limitaciones: un factor general de estas caracterizaciones es que son de bajo nivel y mantienen un orden (no se pueden permutar); y si éste se altera, podrían perder el sentido natural e intrínseco del objeto. Los algoritmos de aprendizaje típicos no responden bien a las representaciones ordenadas, y por ende, podrían presentar un impacto potencial en los resultados.

4.2.2. Análisis espectral

El análisis en el dominio de la frecuencia y simultáneamente en tiempo-frecuencia ha sido continuamente usado en la literatura para representar las señales sísmicas; de esta manera, se intenta mantener bajo control la alta variabilidad en su contenido frecuencial, y caracterizarlo para sacar provecho de las diferencias espectrales entre los distintos tipos de eventos sísmicos.

Diferentes técnicas se han aplicado para hacer la transformación de las señales de interés al dominio de la frecuencia, y a partir de éste extraer descriptores que logren aportar mayor discriminancia que los atributos calculados en el dominio del tiempo, poniendo a prueba que la concentración energética del espectro de la señal (y sus parámetros intrínsecos extraídos) pueden marcar mayor separabilidad en un espacio de características que los patrones morfológicos y momentos estadísticos de la señal —aunque en la mayoría de casos, resulta complementaria la caracterización en ambos dominios. La transformada de Fourier (definida abajo, en esta misma sección) es una técnica comúnmente usada en el estudio de señales para revelar la variación en amplitud de su contenido frecuencial.

Algunos cálculos simples sobre la densidad espectral se han usado como características, tales como la frecuencia dominante, rango de frecuencias del contorno espectral, frecuencia de la energía máxima del espectrograma [Ibs-von Seht, 2008], frecuencia media de ciertos picos del espectro, energía en determinada banda de frecuencia [Curilem et al., 2009], entre otras.

En otros trabajos como [Orozco-Alzate et al., 2006, 2008; Porro-Munoz et al., 2010a,b], se muestra cómo se puede hacer uso de la transformada de Fourier y efectuar una parametrización determinada sobre el espectro calculado, para obtener el mayor provecho posible de esta forma de representación. En [Orozco-Alzate et al., 2006], emplearon el cálculo del espectro de las señales, usando dos enfoques diferentes: aplicación de la transformada de Fourier y la densidad espectral de potencia, y a partir de estas dos estimaciones, se formó una matriz de disimilitudes usando la distancia euclidiana y la diferencia de áreas como métricas; finalmente, emplearon clasificadores básicos como la regla del vecino más cercano (k -NN) y otros basados en densidad de probabilidad, aplicados en el espacio de disimilitudes, para probar la capacidad de generalización aportada por la representación espectral (en principio) y posteriormente basada en disimilitudes.

Los espectrogramas (que también han sido ampliamente usados para caracterizar señales sísmicas) podrían considerarse como una representación intermedia en tiempo y frecuencia, que combina las bondades de los métodos temporales clásicos y los espectrales. Éstos resultan especialmente útiles a la hora de generar descriptores para los sismos de origen volcánico, dado que permiten hacer un análisis visual de las concentraciones energéticas de tales señales, que generalmente están bien definidas para las diferentes clases de sismos; lo cual permitiría generar parámetros o atributos altamente discriminantes, favorables durante la clasificación. Otro tipo de transformaciones espectrales tales como los coeficientes cepstrales en frecuencia de Mel [Benítez et al., 2006; Gutiérrez et al., 2006, 2009], los coeficientes de predicción lineal (*Linear predictive coding - LPC*) [Del Pezzo et al., 2003; Esposito et al., 2006, 2008; Ezin et al., 2002; Scarpetta et al., 2005], y la transformada Wavelet [Porro-Munoz et al., 2010b; Riggelsen et al., 2007; San-Martin et al., 2010] también han sido empleadas en el tratamiento de señales sísmicas; estas representaciones han sido inicialmente usadas con éxito en otros problemas reales, como el reconocimiento de voz, y extendida su aplicación a señales sísmicas por su semejanza entre ambas señales de ondas mecánicas.

Transformada de Fourier

La transformada de Fourier (*Fourier transform - FT*) es una herramienta matemática básica en el tratamiento y análisis de señales en el dominio de la frecuencia. Esta transformada opera idealmente en señales estacionarias, dado que está compuesta por una combinación de funciones sinusoidales como función base; sin embargo, como difícilmente se hallan señales de este tipo en el mundo real, la naturaleza no estacionaria de señales como las sísmica puede ser tratada con este método espectral manteniendo controladas ciertas consideraciones matemáticas para no generar resultados o interpretaciones erróneas. De manera que una señal $x(t)$ proyectada sobre una función base

exponencial compleja, con una frecuencia $\omega = 2\pi f$, define la transformada de Fourier ¹, que se expresa matemáticamente de la siguiente manera:

$$X(j\omega) = \int_{-\infty}^{+\infty} x(t) e^{-j\omega t} dt \quad (4-2)$$

De manera análoga, la reconstrucción de $x(t)$, expresada como una combinación ponderada de la función exponencial compleja, corresponde a la transformada inversa de Fourier, y está definida como:

$$x(t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} X(j\omega) e^{j\omega t} d\omega \quad (4-3)$$

Ahora bien, teniendo clara la transformación de señales continuas a discretas tras la adquisición de registros por dispositivos digitales, conviene definir las anteriores expresiones acorde a dicha condición. Así pues, dada una secuencia $x[n]$, la transformada de Fourier en tiempo discreto (*Discrete Fourier Transform - DFT*) está dada de la forma:

$$X(j\omega) = \sum_{n=-\infty}^{+\infty} x[n] e^{-j\omega n} \quad (4-4)$$

Teniendo presente que la secuencia $x[n]$ puede ser representada mediante una suma ponderada de infinitas exponenciales complejas infinitesimales, los coeficientes de la señal discreta se pueden calcular usando la integral de Fourier limitada entre $[-\pi, +\pi]$, definiendo así su transformada inversa, como sigue:

$$x[n] = \frac{1}{2\pi} \int_{-\pi}^{\pi} X(j\omega) e^{j\omega n} d\omega \quad (4-5)$$

En adelante, eventualmente, se menciona la transformada rápida de Fourier (*Fast Fourier Transform*), más conocida por su abreviatura FFT, que corresponde a un algoritmo creado en la década de los 60's para calcular de manera eficiente la DFT y su inversa. La FFT tiene una amplia cantidad de aplicaciones, especialmente en el área del tratamiento de señales y la resolución de ecuaciones diferenciales, por lo que es el algoritmo de preferencia para cálculos espectrales como los realizados en este trabajo.

¹Detalles teóricos de la transformada de Fourier pueden encontrarse en [Oppenheim et al., 1998].

Espectrograma

El espectrograma es la representación gráfica de las concentraciones energéticas del espectro de una señal, mediante el cual se puede hacer un análisis tiempo-frecuencia de la misma. Generalmente, la gráfica tridimensional del espectrograma se visualiza, bien sea como una superficie, o como un plano donde el tiempo ocupa el eje horizontal, la frecuencia el eje vertical y la amplitud se representa en escala de grises o de colores acompañada de un mapa de colores que indica los valores de la amplitud. En la Figura 4-2 se muestra el ejemplo de un espectrograma de una señal sísmica tipo VT, en la que se puede detallar lo explicado previamente.

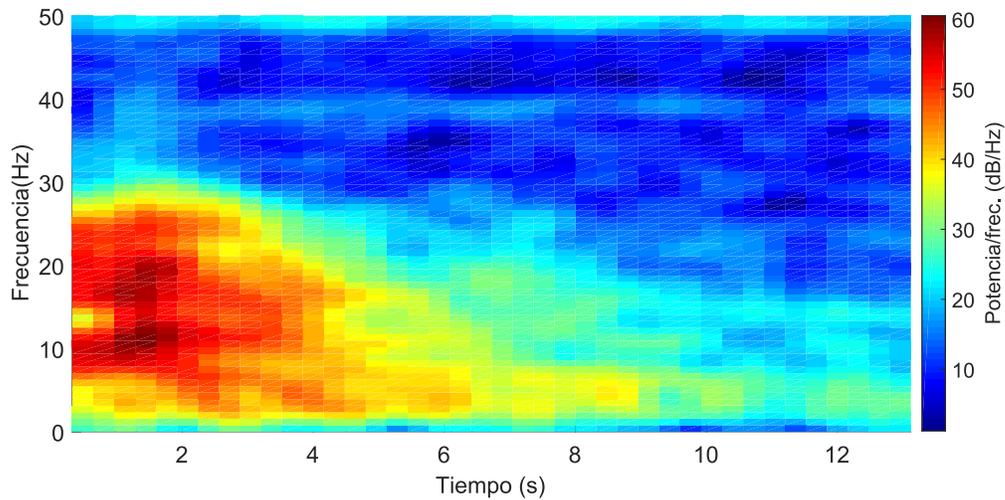


Figura 4-2.: Ejemplo de espectrograma de un sismo volcánico perteneciente a la clase VT.

La definición del espectrograma se lleva a cabo mediante el cálculo de la transformada de Fourier de tiempo corto (*'short-time Fourier transform - STFT'*). Básicamente ésta consiste en deslizar una ventana de determinada longitud sobre la señal, manteniendo cierto traslape entre una ventana y la siguiente (proceso llamado *'ventaneo'*), para luego calcular la transformada discreta de Fourier sobre cada una de ellas. De esta manera es posible realizar un análisis tiempo-frecuencia sobre la señal $x(t)$, dado que la localización de la ventana desplazada da lugar a la dimensión temporal. El cálculo de la STFT de una señal se efectúa mediante la ecuación 4-6:

$$X[k, l] = \sum_{n=0}^{N-1} x[n + lL] \cdot w[n] \cdot e^{-\frac{j2\pi kn}{K}} \quad (4-6)$$

donde k corresponde al índice de la frecuencia y l al índice del tiempo dentro del segmento de señal ventaneado; N es el tamaño de la ventana; n es el índice correspondiente al instante donde inicia la ventana desplazada; y $w[n]$ es la función de ventana de tiempo.

La construcción del espectrograma se lleva a cabo dividiendo la señal en segmentos pequeños (que llamaremos *'frames'*) y que tendrán determinado traslape; dichos *frames* tendrán características

espectrales que se mantendrán casi constantes, es decir, se asume estacionariedad en cada segmento. Estos *frames* son multiplicados por una función ventana cuya forma puede variar entre simétrica, unimodal, gaussiana, entre otras; su longitud será determinante en la resolución del tiempo y de la frecuencia en la gráfica del espectrograma, y además definirá el cumplimiento de la condición de estacionariedad en cada segmento de señal. Por tal motivo, la longitud de la ventana es un parámetro que debe ser seleccionado con especial cuidado. En conclusión, la representación tiempo-frecuencia mediante el espectrograma $SP[k, l]$ de una señal x , se define como la magnitud al cuadrado de la STFT de la señal, y está dada por la siguiente ecuación:

$$SP[k, l] = \frac{1}{N} |X[k, l]|^2 \quad (4-7)$$

Coefficientes cepstrales en frecuencia de Mel

Los coeficientes cepstrales en frecuencia de Mel (*'Mel Frequency Cepstral Coefficients'* - MFCCs) son una representación de las señales del habla basada en el proceso de la percepción auditiva humana. Estos surgen en la década de los 80's [Davis and Mermelstein, 1980] como consecuencia de la necesidad de caracterizar los componentes de una señal audible en el área de reconocimiento automático del habla; desde entonces se han mantenido vigentes en el estado del arte de su área de estudio. A diferencia de la parametrización en las señales de audio (que ha sido extensamente estudiada y bien definida), en las señales sísmicas de origen volcánico, el problema de extracción de características y representación aún es ampliamente discutido; razón por la cual se aprovechó la analogía entre las señales sísmicas y las de habla, haciendo extensivos algunos de sus métodos de caracterización.

La estrecha correlación que existe entre las señales sísmicas y las del habla no es casual; analizando y comparando la fisiología para la producción del habla y el proceso físico para la generación de sismos volcánicos (en particular, aquellos relacionados a la dinámica de fluidos: LP, TR, LF) se logra identificar ciertas similitudes. En ambos casos, el mecanismo de excitación que confluye en la producción de los dos tipos de señales, se puede generalizar como de turbulencia o inestabilidad en un proceso de flujo de fluidos, que causa un importante efecto tanto en la modulación de la voz como en la generación de un sismo. De esta manera, se propagan resonancias en el tracto bucal —en el caso de las señales de habla— y en conductos, cavidades y/o grietas, en el caso de las señales sísmicas. De esta manera se da por justificado el uso de los MFCCs como una alternativa de representación de los sismos volcánicos.

En términos generales, los MFCCs hacen una representación de elementos en el dominio de la frecuencia, empleando una escala de nuestra fonética humana, para reducir una señal a valores absolutos interpretativos. Tal como se muestra en la Figura 4-3, la extracción de los MFCCs inicia con la fragmentación de la señal en recuadros o *frames*, y se establece una proporción de traslape de tal manera que se logre una buena correlación entre los frames y no ocurra pérdida sustancial de información. Dado que la segmentación de la señal produce efectos de alta frecuencia al principio

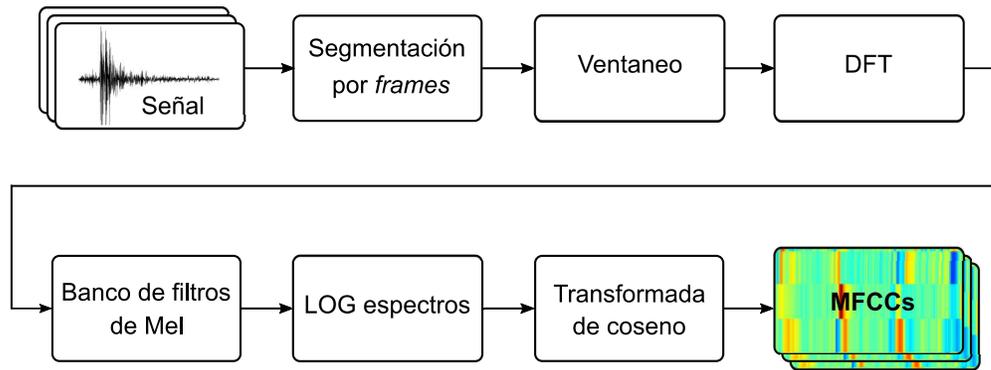


Figura 4-3.: Esquema del proceso de generación de los MFCCs

y al final de cada *frame* (por variaciones súbitas de amplitud de la señal a cero y viceversa), se requiere la implementación de un ventaneo que contrarreste los efectos de borde, y por lo general, se usa la ventana de Hamming para tal fin. Posteriormente, se calcula el espectro de la señal mediante la DFT, para luego transformarlo a la escala Mel haciendo uso de un banco de filtros (generalmente triangulares).

Hasta este punto del proceso, ya se ha logrado obtener una medida de la concentración de energía de la señal en una banda de frecuencias determinada (denominada '*cepstrum*'). Ahora, tras la aplicación del banco de filtros, se generan unos coeficientes que se encuentran altamente correlacionados, por lo cual se debe aplicar una transformación de de-correlación mediante la transformada discreta de coseno; operación que se aplica al logaritmo de los espectros (el LOG proporciona una información más comprimida y representativa de la energía de Mel). Habitualmente, en aplicaciones de procesamiento de señales, se toman los 13 primeros coeficientes Mel calculados, y ocasionalmente, para obtener características dinámicas de la señal, se añade el mismo número de coeficientes calculando la velocidad, y de igual forma para la aceleración.

Linear Predictive Coding (LPC)

Al igual que los MFCCs, el procesamiento llamado Codificación Predictiva Lineal, mejor conocido por su abreviación en inglés LPC (*Linear Predictive Coding*), proviene de un requerimiento dado en el área de procesamiento de voz como un modelo de compresión, propuesto desde 1984 por el Departamento de Defensa de los Estados Unidos [O'Shaughnessy, 1988]. Acá nuevamente se parte de la similitud entre las señales de voz y las sísmicas para extender sus métodos de extracción de características entre uno y otro tipo de señal. En sismología y geofísica, este método se ha denominado "Análisis Espectral de Máxima Entropía" (*Maximum Entropy Spectral Analysis - MASA*), y básicamente consiste en modelar cada evento o predecir segmentos de una señal a partir de la com-

binación lineal de valores o muestras del pasado. Este modelado se puede definir matemáticamente de la forma:

$$x^*(n) = \sum_{k=1}^d c_k x(n-k) + G \quad (4-8)$$

donde $x^*(n)$ corresponde a la predicción de la muestra n de la señal x ; G es la ganancia; y c_k son los coeficientes de predicción, obtenidos mediante un proceso de optimización que minimiza la función de error entre la estimación LPC y la señal real en el tiempo n . El valor d representa el orden del modelo, y por tanto, el número de coeficientes de predicción a calcular. La definición del orden d deriva en un problema de optimización basado en la evaluación de una función de desajuste dado por la siguiente ecuación:

$$E(\mathbf{c}) = \sum_n (x(n) - x^*(n))^2 \quad (4-9)$$

donde \mathbf{c} es el vector que contiene los coeficientes del predictor. La minimización de la función $E(\mathbf{c})$ se lleva a cabo actualizando los d coeficientes de manera iterativa; de manera que, evaluando el error residual como una función del número de d coeficientes, entonces el número óptimo de coeficientes predictivos se estima definiendo un compromiso entre la cantidad de información a conservar y la compacidad de representación deseada, entendiéndose que los coeficientes LPC corresponden a las características que representan el espectro de una señal de manera muy compacta.

4.2.3. Transformada wavelet y análisis multiresolución

La transformada wavelet ² es una transformación que interacciona simultáneamente en dos dominios: el tiempo, y el dominio de la escala, que está estrechamente relacionada con la frecuencia (es inversamente proporcional a una frecuencia, la cual depende de la función wavelet empleada); por tal motivo, es adecuada para el análisis de señales donde se requiere resolución tiempo-frecuencia. En décadas recientes, el uso de esta transformada se ha expandido para tratamiento de problemas como la compresión de grandes volúmenes de información, el análisis de imágenes, procesamiento y eliminación de ruido en diferentes tipo de señales, reconocimiento de patrones, entre otros. Centrándonos en el área de procesamiento de señales, en términos generales, la transformada wavelet permite analizar detalles intrínsecos de una señal al descomponerla mediante el uso de versiones desplazadas y escalonadas (dilatadas) de una 'wavelet' determinada; en otras palabras, podría decirse que la transformada wavelet actúa como un filtro pasa banda que permite el paso de componentes de la señal a ciertas frecuencias.

²Ver detalles teóricos de la transformada de wavelet en [Debnath, 2003].

Las *wavelets* son formas de onda (señales) localizadas, de duración limitada, con valor promedio cero, y que decaen rápidamente a cero después de unas pocas oscilaciones. La aplicación de esta transformada implica, en principio, la selección de una '*wavelet*' idónea, que se conoce como '*wavelet madre*', ya que será la que sufra modificaciones de expansión/compresión y desplazamientos a lo largo de la señal analizada. La elección de la wavelet madre dependerá tanto de la señal que se está analizando, como del tipo de información que se desea obtener; su selección podrá hacerse en base a su similitud con las formas de onda de la señal en cuestión, o por método de prueba-error empleando diferentes tipos de wavelets. Matemáticamente, las wavelets se pueden definir como funciones generadas a partir de variaciones en los parámetros de escalamiento (a) y desplazamiento (b) de una función wavelet inicial, tal como se define en la siguiente ecuación:

$$\varphi_{a,b}(t) = \frac{1}{\sqrt{a}} \cdot \varphi\left(\frac{t-b}{a}\right) \quad (4-10)$$

A partir de lo anterior, se puede entonces definir la transformada wavelet continua (CWT) como la suma (en todo tiempo t) de la señal $x(t)$ multiplicada por la versión dilatada y desplazada de la wavelet original, y está dada de la forma:

$$C(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \cdot \varphi\left(\frac{t-b}{a}\right) dt \quad (4-11)$$

Dado que la mayoría de aplicaciones de la transformada wavelet se da en forma digital, conviene definir la transformada wavelet discreta (DWT). La CWT genera ciertas redundancias dado que la reconstrucción de una señal se puede dar a partir de un número limitado de escalas, como por ejemplo, potencias enteras de 2; por lo que se reemplazan los parámetros de escala y desplazamiento por: $a = 2^{-i}$ y $b = 2^{-i}k$ para cada $i, k \in \mathbb{Z}$, de manera que la DWT se puede definir como sigue:

$$D_{i,k}(n) = 2^{i/2} \sum_{k=-\infty}^{\infty} x(k) \cdot \varphi(2^i n - k) \quad (4-12)$$

Los parámetros de escalamiento y desplazamiento posibilitan la obtención de los coeficientes wavelet (de 'detalle' y de 'aproximación'), dando lugar a componentes de la señal en determinadas frecuencias. Los coeficientes wavelet extraídos ofrecen una representación compacta que muestra la distribución energética de la señal en tiempo y frecuencia.

El análisis multiresolución (MRA) es el eje central de la teoría de las wavelets, pues permite que una función pueda derivarse en varios niveles de aproximaciones o "resoluciones", que son combinaciones lineales de dilataciones y desplazamientos de una función de escalamiento; esto permitiría detectar patrones no visibles en datos sin procesar y resaltar atributos que podrían ser determinantes. A

través de la aplicación del MRA, se puede dividir una función complicada en varias más simples para poderlas estudiar de manera separada. La idea básica del MRA consiste en proyectar una función $f \in L^2(\mathbb{R})$ sobre una secuencia de subespacios cerrados $\{V_j : j \in \mathbb{Z}\}$ que se obtienen mediante la función de escalamiento $\phi(t)$ definida como: $\phi_{i,k}(t) = 2^{-i/2} \phi(2^{-i}t - k)$, la cual cumple que $\int_{\mathbb{R}} \phi_{0,0}(t) dt = 1$.

4.3. Extracción de medidas de representación

La no estacionariedad de las señales sísmicas y sus transitorios, desencadenan amplitudes y frecuencias altamente variantes, que evolucionan a lo largo del tiempo; lo que hace necesario extraer características a partir de varias representaciones con el propósito de encontrar un conjunto de descriptores que aporte alta discriminancia entre las distintas clases de señales sísmicas. En este trabajo se estudió un nutrido grupo de características que se encuentran mapeadas en diferentes dominios (tiempo, frecuencia, tiempo-frecuencia, cepstrales, Mel, etc.), las cuales fueron recopiladas a partir de múltiples investigaciones orientadas a la representación de eventos sismo-volcánicos. Recordemos que el principal propósito de esta tesis no es la proposición de nuevas representaciones sino la definición de las más adecuadas para garantizar una base no sesgada en las etapas posteriores de clasificación y evaluación, donde se centran los aportes de este trabajo.

En el siguiente apartado, se definen matemáticamente los atributos calculados para cada evento; estos parámetros corresponden a un compendio de formas de representación tomadas de los siguientes trabajos: [Álvarez et al., 2009; Avesani et al., 2012; Curilem et al., 2009; Del Pezzo et al., 2003; Ibs-von Seht, 2008; Hibert et al., 2017; Malfante et al., 2018], de los cuales se ha tomado la mayoría de atributos, obviando aquellos que son redundantes porque están repetidos en dos o más trabajos o porque proveen información similar con otro descriptor ya incluido. Tales caracterizaciones se disponen a continuación, organizadas de acuerdo al dominio de sus representaciones aplicadas, ya sea en el tiempo, frecuencia o tiempo-frecuencia. Se incluyen en el dominio frecuencial los dominios cepstral (MFCCs) y de escala (wavelet) que, aunque no son una transformación a la frecuencia propiamente dicha, la FFT hace parte de su proceso de transformación, o conservan una relación inversa con la frecuencia, como en el caso de las wavelet.

Características en el dominio del tiempo

En este grupo de características se encuentran incluidos los atributos estadísticos, que brindan una interpretación inmediata con respecto a la forma de onda de la señal y al comportamiento de los datos. También hacen parte de este conjunto, aquellos descriptores relacionados a la morfología de las señales, que pueden facilitar una interpretación física de las mismas, y relacionarlas de manera más directa a determinada clase.

- *Media aritmética o promedio*

Es el cociente entre la sumatoria de los datos a considerar y la cantidad total de los mismos,

y se define como muestra la ecuación 4-13:

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i \quad (4-13)$$

– **Desviación estándar**

Es una medida de dispersión de una distribución o conjunto de datos. Matemáticamente se expresa según la ecuación 4-14, considerando el conjunto de datos \mathbf{x} :

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{i=1}^n |x_i - \mu|} \quad (4-14)$$

– **Mediana**

La mediana estadística corresponde al número intermedio (o al promedio de los dos del medio, en caso de haber número par de datos) de una sucesión de valores, después de haber sido ordenados de manera ascendente. La mediana Me se puede calcular mediante la siguiente expresión matemática, considerando que su resultado indicará la posición i del valor de la mediana dentro de la sucesión de datos observados:

$$Me = x_{i_{Me}} \quad \text{donde } i_{Me} = \frac{n+1}{2} \quad \text{y } 0 \leq i \leq n \quad (4-15)$$

– **Valor máximo**

Se determina el valor máximo de la señal como atributo a considerar, dado que podría coincidir con el punto máximo de la onda P de señal sísmica s , que en magnitud y duración podría ser característico para determinados tipos de sismos. Matemáticamente, podemos expresarlo como sigue:

$$s_{i_{max}} = \max \{s\} \quad (4-16)$$

– **Curtosis**

La curtosis es una medida estadística que estima la concentración de datos alrededor del punto central de una distribución de frecuencias. Dicha densidad indica la presencia marcada o no de *outliers* (datos atípicos) dependiendo de la suave o acentuada terminación de las 'colas' de la distribución en comparación con la normal. Matemáticamente, la curtosis se expresa como la razón entre el cuarto momento y el cuadrado del segundo momento de la distribución, de la siguiente manera (donde m representa el primer momento estadístico):

$$C_x = \frac{m_4}{m_2^2} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^4}{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2\right)^2} \quad (4-17)$$

– **Asimetría estadística**

El coeficiente de asimetría (también conocido como '*skewness*') mide justamente el grado de

asimetría de los datos alrededor de la media. Si la asimetría es negativa, los datos se dispersan más hacia la izquierda de la media; si la asimetría es positiva, los datos se dispersan más hacia la derecha. La asimetría de la distribución normal (o cualquier distribución perfectamente simétrica) es cero. Matemáticamente, la asimetría puede definirse como:

$$SK_x = \frac{E(x - \mu)^3}{\sigma^3} \quad (4-18)$$

– ***Duración del evento***

Este atributo indica el tiempo de duración del evento sísmico, el cual se puede identificar conociendo el tiempo de inicio y fin del evento propiamente dicho, segmentado de su traza sísmica: $Dur_x = t_{fin} - t_{ini}$; o puede calcularse usando la cantidad de muestras de la señal (n) y su frecuencia de muestreo (f_s), como sigue:

$$Dur_x = \frac{n}{f_s} \quad (4-19)$$

– ***Duración de ventana de activación***

Ésta corresponde a una propiedad inherente de las señales sísmicas, y hace referencia a la duración de una ventana denominada “de activación” que parte desde el inicio de la señal hasta un punto i de la misma. De acuerdo a lo sugerido en [Ibs-von Seht, 2008], el fin de la ventana se asumió como:

$$Dur_{ven} = P_x + n_d \quad (4-20)$$

Esto es, n_d segundos (muestras) después de haber determinado la onda P de señal sísmica (P_x), la cual se definió haciendo uso del conocido algoritmo STA/LTA (ver pseudo-código en Anexo A) y validada con los parámetros medidos sobre la forma de onda, que son marcados por el observatorio vulcanológico de donde proviene la señal.

– ***Impulsividad***

Al igual que la anterior, esta característica es propia y muy peculiar en los sismos, e indica la rapidez con la que aumenta la amplitud de la forma de onda hasta alcanzar su valor máximo. La impulsividad se puede calcular como:

$$Imp_x = \frac{i_c}{n_d} \quad (4-21)$$

donde i_c es el índice para el cual se cumple que $\sigma(i_c) > \sigma(n_d) * 0,2$, siendo n_d el número total de muestras incluidas en la ventana de activación (Dur_x), y en donde $\sigma = \sum_{i=1}^{n_d} \text{abs}(x_i)$.

– ***LPCs***

Se incluyen los coeficientes de predicción lineal dentro del conjunto de características que se ha creado para este trabajo, calculándolos de acuerdo a los lineamientos matemáticos expuestos en la Sección 4.2.2. La cantidad de coeficientes d elegidos, se determinó aplicando la ecuación

4-9, y se convalidó con el rango de coeficientes sugerido en [Del Pezzo et al., 2003], por lo que se definió $d = 5$.

Características frecuenciales

Este grupo o familia de atributos compone una representación en el dominio de la frecuencia, lograda a partir de una transformación mediante la FFT, que muestra concentraciones de energía en determinadas bandas espectrales, y que revela frecuencias fundamentales que puedan ser propias de ciertas clases de sismos.

– *Frecuencia media*

Se determinan las frecuencias medias de los cinco picos más altos del espectro de magnitud, tras aplicar la FFT a la señal, y se normaliza con el valor de su energía. Este cálculo dará como resultado una cantidad representativa referente al contenido de frecuencia de la señal. Este descriptor se puede definir de la siguiente manera:

$$FrMd = \frac{\sum_{i=1}^5 P(i)}{5 * \sum_{j=1}^n Z(j)} \quad (4-22)$$

De la anterior expresión, $P(i)$ corresponde al vector de las frecuencias a las cuales corresponden los valores máximos del espectro de magnitud (Z) de la señal, ordenados de manera descendente.

– *Frecuencia dominante*

Esta característica corresponde al valor de la frecuencia del mayor pico del espectro de magnitud, obtenido después de aplicar la FFT a la señal (como se muestra en la ecuación 4-23). En algunos trabajos previos, este atributo lo calculan mediante el conteo de cruces por cero de la señal en el tiempo [Ibs-von Seht, 2008].

$$FrDm = \text{máx}(Z) \quad (4-23)$$

– *Energía en sub-bandas wavelet*

Se calcula la energía en cada una de las sub-bandas de frecuencias originadas tras la descomposición wavelet, aplicada de acuerdo a las formulaciones matemáticas expuestas en la Sección 4.2.3. Conforme a lo sugerido en [Curilem et al., 2009], se ha seleccionado una descomposición wavelet por debajo de 1.56Hz, dado que a esta frecuencia se da una mejor diferenciación entre sismos LP y TR. Por tal motivo, se lleva a cabo una descomposición wavelet a 7 niveles, cuyas sub-bandas de frecuencias asociadas son las siguientes:

– *MFCCs*

Se incluyen los MFCCs como atributos en esta familia de características, haciendo su cálculo conforme al proceso señalado en el diagrama 4-3 y a lo sugerido en [Álvarez et al., 2009]. En el tercer bloque del esquema mencionado, se ha generado un ventaneo con traslape de 4s y

Tabla 4-2.: Sub-bandas de frecuencias de acuerdo a niveles wavelet

Nivel wavelet	Frec. inf. [Hz]	Frec. sup. [Hz]
1	25.00	50.00
2	12.50	25.00
3	6.25	12.50
4	3.13	6.25
5	1.56	3.13
6	0.78	1.56
7	0.39	0.78

un desplazamiento de 0,5s. La DFT se ha implementado con 512 puntos y se ha empleado un banco de 16 filtros triangulares, espaciados entre 0 y 25Hz, con un traslape entre ellos del 50%, obteniéndose un vector de 16 parámetros. Tras la de-correlación inducida por la transformada de coseno, se obtiene un total de 13 coeficientes por cada señal.

Características en tiempo-frecuencia

La tercera familia de descriptores se ha generado a partir del espectrograma de las señales, de tal manera que se pudiera contar con una representación de la evolución del contenido de frecuencia de la señal sísmica en el tiempo. Los espectrogramas fueron calculados de acuerdo a lo definido en la Sección 4.2.2, utilizando una FFT de 128 puntos, con segmentos ventaneados por ventanas de Hamming, con un traslape del 50%. La magnitud en decibeles es calculada como $20 \cdot \log_{10} |X|$, donde X corresponde a la matriz que contiene la FFT de la señal x .

– *Energía media en sub-bandas*

Conforme a lo sugerido por [Avesani et al. \[2012\]](#), una vez generado el espectrograma, se lleva a cabo una reducción de dimensión de la matriz originada calculando la media de la energía en cada una de la bandas de frecuencia a través del tiempo evaluado; este cálculo muestra en qué banda de frecuencia hay mayor concentración de energía a lo largo de toda la señal, como se indica en la ecuación 4-24:

$$Med_{BF}[k] = \frac{\sum_{l=1}^{n_{sp}} SK[k, l]}{n_{sp}} \quad (4-24)$$

donde SK es la matriz representada por el espectrograma (de acuerdo a la ecuación 4-7) y n_{sp} son los puntos de la escala de tiempo generada en el espectrograma. Este cálculo se realiza para k sub-bandas de frecuencias definidas en SK .

– *Frecuencia del contorno espectral*

Sobre la matriz SK del espectrograma, se genera un contorno espectral sobre el área de mayor concentración de energía, y se determina el rango de las frecuencias a las cuales corresponde

dicha contorno mediante la diferencia entre sus puntos máximo y el mínimo:

$$C_{SK} = \text{Contorno}(SK) \quad R_f = \text{máx}(C_{SK}) - \text{mín}(C_{SK}) \quad (4-25)$$

– ***Frecuencia del centroide***

Partiendo de lo descrito en el atributo anterior, se halla el centroide (centro de gravedad) del área que fue rodeada por el contorno, y se determina la frecuencia correspondiente de dicho punto en la matriz SK .

$$CT = \text{centroide}(C_{SK}) \quad (4-26)$$

– ***Frecuencia de la máxima energía***

Se halla el máximo de la magnitud de la energía representada por SK , y se define la frecuencia a la que corresponde tal valor.

4.4. Marco experimental

Como se ha mencionado previamente, definir una parametrización adecuada es crucial para garantizar un apropiado aprendizaje de máquina y que los resultados durante la etapa de clasificación sean lo más precisos posible. En este orden de ideas, se desea identificar experimentalmente las características que proporcionen una representación adecuada de las señales sísmicas de origen volcánico y la más conveniente posible para las subsecuentes etapas de clasificación y evaluación de un sistema de aprendizaje adaptativo.

Se lleva a cabo la comparación de cuatro grupos de caracterizaciones para identificar aquel de mayor poder discriminante sobre las señales sísmico-volcánicas. Con el fin de establecer con facilidad la procedencia del atributo propuesto, tales agrupaciones de características se definieron a partir del trabajo investigativo en el cual fueron planteadas.

Definición de las representaciones

El primer conjunto de características es el presentado por [Curilem et al. \[2009\]](#), donde se proponen las siguientes ocho características³: 1) desviación estándar, 2) media, 3) mediana y 4) valor máximo; estas cuatro características se calculan a partir del valor absoluto de la señal. Las siguientes dos características, 5) kurtosis y 6) 'skewness', describen la agudeza y la forma de cada registro; estas dos medidas se obtienen de un histograma construido con 200 bins. Las dos características restantes se basan en el contenido espectral. La séptima característica da un valor representativo del contenido de frecuencia de la señal y corresponde a 7) la frecuencia media de los cinco picos más altos en su transformada de Fourier. La última característica es 8) la energía en sub-bandas de frecuencia, calculada a partir de los coeficientes de aproximación y detalle obtenidos por una descomposición

³El detalle del cálculo de las características mencionadas, se encuentra en la Sección 4.3

wavelet discreta ejecutada en 7 niveles de frecuencia. La wavelet madre escogida para ejecutar la descomposición wavelet fue la *Daubechies 7* debido a su similitud con la forma de onda de la señal sismo-volcánica. Finalmente, el vector de características obtenido se normaliza al intervalo $[-1, 1]$.

El segundo conjunto de características fue propuesto originalmente por [Ibs-von Seht \[2008\]](#), el cual básicamente describe las propiedades de la forma de onda y del espectrograma de los eventos sísmicos, leyendo magnitudes en el dominio del tiempo y caracterizando la señal en el dominio de la frecuencia por medio de patrones definidos visualmente a partir de su correspondiente espectrograma. Las características de este conjunto son: 1) la duración del evento después de la segmentación de la señal sin procesar, 2) la impulsividad de la señal (ambas calculadas sobre la señal en el tiempo), y 3) la frecuencia dominante del evento sísmico (definida a partir de la FFT de la señal). Las siguientes tres características se calculan a partir del espectrograma: 4) La diferencia entre las frecuencias mayor y menor del contorno espectral, 5) la frecuencia correspondiente al centroide del contorno espectral, y 6) la frecuencia del máximo de energía en el espectrograma. Los vectores de características están estandarizados (usando *z-score*) para garantizar una influencia uniforme de los mismos durante la clasificación.

Una tercera representación para registros sísmicos se basa en el enfoque propuesto por [Alvarez et al. \[2012\]](#), en el que utilizan los MFCCs como forma de representación. Ese trabajo contempla las contribuciones realizadas por los autores en publicaciones anteriores, donde se probaron diferentes configuraciones experimentales de los MFCCs. El tercer conjunto de características consta de un vector base de 13 coeficientes (12 coeficientes cepstrales, más la energía logarítmica de la señal), unido a sus derivadas temporales de primer orden, para obtener un total de 26 características. Para llevar a cabo el cálculo de los MFCCs, se empleó un ventaneo de 4s, con una ventana de desplazamiento de 0,5s; un banco de 16 filtros triangulares, espaciados uniformemente en la escala de Mel entre 0 y 25Hz, con traslape del 50% son los principales parámetros de estimación de los MFCCs utilizados.

El cuarto conjunto de características hace una representación tiempo-frecuencia de las señales de estudio, calculando la energía media por bandas de frecuencias sobre el espectrograma de cada registro (estimación basada en lo propuesto por [Avesani et al. \[2012\]](#)). Para ello, se lleva a cabo el cálculo del espectrograma de cada señal mediante la FFT, y un ventaneo con un traslape definido; luego, se calcula un promedio del espectrograma por bandas de frecuencia. Para este marco experimental, los parámetros empleados para la generación de los espectrogramas fueron: una FFT de 128 puntos, una ventana de Hamming de 64 puntos y un traslape del 50%. De esta manera se logra un vector de 65 características.

Datos empleados

Los experimentos llevados a cabo en este capítulo fueron ejecutados sobre las dos bases de datos dispuestas para esta tesis, descritas detalladamente en la Sección 3.3. El primer conjunto de datos proviene de la base de datos del VNR. Aún cuando el catálogo general pone a disposición cerca de 2900 registros categorizados en 13 clases, para este estudio se utilizaron únicamente señales

sísmicas de las cinco clases más representativas que caracterizan la actividad del VNR; además, se determina descartar las demás clases de sismos por ser de tipo no volcánico y por contar con una cantidad de ejemplos estadísticamente poco significativa. Las clases de sismos tenidas en cuenta y su correspondiente cantidad de ejemplos fueron las siguientes: VT (con 153 eventos), LP (con 333 eventos), TR (con 242 eventos), TO (con 104 eventos) y HB (con 393 eventos). De esta manera, se conforma un conjunto de datos de 1225 registros segmentados, con duraciones entre 5,5 y 2442s, que corresponden a la actividad volcánica de enero de 2010 a septiembre de 2013.

El segundo conjunto de datos se deriva del catálogo de registros del volcán Villarrica (obtenidos entre enero de 2010 y abril de 2017, como se precisa en la Sección 3.3). Debido al alto costo computacional que comúnmente demandan los algoritmos de selección de características (aplicados en estos experimentos), no se empleó la cantidad total de registro dispuestos en el catálogo del volcán (que pasó de 350426 a 260365 registros, tras el pre-procesamiento de la base de datos). Se creó un conjunto de datos de únicamente 20000 registros, distribuidos en las tres clases volcánicas que predominan en el Villarrica, de la siguiente manera: LP (con 7217 eventos), TR (con 12723 eventos), y VT (con 189 eventos). Como puede observarse, es evidente el desbalance de clases del presente problema de clasificación; sin embargo, se optó por no aplicar ningún método de balanceo en aras de una posible optimización del rendimiento predictivo del clasificador, dado que, en general, éstos son aproximaciones de sub-muestreo o sobre-muestreo [Batista et al., 2004]. Lo anterior, se da en vista de que los registros sísmicos en el volcán Villarrica se presentan de manera natural en dichas proporciones (predominantemente, eventos de baja frecuencia), adicional al hecho que una premisa de este trabajo es la configuración de condiciones “lo más realistas posibles”. Por tal motivo, no se consideró alterar y equilibrar convenientemente el número de registros por clase, y en cambio, nos inclinamos por explorar el desempeño de los algoritmos de aprendizaje con proporciones de clases reales, proyectándonos a futuras puestas en marcha *on-line* de dichos algoritmos.

Detalles experimentales

Una vez se ha completado la etapa de la representación, se ha obtenido un vector de 105 características por cada uno de los ejemplos considerados. De acuerdo a la teoría de ML, cuando se crea un espacio de características de una alta dimensión, es posible que varios de sus elementos pueden resultar redundantes o incluso irrelevantes para el proceso de clasificación. Para tales casos, se sugiere *adaptar* la representación aplicando técnicas de reducción de dimensión para encontrar las características más discriminantes, así como para evitar la *maldición de la dimensión*. Por lo tanto, los algoritmos de selección de características resultan muy útiles para determinar el mejor subconjunto de características en términos de algún criterio de representación o clasificación, con el cual se cree un espacio vectorial más compacto en el que un determinado clasificador pueda actuar de manera más selectiva. Conforme a lo precisado en el Capítulo 5 de [Castro Cabrera, 2011], existen diferentes estrategias que logran la reducción de dimensión; no obstante, más que comparar la efectividad de varios de estos métodos, se desea obtener un subconjunto estable de atributos que brinden discriminancia durante la clasificación, por lo que se opta por un solo método de búsqueda exhaustiva, que aunque es computacionalmente costoso, pone a prueba todas las posibles combi-

naciones de subconjuntos de características hasta encontrar el más discriminante. En este orden de ideas, en este marco experimental se empleó el algoritmo de *Búsqueda hacia Adelante (SFS)*, el cual utiliza el error de validación cruzada de *leave-one-out* como criterio de evaluación.

La mayoría de los clasificadores deben ser entrenados para hacer ajuste de parámetros y maximizar su rendimiento; sin embargo, dado que nuestro objetivo es probar la bondad de diferentes representaciones, nos restringimos a una opción sin parámetros: la regla del K vecino más cercano: *k-Nearest Neighbor (k-NN)* en inglés. Considerando que nuestro estudio es sobre un problema multiclase, la evaluación del desempeño de la clasificación se realizó con medidas que permiten evaluar el desempeño por clase, a saber: matriz de confusión, precisión, recuperación y puntaje F1; además, la precisión y su error estándar se reportan como una medida global. Se consideró la validación cruzada *leave-one-out* a fin de diseñar experimentos reproducibles, con resultados consistentes.

4.5. Resultados y discusión

Las cuatro representaciones de características definidas previamente se aplicaron a los dos conjuntos de datos arriba descritos; adicionalmente, se analizó un 5^o conjunto de características generado a partir de la combinación (concatenación) de los cuatro primeros. Su poder de discriminación se probó usando el clasificador *k-NN* con $k = 1$, tras comprobar que con un mayor número de vecinos, los resultados obtenidos no muestran mejora significativa. Las tablas 4-3 y 4-4, así como la Figura 4-4 corresponden a los resultados generados por la aplicación del marco experimental sobre la base de datos del volcán Nevado del Ruiz.

La Tabla 4-3 compila las matrices de confusión y otras medidas de rendimiento de clasificación por clase definidas para los conjuntos de características. Un análisis por clase de los resultados obtenidos indica que para la clase HB, aunque el 3^{er} y 4^o grupo de representaciones muestran desempeños similares, este último podría ser más apropiado porque obtuvo más verdaderos positivos, sin embargo, esa representación es más susceptible de confundir eventos HB con LP. Con respecto a la clase LP, ésta también puede estar bien representada por el conjunto de características 3^o o 4^o pero, como en el caso anterior, una mayor cantidad de ejemplos LP se confunden con los eventos HB al usar la 4^a representación, en comparación con la 3^a representación. Este hecho puede explicarse por la naturaleza combinada de los eventos híbridos, lo que implica tanto la fractura de rocas (mecanismo típico VT) como movimientos de fluidos (mecanismo LP) para su generación.

Con respecto a la clase TO, se mostró un mejor desempeño de clasificación con la 3^a representación, mientras que la clase TR obtuvo su mejor desempeño de clasificación con la 4^a representación. Es notable que VT sea la clase con menos clasificaciones erróneas, hecho que se evidencia con las cifras de la puntuación F1, *recall* y precisión más altas logradas para esta clase cuando se usa el 4^{to} conjunto de representación, debido a sus componentes espectrales bien definidos y peculiar forma de onda.

En general, según los valores de precisión y error estándar obtenidos para las cuatro representaciones (a saber: $0,7061 \pm 0,0130$; $0,7143 \pm 0,0129$; $0,7829 \pm 0,0118$ y $0,8073 \pm 0,0113$, en su

respectivo orden), se observa que la representación basada en espectrograma promediado conlleva a una mejor identificación de los eventos sísmicos de origen volcánico con respecto a la otras tres representaciones.

Tabla 4-3.: Matrices de confusión y medidas de desempeño para los cuatro conjuntos de representaciones bajo comparación, con datos del VNR.

			<i>Predicción</i>					<i>Medidas de desempeño</i>		
			HB	LP	TO	TR	VT	Precisión	Recall	F1
(a) 1 ^a rep.	<i>Actual</i>	HB	291	66	6	11	19	0,6736	0,7405	0,7055
		LP	89	206	13	11	14	0,6561	0,6186	0,6368
		TO	7	14	72	2	9	0,7200	0,6923	0,7059
		TR	15	14	1	202	10	0,8670	0,8347	0,8505
		VT	30	14	8	7	94	0,6438	0,6144	0,6288
(b) 2 ^a rep.	<i>Actual</i>	HB	310	57	0	4	22	0,6935	0,7888	0,7381
		LP	91	190	20	14	18	0,6312	0,5706	0,5994
		TO	8	24	64	4	4	0,7356	0,6154	0,6702
		TR	7	7	2	218	8	0,8898	0,9008	0,8953
		VT	31	23	1	5	93	0,6414	0,6078	0,6242
(c) 3 ^a rep.	<i>Actual</i>	HB	299	47	1	11	35	0,7438	0,7608	0,7522
		LP	77	214	5	25	12	0,7782	0,6426	0,7039
		TO	6	8	85	1	4	0,9239	0,8173	0,8673
		TR	3	3	0	234	2	0,8478	0,9669	0,9035
		VT	17	3	1	5	127	0,7056	0,8301	0,7628
(d) 4 ^a rep.	<i>Actual</i>	HB	317	64	2	6	4	0,7338	0,8066	0,7685
		LP	91	220	7	15	0	0,7309	0,6607	0,6940
		TO	5	13	82	4	0	0,9011	0,7885	0,8410
		TR	10	4	0	227	1	0,8972	0,9380	0,9172
		VT	9	0	0	1	143	0,9662	0,9346	0,9502

Por otra parte, de acuerdo a lo mostrado en la Tabla 4-4, el conjunto de características compuesto por las cuatro representaciones concatenadas obtuvo un desempeño de clasificación comparable con el logrado por la 4^a representación (sección (a) de la tabla en mención), la cual puede considerarse como la mejor en términos de precisión y error estándar ($0,8073 \pm 0,0113$ frente a $0,8065 \pm 0,0113$). Las bondades de la 4^a representación se ven ligeramente afectadas por la información redundante aportada por las características restantes, lo que lleva a la necesidad de aplicar una selección de características para identificar las más discriminantes.

Después de aplicar el algoritmo de selección de características SFS sobre el conjunto de características concatenadas, la dimensión se redujo de 105 a 57, lo que representa un 46% menos de características para procesar en la siguiente etapa; esto se refleja en una considerable reducción del costo computacional para la clasificación. Además, la precisión ($0,8637 \pm 0,0098$) fue la más alta alcanzada entre todas las representaciones; el mismo comportamiento se observa para las otras medidas de desempeño en cada clase, como se muestra en la parte (b) de la Tabla 4-4.

Tabla 4-4.: Matrices de confusión y medidas de desempeño para (a) la combinación/concatenación de los cuatro conjuntos de representación evaluados, y (b) mejor subconjunto de características seleccionado por *Selección hacia Adelante*, con datos del VNR.

			<i>Predicción</i>					<i>Medidas de desempeño</i>		
			HB	LP	TO	TR	VT	Precisión	<i>Recall</i>	F1
(a) Rep. comb.	<i>Actual</i>	HB	312	67	2	7	5	0,7446	0,7939	0,7685
		LP	86	220	8	18	1	0,7261	0,6607	0,6918
		TO	5	13	83	3	0	0,8830	0,7981	0,8384
		TR	8	3	0	230	1	0,8880	0,9504	0,9182
		VT	8	0	1	1	143	0,9533	0,9346	0,9439
(b) Subc. sel.	<i>Actual</i>	HB	336	49	0	7	1	0,8175	0,8550	0,8358
		LP	58	259	3	11	2	0,8069	0,7778	0,7920
		TO	7	9	84	4	0	0,9655	0,8077	0,8796
		TR	6	4	0	231	1	0,9094	0,9545	0,9315
		VT	4	0	0	1	148	0,9737	0,9673	0,9705

En el subconjunto de características resultante tras la aplicación de SFS, el 40 % de los descriptores pertenecen a la 4ª representación y el 35 % a la 3ª, lo que explica por qué esos dos conjuntos de características ofrecen una mejor representación para todas las clases en general. En consecuencia, las tres características más discriminantes identificadas por el algoritmo de selección son: la frecuencia correspondiente al centroide del contorno espectral (de la 2ª representación), la derivada de primer orden de los primeros MFCC (de la 3ª representación) y la desviación estándar de la señal sísmica (de la 1ª representación). Estas tres características sirvieron para generar un espacio 3-dimensional en el que se dispusieron las observaciones para dar una visualización 3D y examinar la compacidad o dispersión de las clases. En la Figura 4-4 se puede observar que las clases TO y TR son los grupos más compactos (aunque con valores atípicos); en consecuencia, son las clases con menos falsos negativos.

De manera análoga a lo efectuado con los datos del VNR, las siguientes dos tablas relacionan los resultados obtenidos con la base de datos del volcán Villarrica. En la Tabla 4-5 se muestran los resultados obtenidos en las tres clases estudiadas con cada una de las cuatro formas de representaciones aplicadas. Las medidas de desempeño evaluadas muestran que el segundo método de extracción de características es el que ofrece la mejor representación para las señales estudiadas. Esto se corrobora mediante los valores de exactitud y error estándar obtenidos en cada forma de representación (en su respectivo orden): 0,9685, 0,9727, 0,8886 y 0,8555.

Por su parte, en la Tabla 4-6, la cual contiene los resultados de representar las señales con las características de las cuatro representaciones de forma concatenada y de aplicar en este conjunto un algoritmo de selección de características, muestra que en efecto, resulta muy conveniente esta etapa de adaptación para identificar los atributos más relevantes que van a aportar mayor discriminancia en la subsecuente etapa de clasificación. En consecuencia, el algoritmo SFS definió que, en su orden, las cuatro características seleccionadas fueron: la duración (proveniente de la 2ª representación), una banda de frecuencia media obtenida mediante la 4ª representación, un coeficiente MFCC (de

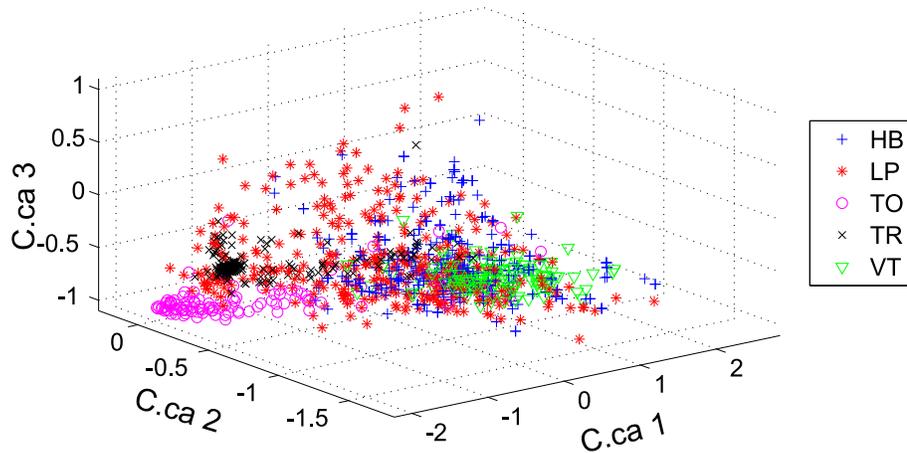


Figura 4-4.: Gráfica de dispersión del conjunto de datos del VNR. Los ejes corresponden a las tres mejores características seleccionadas del conjunto de características concatenadas tras aplicar SFS: C.ca1: frecuencia correspondiente al centroide del contorno espectral; C.ca2: derivada de primer orden de los primeros MFCC; C.ca3: la desviación estándar de la señal sísmica.

la 3ª representación), y la diferencia entre las frecuencias de contorno espectral (planteada en la 2ª representación). Se observa también que después de aplicar el método de selección de características, el desempeño del clasificador para discriminar la clase VT disminuye sustancialmente; esta situación posiblemente sea consecuencia del tamaño tan reducido de la muestra para esta clase con respecto a las demás.

4.6. Resumen del capítulo

En este capítulo se hace una comparación de algunas de las formas de representación de señales sísmicas mencionadas, con el fin de determinar cuál de ellas proporciona al clasificador una mejor capacidad de generalización. Para ello, cada representación se evalúa mediante el desempeño mostrado por un clasificador básico (k -NN), ajustado a las mismas condiciones en todos los casos, de tal manera que los rendimientos de clasificación alcanzados se debieran más a las bondades de la representación que a las del clasificador. Los resultados mostraron que, debido a la diferencia entre los problemas de clasificación (número de clases evaluadas y cantidad de muestras por clase), las características seleccionadas tras aplicar SFS (y por tanto el tipo de representación) no coincidieron: los espectrogramas promediados proveen la mejor representación para las señales sísmicas del VNR, mientras que para el volcán Villarrica, las características propuestas en la segunda forma de representación resultaron ser las más discriminantes. Lo anterior muestra que necesariamente se debe hacer un análisis de caracterización de manera independiente para cada volcán estudiado. No obstante, como pudo observarse en la multiplicidad de enfoques mencionados en este estado del arte, encontrar la representación adecuada de los eventos sísmicos, con el fin de mejorar la tarea de clasificación, continúa siendo un asunto de debate.

Tabla 4-5.: Matrices de confusión y medidas de desempeño para los cuatro conjuntos de representaciones bajo comparación, con datos del volcán Villarrica.

			<i>Predicción</i>			<i>Medidas de desempeño</i>		
			LP	TR	VT	Precisión	Recall	F1
(a) 1ª rep.	<i>Actual</i>	LP	6907	288	22	0,9577	0,9570	0,9574
		TR	275	12443	5	0,9765	0,9780	0,9773
		VT	30	11	19	0,4130	0,3167	0,3585
(b) 2ª rep.		LP	6962	239	16	0,9607	0,9647	0,9627
		TR	266	12456	1	0,9808	0,9790	0,9799
		VT	19	5	36	0,6792	0,6000	0,6372
(c) 3ª rep.		LP	5422	1786	9	0,9287	0,7513	0,8306
		TR	410	12312	1	0,8723	0,9677	0,9175
		VT	6	17	37	0,7872	0,6167	0,6916
(d) 4ª rep.	LP	4923	2281	13	0,8961	0,6821	0,7746	
	TR	564	12149	10	0,8410	0,9549	0,8943	
	VT	7	16	37	0,6167	0,6167	0,6167	

Tabla 4-6.: Matrices de confusión y medidas de desempeño para (a) la combinación/concatenación de los cuatro conjuntos de representación evaluados, y (b) mejor subconjunto de características seleccionado por SFS, con datos del volcán Villarrica.

			<i>Predicción</i>			<i>Medidas de desempeño</i>		
			LP	TR	VT	Precisión	Recall	F1
(a) Rep. comb.	<i>Actual</i>	LP	5550	1657	10	0,9389	0,7690	0,8455
		TR	355	12365	3	0,8808	0,9719	0,9241
		VT	6	17	37	0,7400	0,6167	0,6727
(b) Subc. sel.		LP	7107	91	19	0,9808	0,9848	0,9828
		TR	101	12620	2	0,9925	0,9919	0,9922
		VT	38	4	18	0,4615	0,3000	0,3636

5. Identificación del cambio de concepto en registros sísmicos

Durante las últimas dos décadas, los estudios de ML han brindado herramientas y técnicas para enfrentar el desafío del monitoreo volcánico, al facilitar una tarea repetitiva y que consume mucho tiempo como es la identificación de categorías y asignación de etiquetas de eventos sísmicos. La aplicación de métodos como los HMM, las ANN, las SVM, entre otros (ver detalles en [Orozco-Alzate et al., 2012]), han mostrado resultados satisfactorios en el estado del arte; sin embargo, éstos se han logrado con configuraciones experimentales básicas, esto es, con tamaños de muestra pequeños, tomados en períodos cortos de actividad volcánica, y sin tener en cuenta el orden cronológico de los ejemplos. Bajo esta premisa, es difícil identificar cambios en la dinámica volcánica y, en consecuencia, el desempeño de la clasificación podría deteriorarse una vez que el modelo de aprendizaje se implemente en línea.

El trabajo efectuado en el presente capítulo, tiene como objetivo demostrar la existencia de cambios a través del tiempo (referido en la literatura como cambios del concepto - *concept drift* en inglés) en el fenómeno volcánico, manifestados intrínsecamente en sus registros sísmicos. Para tal fin, se hace un estudio teórico sobre el problema del cambio del concepto y ejecuta un marco experimental en el que se mantuvo el orden cronológico de los ejemplos para simular una situación en línea. Se muestra, mediante tres métodos, uno supervisado y dos no supervisados, la existencia de cambios significativos en los componentes intrínsecos de los datos (cambios del concepto) generados dentro del fenómeno volcánico. Adicionalmente, se muestra cómo el desempeño de un modelo de aprendizaje se ve afectado considerablemente en una tarea de clasificación, cuando los cambios del concepto no son considerados en el análisis de un ambiente volcánico.

Algunas secciones de los marcos conceptual y experimental de este capítulo están basadas en la siguiente publicación asociada a la tesis:

- Castro-Cabrera, P. A., Orozco-Alzate, M., Castellanos-Domínguez, C. G., Huenupán, F., and Franco, L. E. (2018). *Supervised and Unsupervised Identification of Concept Drifts in Data Streams of Seismic-Volcanic Signals*. In Advances in Artificial Intelligence-IBERAMIA 2018: 16th Ibero-American Conference on AI, Trujillo, Peru, November 13-16, 2018, Proceedings 16 (pp. 193-205). Springer International Publishing. DOI: https://doi.org/10.1007/978-3-030-03928-8_16

5.1. Problema del cambio de concepto

El vertiginoso crecimiento de las tecnologías digitales, y por ende, del volumen de datos generados en diferentes aplicaciones del mundo real, ha exigido el uso de herramientas, estrategias y métodos de análisis para datos continuamente crecientes y que, adicionalmente, tienden a cambiar en el tiempo. En años recientes, el estudio de detección de cambios en datos se ha tornado más extenso debido a sus aplicaciones potenciales en escenarios reales como control de tráfico de red, análisis de mercado, detección de fraude, monitoreo de condiciones médicas, entre otros [Gama et al., 2014]. Esto se debe a que la mayoría de estos contextos son entornos no estacionarios en los cuales surgen nuevas fuentes de generación de datos, donde los nuevos datos generados se detectan y reaccionan a los cambios. Dependiendo del área y aplicación que se esté tratando, los cambios subyacentes en los datos pueden deberse a efectos de periodicidad, cambios en los intereses, hábitos o preferencias de usuarios, cambios en la población, fallas de hardware o software que afecten un sistema lógico-físico, gradientes térmicos, efectos de envejecimiento en los sensores, o simplemente pueden atribuirse a una naturaleza compleja del entorno.

Al hacer el análisis de los datos generados en entornos como los previamente mencionados, a menudo se parte de la suposición (ya sea implícita o explícitamente), que el proceso que genera tal flujo de datos es estacionario, es decir, los datos se extraen de una distribución de probabilidad fija, aunque desconocida. Sin embargo, en la mayoría de escenarios del mundo real, tal suposición no es cierta, y el proceso subyacente que genera el flujo de datos se caracteriza por un fenómeno intrínseco no estacionario (evolutivo o cambiante). En tales entornos no estacionarios, donde las propiedades probabilísticas de los datos cambian con el tiempo, un modelo no adaptativo entrenado con datos históricos y bajo la suposición de estacionariedad falsa, está destinado a volverse obsoleto con el tiempo; esto es, que sus predicciones pueden volverse menos precisas a medida que pasa el tiempo o se pueden perder oportunidades para mejorar la precisión. Por lo tanto, los modelos de aprendizaje deben tener mecanismos para el diagnóstico continuo del rendimiento y poder adaptarse a los cambios en los datos a lo largo del tiempo.

En el aprendizaje automático, la minería de datos y el análisis predictivo, los cambios inesperados en la distribución de datos subyacentes a lo largo del tiempo es denominado *cambio de concepto*. Por su parte, en el área de reconocimiento de patrones, el fenómeno se conoce como *cambio de covariante* o *cambio de conjunto de datos*; mientras que en procesamiento de señales, el fenómeno se conoce como *no estacionariedad*. Como vemos, en el estado del arte se pueden encontrar diferentes nombres para un mismo problema que está siendo arduamente estudiado, desde hace varios años, desde diferentes comunidades académicas. A partir de estos estudios, ha surgido cierta cantidad de enfoques, métodos y algoritmos que tratan este problema e intentan contrarrestar los efectos que causa el paso del tiempo en las distribuciones de los datos.

Partiendo de un entendimiento del teorema de Bayes, se puede plantear la definición formal del cambio de concepto entre los tiempos t y $t + 1$ de la siguiente manera [Ditzler et al., 2015; Gama et al., 2014; Elwell and Polikar, 2011; Žliobaitė et al., 2016]:

$$\exists \mathbf{x} : p(\mathbf{x}, y)_t \neq p(\mathbf{x}, y)_{t+1} \quad (5-1)$$

donde $p(\mathbf{x}, y)_t$ y $p(\mathbf{x}, y)_{t+1}$ son las distribuciones conjuntas en los tiempos t y $t+1$, respectivamente; \mathbf{x} es un vector de datos de entrada (una observación o ejemplo), y y es la variable objetivo, que para nuestro caso es el vector de etiquetas de clase. Vale la pena dar una mirada más profunda a esta definición para entender los diferentes aspectos del cambio de concepto [Elwell and Polikar, 2011].

La probabilidad $p(\mathbf{x})$ describe las probabilidades basadas en características (evidencia) de los datos. La observación de $p(\mathbf{x})$ a lo largo del tiempo nos permite ver cambios en el entorno que genera estos datos. Un cambio en la distribución general de las características a menudo significa que los verdaderos límites de decisión también están cambiando; sin embargo, una observación del cambio en $p(\mathbf{x})$ es insuficiente para indicar con certeza un cambio de concepto debido a su independencia de las etiquetas de clase.

El término $p(\mathbf{x}, y)$ describe la probabilidad de considerar la observación \mathbf{x} dentro de una clase particular. Esta medida de probabilidad es dependiente de la clase y se rige por las instancias de datos previamente vistas. Un cambio en esta probabilidad parecería indicar que las etiquetas de clase también pueden estar cambiando. Sin embargo, afirmamos que no es así hasta que la distribución de una clase cambia de tal manera que los verdaderos límites de clase se alteran, lo cual podemos denominar un *cambio de concepto real*. El cambio en una clase sin superposición de los límites de la clase verdadera, se conoce como un *cambio de concepto virtual*, y simplemente muestra que el algoritmo de aprendizaje está recibiendo datos adicionales del mismo entorno. El cambio virtual es el resultado de una representación incompleta de la verdadera distribución en los datos actuales. La diferencia clave es que el cambio de concepto real requiere un aprendizaje de reemplazo, es decir, donde el conocimiento previo se vuelve irrelevante (reestructuración), mientras que el cambio virtual requiere un aprendizaje complementario (agregar al conocimiento actual).

5.1.1. Tipos de cambios de concepto

De acuerdo a lo explicado previamente, los diferentes tipos de cambios de concepto pueden darse por alteraciones en alguno (o en los dos) componentes de la relación de probabilidades, o también por la velocidad a la que se dan los cambios. Entonces, en el primer caso, los cambios dados con base en las modificaciones de los componentes del teorema de Bayes son:

- El *cambio de concepto real* se refiere a los cambios en la probabilidad de clase $p(y|\mathbf{x})$. Dichos cambios pueden ocurrir con o sin cambios en la distribución de los datos $p(\mathbf{x})$.
- El *cambio de concepto virtual* ocurre si la distribución de los datos entrantes cambia, es decir, si $p(\mathbf{x})$ cambia, sin afectar la probabilidad de clase $p(y|\mathbf{x})$.

De acuerdo a la intensidad y frecuencia con que se da el cambio, éste se puede categorizar en:

- Un cambio puede ocurrir de manera *abrupta o repentina*, al cambiar de un concepto a otro en un solo instante de tiempo (por ejemplo, el reemplazo de un sensor con otro que tiene una

calibración distinta), generando alteraciones repentinas en las distribuciones *a posteriori* de las clases.

- Un cambio se da de manera *gradual, suave o incremental*, cuando intervienen muchos conceptos intermedios antes de alcanzar un nuevo concepto de manera permanente, es decir, que el concepto sufre alteraciones leves en cada instante de tiempo t (por ejemplo, cuando un sensor se desgasta lentamente y se hace menos preciso).
- Se puede dar el caso en el que se introducen nuevos conceptos que no se habían visto antes, o que los conceptos vistos anteriormente pueden volver a aparecer después de un tiempo. Este último se conoce como *concepto recurrente* (un ejemplo de ello es la moda, o los datos climáticos cuya recurrencia es marcada por las estaciones).

5.1.2. Flujo de datos en contextos cambiantes

En la actualidad digital prevalece una creciente expansión de aplicaciones innovadoras del mundo real que implican procesos de generación de datos en contextos no-estacionarios. El almacenamiento físico en bases de datos estáticas es una limitante para tales aplicaciones, y por tanto, los datos deben ser organizados en forma de flujos de datos (*data streams* en inglés). *Data streams* se entiende como una cantidad de datos que llegan en línea, de manera constante y a una alta velocidad; además, estos datos generalmente no tienen un control en el orden de llegada y su tamaño crece potencialmente de forma ilimitada [Khamassi et al., 2018].

Un flujo de datos es una secuencia ordenada y potencialmente ilimitada de elementos de datos que llegan con el tiempo. Los intervalos de tiempo entre las llegadas consecutivas de elementos de datos pueden variar. Estos elementos de datos pueden ser simples pares de atributos y valores, como tuplas de bases de datos relacionales, o estructuras más complejas, como grafos.

Las principales diferencias entre los flujos de datos y los conjuntos de datos estáticos convencionales incluyen:

- Los elementos del flujo de datos surgen secuencialmente a lo largo del tiempo.
- No hay control sobre el orden en que llegan los elementos de datos y el sistema de procesamiento debe estar listo para reaccionar en cualquier momento.
- El tamaño de los datos puede ser enorme (los flujos posiblemente tengan una longitud infinita); normalmente es imposible almacenar todos los elementos de un flujo de datos en una memoria estática.
- Por lo general, solo es posible un único escaneo de los elementos del flujo de datos; cuando el elemento se procesa, éste se descarta o se almacena si es necesario.
- En la práctica, se puede almacenar parte de los datos durante un período de tiempo determinado, utilizando un mecanismo de olvido para descartarlos posteriormente.

- La tasa de llegada de elementos del flujo de datos es rápida (relativamente alta con respecto a la potencia de procesamiento del sistema).
- Los flujos de datos son susceptibles de cambiar (las distribuciones de datos que generan ejemplos pueden cambiar sobre la marcha).
- El etiquetado de datos puede ser muy costoso (o incluso imposible en algunos casos), y generalmente no se da de forma inmediata.

Definiéndolo formalmente, un flujo de datos D es una secuencia masiva de elementos de datos $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N$, esto es, $D = \{\mathbf{x}_i\}_{i=1}^N$ el cual es potencialmente ilimitado. Cada elemento del flujo de datos se describe mediante un vector de atributos n -dimensional perteneciente a un espacio de atributos ω que puede ser continuo, categórico o mixto.

De los diferentes temas estudiados alrededor de los flujos de datos, la clasificación supervisada ha recibido un gran atención. El manejo de los flujos de datos a menudo se aplica para resolver diversos problemas de la vida real, como descubrir cambios en las preferencias de los clientes, filtrado de correo no deseado, detección de fraudes y diagnóstico médico, por enumerar solo algunos. Las condiciones mencionadas de velocidad, tamaño y naturaleza evolutiva de los flujos de datos plantean la necesidad de desarrollar nuevas soluciones algorítmicas. En particular, los clasificadores dedicados a flujos de datos deben presentar capacidades de adaptación, ya que la distribución de los datos en movimiento puede cambiar. Para hacer frente a estos desafíos, en la última década se han introducido varios algoritmos nuevos, con enfoques de ventanas deslizantes especializadas, métodos de muestreo, detectores de deriva, conjuntos adaptativos, entre otros.

5.2. Detección del cambio de concepto

La detección de cambios de concepto se refiere a las técnicas y mecanismos que caracterizan y cuantifican la desviación del concepto mediante la identificación de puntos de cambio o intervalos de cambio en el tiempo. Lu et al. [2018] proponen un esquema general para la detección de cambios, dividido en cuatro etapas, las cuales se explican a continuación:

La etapa 1, denominada de “*Recuperación de datos*”, tiene como objetivo recuperar fragmentos de datos a partir del flujos de datos. Dado que una única instancia de datos no puede transportar suficiente información para inferir la distribución general, es importante en las tareas de análisis de flujo de datos saber cómo organizar fragmentos de datos para formar un patrón o conocimiento significativo.

La etapa 2, destinada al “*Modelado de datos*”, tiene como objetivo abstraer los datos recuperados y extraer las características esenciales que contienen información confidencial, es decir, las características de los datos que más impactan en un sistema si los datos cambian. Esta etapa es opcional, ya que se refiere principalmente a la reducción de la dimensión, o reducción del tamaño de la muestra, para cumplir con los requisitos de almacenamiento y velocidad en línea.

La etapa 3 consiste en el “*Cálculo de pruebas estadísticas*”. Es la fase donde se lleva a cabo la medición de disimilitud o estimación de la distancia. Cuantifica la severidad del cambio y forma estadísticas para la prueba de hipótesis. Se considera que es el aspecto más desafiante de la detección del cambio de concepto. El problema de cómo definir una medida de disimilitud precisa y robusta sigue siendo una pregunta abierta. Una medida de disimilitud también se puede utilizar si se utiliza un enfoque no supervisado, para la evaluación de agrupamientos, y para determinar la disimilitud entre subconjuntos de datos.

La etapa 4, que se denomina “*Prueba de Hipótesis*”, utiliza una prueba de hipótesis específica para evaluar la significación estadística del cambio observado en la etapa 3 (valor p). Las pruebas de hipótesis se utilizan para determinar la precisión de la detección del cambio al probar los límites estadísticos de las pruebas estadísticas propuestas en la etapa 3. Sin la etapa 4, las estadísticas de prueba adquiridas en la etapa 3 no tendrían mayor sentido para la detección del cambio, porque no pueden determinar el intervalo de confianza del cambio, es decir, qué tan probable es que el cambio sea causado por el cambio de concepto y no por ruido o por sesgo de selección aleatoria de la muestra, por ejemplo. Las pruebas de hipótesis más utilizadas son: estimación de la distribución de los estadísticos de prueba, *bootstrapping*, la prueba de permutación, y la identificación de límites basada en la desigualdad de Hoeffding.

Vale la pena mencionar que, sin la etapa 1, el problema de detección de cambio de concepto podría considerarse como un problema de dos conjuntos de muestras que se examinan para determinar si la población proviene de la misma distribución. En otras palabras, cualquier prueba multivariable de dos muestras es una opción que se puede adoptar en las etapas de la 2 a la 4 para detectar el cambio de concepto. Sin embargo, en algunos casos, el cambio de la distribución puede no estar incluida en el subconjunto de características seleccionadas, por lo que la selección de características afectará el rendimiento general de un sistema de aprendizaje y es considerado un problema crítico en la detección del cambio de conceptos.

5.3. Algoritmos de detección

5.3.1. Consideraciones algorítmicas

Ditzler et al. [2015] plantean ciertas consideraciones importantes que deberían tenerse en cuenta al momento de diseñar un enfoque de aprendizaje en un entorno no estacionario. En primera instancia, se parte de un proceso no estacionario P que genera un secuencia de datos \mathbf{S}_t para $t = 1, 2, 3, \dots$; se asume que los datos son muestreados de distribuciones de probabilidad potencialmente diferentes. Si los datos se muestrean a partir de una secuencia de longitud potencialmente infinita (o muy larga), entonces no es realista esperar que todos los datos adquiridos puedan estar siempre disponibles, una consideración que es especialmente crítica en aplicaciones de *Big Data*. Por lo tanto, una suposición más realista, que también define el aprendizaje adaptativo, es aceptar que \mathbf{S}_t solo está disponible para el aprendizaje o para la evaluación en el momento en que se presenta por primera vez al algoritmo, lo que también se califica como “aprendizaje de un solo paso”.

En segundo lugar, la mayoría de los algoritmos destinados a tratar el cambio de concepto esperan que las predicciones realizadas por el clasificador se verifiquen con las etiquetas asignadas a \mathcal{S}_t que llegan junto con el siguiente conjunto de datos de entrenamiento \mathcal{S}_{t+1} . Esta configuración permite que el algoritmo mida una pérdida en cada paso de tiempo y se conoce como escenario de “prueba y luego del entrenamiento”, donde se realiza una evaluación del conjunto de datos anterior antes del entrenamiento con el siguiente conjunto de datos. Si las etiquetas no están disponibles inmediatamente cuando llega el siguiente lote de datos, este escenario se denomina “latencia de verificación”, cuyo caso extremo (las etiquetas nunca están disponibles más allá del paso de inicialización) conduce a “entornos inicialmente etiquetados”.

Finalmente, el cambio de concepto también puede ser percibido a causa de una caracterización insuficiente, atributos desconocidos o no observables, un fenómeno conocido como “contexto oculto” o en inglés, como “*unknown unknown*”. En un contexto oculto, hay un proceso subyacente estático, que está oculto a la vista del algoritmo de aprendizaje. Sin embargo, existe un beneficio de contar con un contexto oculto: eliminaría la no estacionariedad. Dado que nunca se puede conocer el contexto oculto, el algoritmo de aprendizaje debe confiar en la definición probabilística antes mencionada del cambio de concepto para describir entornos no estacionarios.

5.3.2. Métodos aplicados

A continuación se describen los tres métodos estudiados e implementados en este trabajo investigativo para hacer la detección de cambios en una secuencias de datos sísmicos de origen volcánico, y por tanto, comprobar si hay existencia o no del problema del cambio de concepto en este entorno.

The Drift Detection Method (DDM)

Usamos el marco metodológico propuesto en [Gama et al., 2004], denominado simplemente “Método de detección del cambio de concepto” (*DDM* por su nombre en inglés). El objetivo del método propuesto es detectar nuevos “contextos”, entendiéndolos como secuencias de ejemplos con una distribución estacionaria. Según el DDM, un cambio en la distribución de datos ocurre cuando el error aumenta hasta alcanzar un nivel de alerta en la observación n_i , y un nivel de deriva en la observación n_j , donde $i < j$, en una secuencia de n observaciones. Para cada punto de la secuencia, la tasa de error (E_i) es la probabilidad de clasificación errónea, con la desviación estándar definida como $s_i = \sqrt{E_i(1 - E_i)/i}$. La teoría del aprendizaje automático asume que, si la distribución de datos es estacionaria, el error de un modelo de aprendizaje se reducirá cuando crezca el número de observaciones.

Adicionalmente, se definen otras dos variables y almacenan los valores durante el proceso de entrenamiento (E_{min} y s_{min}); cuando $E_i + s_i < E_{min} + s_{min}$, entonces se actualizan E_i y s_i . Los autores definieron las siguientes condiciones de activación:

- $E_i + s_i \geq E_{min} + 2 \cdot s_{min}$ para el nivel de alerta, correspondiente a un posible cambio de contexto.
- $E_i + s_i \geq E_{min} + 3 \cdot s_{min}$ para el nivel de deriva: se supone que una deriva de concepto es verdadera.

Semi-parametric log-likelihood detector (SPLL)

El detector de verosimilitud logarítmica semiparamétrico (*SPLL* por su nombre en inglés), propuesto por [Kuncheva \[2013\]](#), es un método que proviene de unir los beneficios de dos marcos de verosimilitud logarítmica, a saber: el criterio de Kullback-Leibler (K-L) y la prueba de Hotelling t^2 ; pero en esta versión, se superan las debilidades de ambos criterios, con una menor carga computacional.

El método *SPLL* asume que todos los datos provienen de la misma distribución, generada a partir de una mezcla gaussiana $p_1(\mathbf{x})$, correspondiente al número de clases o categorías (denotadas como c), con la misma matriz de covarianza. Se definen dos ventanas de datos, W_1 y W_2 ; en la primera de ellas se estiman los parámetros de la mezcla gaussiana, mientras que en W_2 se deriva el criterio de detección de cambio utilizando un límite superior de la log-verosimilitud, que es una desviación estándar de la media del valor del criterio en caso de que las dos distribuciones sean iguales. El criterio se calcula de la siguiente manera:

$$SPLL(W_1, W_2) = \frac{1}{M_2} \sum_{\mathbf{x} \in W_2} (\mathbf{x} - \mu_{i^*})^T \Sigma^{-1} (\mathbf{x} - \mu_{i^*}) \quad (5-2)$$

donde $i^* = \arg \min_{i=1}^c \left\{ (\mathbf{x} - \mu_i)^T \Sigma^{-1} (\mathbf{x} - \mu_i) \right\}$ es el índice del componente con la distancia de Mahalanobis al cuadrado más pequeña entre \mathbf{x} y su centro, y M_2 como la cantidad de observaciones en W_2 .

Suma de distancias al vecino más cercano

A continuación, se describe el método que proponemos en esta tesis para llevar a cabo la detección de cambios de concepto. Consiste en representar las diferencias entre conjuntos de observación (o lotes) a través de distancias usando la regla k -NN con su caso más simple: $k = 1$. No desarrollamos la regla k -NN hasta llegar a la etapa de la asignación de etiquetas, sino que solo se llega hasta el almacenamiento de la distancia medida entre cada observación del conjunto de prueba y su vecino más cercano, utilizando la distancia euclidiana (d_{L_2}) como métrica.

Haciendo una definición más formal, sea \mathbf{x}_i una observación del conjunto de entrenamiento y \mathbf{x}'_j una observación del conjunto de prueba, con $i = 1, \dots, N$ y $j = 1, \dots, M$. La distancia D_{1-NN_j} definida

para cada \mathbf{x}'_j es $D_{1-NN_j} = \min \left\{ d_{L_2} \left(\mathbf{x}'_j, \mathbf{x}_i \right) \right\}$, y finalmente, la distancia del lote se calcula como:

$$D_{Lote} = \sum_{j=1}^M D_{1-NN_j}.$$

En resumen, para un lote formado por una ventana deslizante de datos de prueba, si sumamos esas distancias tomadas desde cada observación \mathbf{x}'_j hasta aquella encargada de asignarle la etiqueta, podemos estimar qué tan lejos del conjunto de entrenamiento están los puntos del conjunto de prueba.

Vale la pena mencionar el fundamento de esta técnica. Cuando hay divergencia de puntos hacia otras regiones del espacio de características, hay dos consecuencias diferentes pero relacionadas: 1) los nuevos puntos (pertenecientes al conjunto de prueba) se mueven hacia regiones de baja densidad (donde se mide la densidad local); y 2) es posible medir qué tan lejos están los nuevos puntos de los puntos de entrenamiento y determinar qué tan diferentes son en el espacio de características dado. Si hay cambios, entonces se supone que la asignación de la etiqueta será menos confiable y que la disminución de la confianza se puede medir indirectamente a través de la distancia desde el prototipo que asigna la etiqueta hasta el punto de prueba.

5.4. Marco experimental

Se aplicaron los tres métodos expuestos previamente, dentro de un marco experimental bien definido, para demostrar que el fenómeno volcánico es un entorno cambiante donde existen cambios de concepto, que son observables en la evolución de los datos sísmicos a lo largo del tiempo. A continuación, se explican las etapas metodológicas seguidas para obtener unos resultados evaluables.

5.4.1. Pre-procesamiento de datos

Como se anticipó en la Sección 3.3.2, los experimentos de este capítulo fueron efectuados empleando únicamente la base de datos del volcán Villarrica. Esto se debe al hecho que al catálogo de registros del Villarrica se tuvo acceso tres años después de haber adquirido el del VNR, encontrando un compendio de registros muy bien depurado, que obedece a un riguroso procedimiento de pre-procesamiento de las señales (aplicado por el grupo de investigación del Departamento de Eléctrica de la UFRO), adicional al hecho de contar con una cantidad de registros bastante numerosa, con registro consecutivos y proveniente de un periodo de adquisición considerablemente largo (7 años). Adicionalmente, después de realizar pruebas preliminares (cuyos resultados no se reportan en esta tesis por no considerarse fundamentales) en las que se llevaron a cabo los experimentos (que a continuación se detallarán) 1^o) escogiendo muestras aleatorias, luego 2) manteniendo la cronología de los datos, comprobamos la importancia de la secuencialidad de los registros sísmicos al considerarlo como un entorno no estacionario.

Estas condiciones hacen de la base de datos del volcán Villarrica, la indicada para ser sometida a pruebas experimentales para contextos no estacionarios, en el que se deben aplicar enfoques

de aprendizaje adaptativo e incremental. Por este mismo motivo, al no cumplir con condiciones similares, fue necesario descartar la base del datos del VNR.

Conjunto inicial de datos

Para los experimentos de este capítulo, se consideraron únicamente los registros del eje vertical (Z) de la estación de referencia (sismómetro triaxial de banda ancha) asignada por el OVDAS debido a su mejor relación señal/ruido (SNR). Adicionalmente, se realizó una limpieza de datos, excluyendo aquellos registros con una SNR baja o por estar fuera de servicio la estación de referencia, quedando un total de 260365 registros. A continuación, los registros se filtraron con un filtro pasa banda Butterworth de orden 10 entre 0,5 y 15 Hz, porque la mayor parte de la energía significativa de los eventos se encuentra en esta banda de frecuencia. Después de este pre-procesamiento, el número de eventos etiquetados por clase quedó dispuesto así: LP- 222441 registros; TR - 37735 registros y VT - 189 registros.

Extracción de características

La representación empleada para estos experimentos es la detallada en el Capítulo 4, la cual está compuesta por 105 características, categorizadas por el dominio en el que son calculadas: tiempo, frecuencia, tiempo-frecuencia y cepstral.

Después de dividir todo el conjunto inicial de datos en conjunto de prueba y de entrenamiento, las características extraídas se normalizaron restando la media (μ) y dividiendo por la desviación estándar (s) del conjunto de entrenamiento. A continuación, se usaron μ y s para normalizar el conjunto de prueba. El conjunto de datos caracterizado se almacenó en una matriz de 260,365 filas (eventos caracterizados) y 105 columnas (características).

Selección de características

Para encontrar un subconjunto de características relevantes que proporcionen una mayor discriminación en la tarea de clasificación, elegimos un método tradicional de tipo filtro llamado Relief, que utiliza un criterio independiente del algoritmo de aprendizaje y proporciona una clasificación de características de acuerdo con su relevancia estimada.

El algoritmo Relief define la calidad de una característica (como muy relevante) de acuerdo con lo bien que distingue entre dos ejemplos de diferentes clases y, en función de este criterio, asigna el peso de cada característica. Sin embargo, la versión original de Relief está limitada porque no puede manejar datos incompletos y solo funciona para problemas de dos clases. Su versión extendida, llamada ReliefF, es capaz de solucionar los problemas antes mencionados y otros adicionales. El algoritmo ReliefF busca un vecino más cercano para cada clase y encuentra los pesos de las características penalizando las que dan valores diferentes a los vecinos de la misma clase, y recompensa

las características que dan valores diferentes a los vecinos de diferentes clases. En el Anexo B se puede detallar el pseudo-código de este algoritmo.

Aplicando el algoritmo ReliefF, el conjunto inicial de 105 características se redujo a 4, a saber: la media de los 5 picos de frecuencia más altos, la duración del evento y la energía wavelet en los niveles 7 y 2.

5.4.2. Diseño de conjunto de datos: selección de observaciones

Autores en geofísica han señalado que alteraciones en los registros sísmicos de las señales volcánicas, en relación con otros indicadores como parámetros geoquímicos o geodésicos (entre otros), contribuyen a determinar un posible periodo de inestabilidad en la dinámica de un volcán, o incluso son precursores de erupciones [Carniel, 2014; Tárraga et al., 2014]. En el caso de la sismología volcánica, los periodos de variaciones en la dinámica interna de un volcán podrían generar cambios subyacentes, los cuales se evidencian en indicadores tales como cambios en el número de eventos registrados, cambios en las firmas de las señales y sus componentes intrínsecos (usualmente los frecuenciales), entre otros [Carniel, 2014]. Dado que el objetivo de este trabajo es identificar cambios de concepto en el fenómeno volcánico, fue necesario adquirir un conocimiento *a priori* sobre la dinámica de la actividad volcánica a través del análisis de los registros de las señales sísmicas, en aras de poder reconocer dichos periodos con algoritmos de detección de cambios.

Desde las últimas grandes erupciones del volcán Villarrica (1984-1985 y 1991 [Van Daele et al., 2014]), éste ha establecido una línea base de actividad sísmica, la cual, en varias ocasiones y por períodos cortos, ha incrementado sus niveles, pero sin necesariamente terminar en una crisis eruptiva (la erupción más reciente fue en marzo 3, 2015). Tal actividad base es estudiada permanentemente por el OVDAS, usando los parámetros usualmente empleados por los observatorios vulcanológicos en general, tales como las Mediciones de Amplitud Sísmica en Tiempo Real (*Real-Time Seismic Amplitude Measurements - RSAM*), Medición de Amplitud Sísmica Espectral (*Spectral Seismic Amplitude Measurement - SSAM*), Desplazamiento Reducido (*Reduced Displacement - RD*), Magnitud Local (ML) y número/energía de los eventos [Carniel, 2014]. Dado que la actividad volcánica del Villarrica está dominada por la actividad de fluidos (LP y TR), se podría considerar un nivel de referencia medido con el RD cuando está por debajo de 10cm^2 y si el RSAM varía entre 8 y 20 unidades [SERNAGEOMIN et al., 2015].

De acuerdo al análisis realizado por los expertos analistas del OVDAS sobre la actividad sísmica registrada en el volcán Villarrica a partir del 2010, se definieron períodos de estabilidad e inestabilidad volcánica en coherencia con un estudio de registros obtenidos en el área geoquímica. Estas definiciones se basaron en la congruencia de niveles bajos o altos de parámetros como el número de eventos diarios registrados por clase, RSAM, SSAM y RD –en sismología– y niveles de SO_2 –en geoquímica. Así, los períodos definidos fueron:

- Estabilidad: 1 de enero de 2013 al 31 de diciembre de 2013 (de acá en adelante, referenciado como “Período de estabilidad” (marco *PE*)), con 13857 ejemplos, de los cuales 9762 son LP, 4065 son TR y 30 son VT.
- Inestabilidad: del 1 de junio de 2014 al 21 de abril de 2017 (en adelante, identificado como “Período de inestabilidad” (marco *PI*)), con 213301 ejemplos, de los cuales 195941 son LP, 17297 son TR y 63 son VT.

De esta manera han quedado establecidos *a priori* dos conjuntos de datos (*PE* y *PI*), que con certeza de medidas sísmicas propias son drásticamente diferentes, y por lo cual, seguramente provienen de distribuciones de datos diferentes. Ahora se procederá a comprobar experimentalmente esta hipótesis con los algoritmos propuestos.

5.4.3. Experimentos diseñados

Se diseñó un experimento para aplicar cada uno de los tres métodos expuestos en la Sección 5.3.2. A continuación, se precisarán las especificaciones paramétricas aplicadas en cada experimento.

Experimento 1

En el aprendizaje automático, los cambios de concepto a menudo se manejan con ejemplos ponderados según su antigüedad o con ventanas de tiempo deslizantes; en este caso usamos la última opción, empleando ventanas W de tamaño fijo. El procedimiento experimental sigue las bases teóricas del DDM (ver Sección 5.3.2) y fue desarrollado como propone [Gama et al. \[2004\]](#). Éste se resume como sigue:

1. Como modelo de aprendizaje, usamos el clasificador k -NN, donde se definió heurísticamente el número adecuado de vecinos, probando con $k = \{1, 3, 5, 7, 9, 11\}$ y manteniendo fijo el tamaño de W .
2. Los ejemplos fueron ordenados cronológicamente para emular el contexto del flujo de datos donde llegan nuevos ejemplos para ser procesados consecutivamente. Las observaciones dentro del marco *PI* se organizaron como conjunto de entrenamiento, y las pertenecientes al marco *PE* como conjunto de prueba.
3. El modelo de aprendizaje se genera a partir de los datos de entrenamiento, y la validación se lleva a cabo n veces con W_n ventanas deslizantes que se mueven sobre el marco *PI* con una superposición de $\alpha\%$ y una ventana tamaño M , donde, $n = \{1, 2, 3, \dots, N\}$, con N igual al número de veces que la ventana W (de tamaño M) cabe dentro del marco *PI*. Para este experimento, probamos iterativamente con $\alpha = \{20, 50, 80\}$ y $M = \{100, 200, 300, \dots, N_{PE}\}$, donde N_{PE} es el número máximo de ejemplos pertenecientes al marco *PE* que caben en una sola ventana.

Experimento 2

Esta prueba demuestra cómo los datos sísmicos de origen volcánico sufren cambios en su distribución cuando evolucionan en el tiempo, pasando de un período de actividad estable a un período de crisis volcánica que terminó en erupción. Esta prueba se realiza a través del criterio *SPLL* propuesto en [Kuncheva, 2013] y que se explica en la Sección 5.3.2. El procedimiento para implementar este experimento fue el siguiente:

1. Dadas dos (2) ventanas de datos deslizantes $W1$ y $W2$, se realiza un agrupamiento dentro de $W1$ en cl grupos, aplicando el algoritmo k -Means, con $k = 3$ como se sugiere en [Kuncheva and Faithfull, 2014].
2. Se calcula una matriz de covarianza intra-agrupamientos ponderada S .
3. La distancia de Mahalanobis al cuadrado se calcula para cada ejemplo en $W2$ con respecto a los centroides de los agrupamientos.
4. Se calcula $SPLL(W1, W2)$, usando la ecuación 5-2, como la media de las distancias mínimas calculadas previamente.
5. Se intercambian las ventanas $W1$ y $W2$ y se repite del paso 1 al 4: $SPLL(W2, W1)$.
6. Se toma el máximo de los dos valores calculados en los pasos 4 y 5, y se encuentra su distribución chi-cuadrado para definir el valor p .

Para la ejecución del experimento se tuvieron en cuenta las siguientes consideraciones:

- Las ventanas $W1$ y $W2$ se definieron bajo el supuesto de que los datos contenidos en cada una proviene de dos funciones de masa de probabilidad diferentes. Para este propósito, $W2$ se ubicó al comienzo del marco PI y se deslizó con una superposición $\alpha\%$. $W1$ se configuró en una sola ventana fija, centrada dentro del marco PE . Realizamos experimentos con $\alpha = \{20, 50, 80\}$.
- El tamaño de las ventanas es un parámetro sensible en el desempeño de cualquier algoritmo de detección de cambios [Gama et al., 2004; Kuncheva, 2013], por lo que probamos exhaustivamente con diferentes tamaños. Se establecieron tamaños proporcionales para las ventanas $W1$ y $W2$ como se sugiere en [Kuncheva, 2013] y [Kuncheva and Faithfull, 2014], respectivamente: $|W1| = |W2|$ y $|W1| = 2 * |W2|$.
- Probamos iterativamente con diferentes tamaños de ventana, $M = \{100, 200, 300, \dots, N_{SP}\}$, donde N_{PE} es el número máximo de ejemplos pertenecientes al marco PE que caben en una sola ventana. Mantuvimos $cl = 3$ para el número de agrupamientos, como se recomienda en [Kuncheva and Faithfull, 2014].

Experimento 3

Con este experimento pretendemos mostrar los cambios temporales que pueden ocurrir en los datos de un periodo reciente con respecto a uno anterior, haciendo uso de una distancia (ver detalle de método en la Sección 5.3.2). Dada una ventana de datos nunca antes vistos, $W2$, que llegan en orden cronológico (conjunto de prueba), se hace una suma de las distancias desde cada uno de ellos al prototipo responsable de la asignación de etiquetas en una regla 1-NN. Esto servirá como una estimación de cuánto difieren los datos de prueba (proporcional a qué tan lejos están) de los prototipos pertenecientes a $W1$ (P_{W1}), donde $W1$ es una ventana de datos que se supone que proviene de la misma distribución, y $i = \{1, 2, 3, \dots, |W1|\}$.

Para la ejecución de este experimento, se tuvieron en cuenta las siguientes consideraciones:

1. $W1$ se definió como una ventana fija compuesta por los datos ubicados dentro del marco PE . $W2$ es una ventana deslizante que se mueve a través del marco PI , según una superposición de α %. Aquí probamos con $\alpha = \{20, 50, 80\}$.
2. Se calcula la distancia de cada punto de $W2$ a su vecino más cercano, usando la distancia euclidiana como métrica: $D_{1-NN} = \min(d_{L_2}(X_{W2}, P_{W1}))$.
3. Un valor representativo para cada ventana deslizante $W2$ se obtiene de la suma de todas las distancias calculadas para cada x_{W2} .

5.5. Resultados y discusión

En esta sección, se evalúa la dinámica de la actividad sísmica volcánica de tres maneras diferentes para determinar si existe o no un cambio de concepto en este entorno y, por lo tanto, considerar la necesidad de una etapa de detección de cambios en una eventual tarea de clasificación. No es el objetivo del marco experimental de este capítulo comparar los resultados para definir el mejor método para la detección de cambios, ni distinguir entre cambios graduales o abruptos. El objetivo es simplemente obtener evidencia de la presencia de factores que generan cambios en la dinámica del volcán.

Para evaluar el método utilizado en el primer experimento, se emplearon 13857 observaciones ordenadas cronológicamente para entrenar el modelo de aprendizaje, que pertenecen a un período de “estabilidad” en la actividad volcánica, y probamos con 4625 diferentes conjuntos de prueba, cada uno con 100 observaciones ($M = 100$ fue el tamaño de ventana elegido porque mostró la mejor resolución en el tiempo); que corresponde al resultado de deslizar la ventana de tiempo con una superposición de $\alpha = 50$ %, es decir, olvidar 50 observaciones por cada nuevo conjunto de prueba e incluir 50 nuevos, también ordenados cronológicamente. Después de probar con diferentes valores para k en la regla k -NN, vimos que el desempeño del clasificador no mostraba mayor diferencia entre tales variaciones de k . Los resultados para $k = 1$ se muestran a continuación.

La Figura 5-1 muestra el deterioro del rendimiento del clasificador cuando el flujo de datos crece y enfrenta un período atípico que produce datos generados por una función de densidad de probabilidad diferente. La gráfica ilustra la curva de error predictivo señalando episodios de importancia en la actividad volcánica. Se observa cómo la errada clasificación muestra un aumento significativo del error, centrado entre enero y mayo de 2015, período en el que se produjo la última crisis eruptiva, que desembocó en la erupción del 3 de marzo del mismo año. La tasa de error de los meses de “estabilidad” de la actividad volcánica pasó de un máximo del 4% al 27% durante los meses que se produjo la fase crítica. Entre junio y agosto de 2014, se muestra otro incremento en los errores de clasificación; este periodo coincide con un aumento importante de la sismicidad tipo LP (estas anotaciones están documentadas en reportes generados por el OVDAS, que se encuentran en [SERNAGEOMIN et al., 2015]); sin embargo, una interpretación acertada del comportamiento del clasificador en este período podría requerir de un análisis más detallado de la sismicidad.

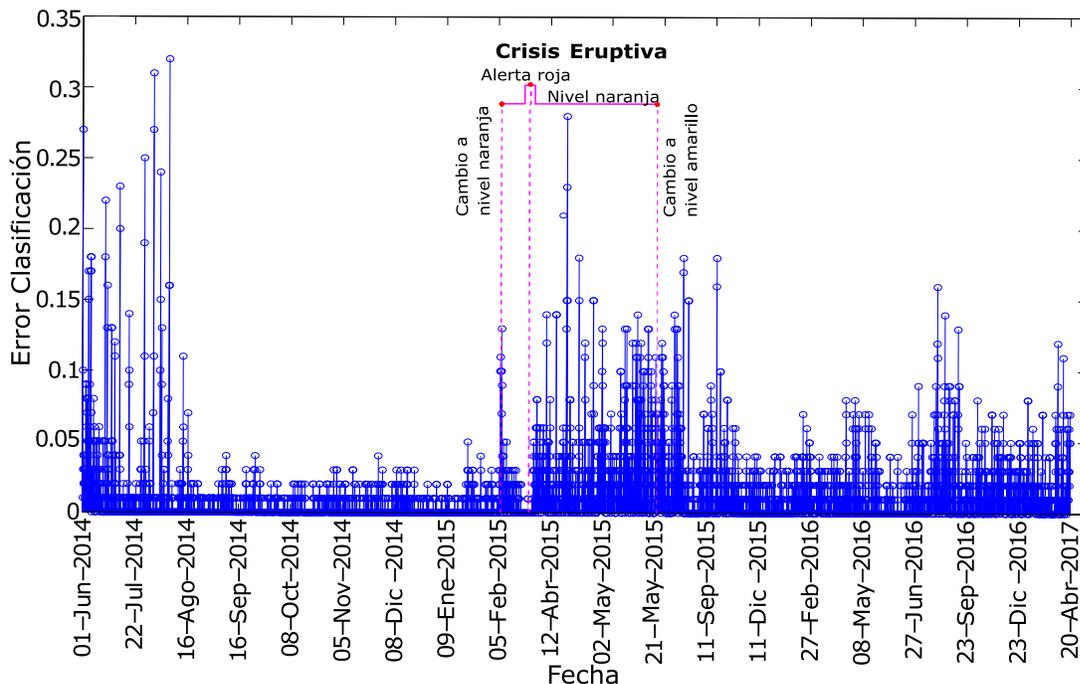


Figura 5-1.: Deterioro de la precisión del clasificador al pasar por diferentes periodos de actividad volcánica, volcán Villarrica. Se indica el nivel de las alertas asignado por el OVDAS (de mayor a menor: rojo, naranja, amarillo, verde [SERNAGEOMIN et al., 2015].)

Las afirmaciones previas se basan en la teoría estadística que indica que, si la distribución de clases es estacionaria, entonces el error del modelo de decisión se reducirá mientras que los ejemplos aumentan [Gama et al., 2004]. Por lo tanto, un aumento significativo de la tasa de error del algoritmo de aprendizaje sugiere un cambio en la distribución de clases y que, en consecuencia, el modelo de decisión utilizado se ha vuelto obsoleto. Entonces, este experimento muestra la importancia de agregar una etapa de cambio de detección y hacer un manejo del cambio de concepto dentro de una tarea de clasificación.

Los dos experimentos subsiguientes muestran que el cambio en la dinámica de la sismicidad volcánica puede manejarse de manera no supervisada. Según el método propuesto por [Kuncheva and Faithfull \[2014\]](#) (ver Sección 5.3.2), un valor demasiado grande del criterio SPLL indicará un cambio; sin embargo, justifica que establecer un umbral para definir “cambio” o “no cambio” es un problema aparte que no analiza en su trabajo. La autora señala que dicho umbral puede ser específico para cada tipo de datos y puede ajustarse de acuerdo con el nivel deseado de falsos y verdaderos positivos.

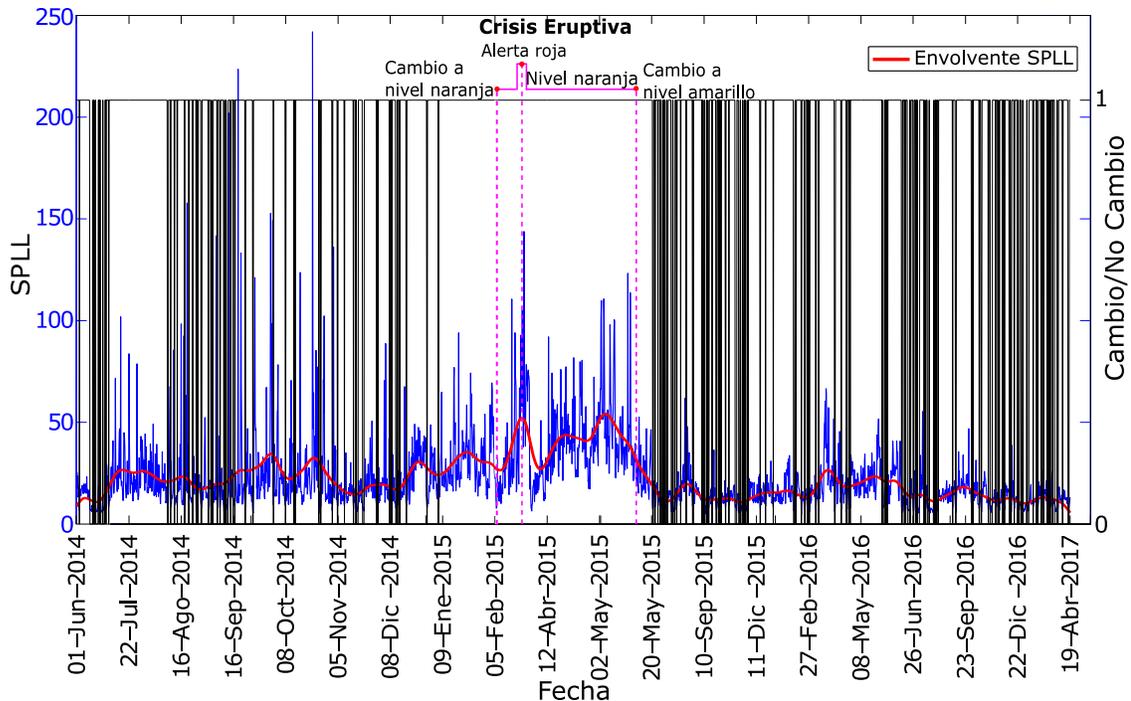


Figura 5-2.: Definición de un entorno cambiante, según el criterio SPLL, sobre la dinámica del volcán Villarrica.

Según lo afirmado previamente, si observamos los valores de la línea azul (y más específicamente la línea roja que representa una envolvente promedio de la azul) de la Figura 5-2, se pueden notar cambios en la región de la gráfica entre enero y mayo de 2015, que coinciden con las mostradas en la Figura 5-1. La línea negra indica el criterio de cambio/no cambio. Dado que no se hizo un ajuste fino del umbral, una variación alterna de tal criterio se entenderá como un cambio nulo o un cambio pequeño y poco significativo.

Con respecto al tercer experimento, como se muestra en la Figura 5-3, la suma de las distancias tuvo los valores más altos en la región entre febrero y mayo de 2015, en particular; una de ellas coincide con la crisis eruptiva. Esto se explica como un movimiento de los puntos de dicho período hacia una región de menor densidad, lo que incrementaría la distancia (puede entenderse como un desajuste entre los puntos comparados) entre los eventos que representan la dinámica “futura”

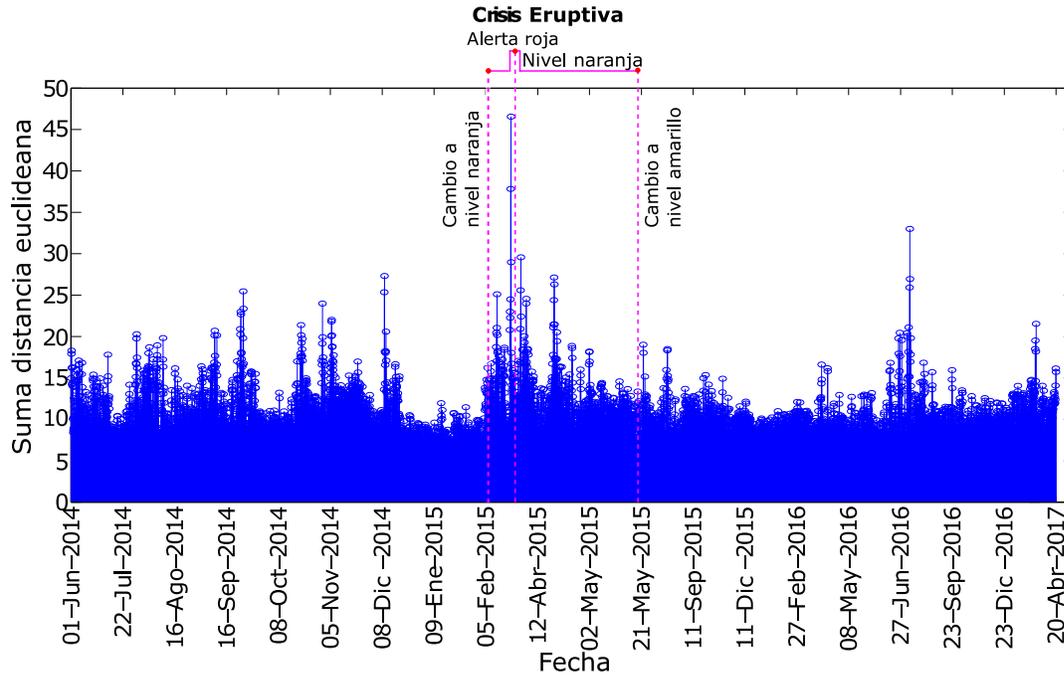


Figura 5-3.: Identificación de cambios significativos en la actividad volcánica a través de la suma de las distancias 1-NN, volcán Villarrica.

del volcán con respecto a los prototipos del pasado que, dentro de la regla 1-NN, le asignaría la etiqueta. Si hay cambios, entonces se supone que la asignación de la etiqueta será menos confiable y que una disminución en la confianza puede medirse indirectamente a través de la distancia desde el prototipo que asigna la etiqueta hasta el punto de prueba.

5.6. Resumen del capítulo

Se han propuesto varias técnicas para el análisis automático de señales sísmico-volcánicas, pero a menudo están limitadas debido a que han sido diseñadas y entrenadas bajo supuestos de distribución de datos invariable a lo largo del tiempo. En el Capítulo 5 se demostró cómo, para un entorno volcánico, un modelo de aprendizaje puede aumentar su tasa de error hasta un 23 % cuando el volcán se enfrenta a una dinámica diferente, como ocurre en fases de crisis eruptiva. Además, se demostró mediante dos métodos no supervisados (uno de ellos simple y directo, propuesto por nosotros) que, al establecer umbrales, se pueden identificar cambios de conceptos en ciertos períodos que provocan cambios en el contexto. Como trabajo futuro, es conveniente hacer un análisis detallado del deterioro del desempeño de la clasificación por clase para determinar las contribuciones de

cada clase. Asimismo, quedan abiertas las posibilidades de verificar la mejora del desempeño de un sistema automático de identificación de eventos sísmico-volcánicos. Esto sería posible agregando una etapa de detección de cambios que retroalimente el modelo de aprendizaje.

6. Clasificación adaptativa de sismos volcánicos mediante aprendizaje incremental

Los sistemas de monitoreo sísmico-volcánico basados en máquinas de aprendizaje pueden llegar a ser muy precisos en períodos seleccionados (específicamente, aquellos en los cuales fue entrenado el modelo de clasificación), pero sus rendimientos tienden a entrar en detrimento a medida que el tiempo transcurre debido a condiciones propias de la sismicidad, como por ejemplo, la generación consecutiva y creciente de datos sísmicos (*data streaming*) —que explica la distribución de datos cambiante en el tiempo— las diversas fuentes sismogénicas que dan origen a los eventos, los mecanismos que producen los diferentes tipos de sismos, entre otros. Adicionalmente, se pueden involucrar otros procesos no estacionarios implicados en escenarios ambientales como la estacionalidad o los cambios climáticos. Y se suman los fenómenos físicos implicados en la captura y transmisión de los datos, como los efectos de envejecimiento inevitables o fallas en los sensores y demás partes electrónicas integradas. Todas estas circunstancias explican la naturaleza evolutiva del contexto volcánico.

Lo anterior conduce a un análisis manual continuo de los nuevos períodos eruptivos para producir conjuntos de datos lo suficientemente grandes como para cubrir la nueva gama de distribuciones de datos, y re-entrenar los modelos de aprendizaje. Por lo tanto, la cantidad insuficiente de nuevos datos etiquetados, junto con el tiempo necesario para analizar y volver a entrenar los modelos, son factores que limitan la puesta en funcionamiento continua y confiable de sistemas de monitoreo automatizados en los observatorios vulcanológicos.

Diversas áreas de las ciencias computacionales y comunidades académicas han propuesto numerosos enfoques de clasificación automática que complementen la agotante labor de asignación de etiquetas que se realizan manualmente en los observatorios; sin embargo, la mayoría de técnicas han sido diseñadas bajo la presunción de estacionariedad, que desconoce la naturaleza cambiante de un proceso que evoluciona en el tiempo como el fenómeno volcánico. En este capítulo, se propone un algoritmo de clasificación adaptativa basada en aprendizaje incremental, el cual identifica y aprende cambios de conceptos en datos procedentes de registros sísmicos que evolucionan en el tiempo. La estrategia presentada, emplea ensambles de clasificadores capaces de tratar estados recurrentes y clasificar datos sin conocimiento *a priori* de sus etiquetas de clase.

En el presente capítulo se profundiza en la teoría del aprendizaje incremental como enfoque empleado para tratar la no estacionariedad de los registros sismo-volcánicos, y se expone un marco experimental que pone a prueba el algoritmo propuesto, planteando protocolos experimentales que,

a diferencia de los usualmente aplicados en el estado del arte, hace el análisis de datos cronológicamente ordenados de largos periodos para lograr la detección de los cambios de concepto.

Una parte significativa del marco conceptual y experimental de este capítulo está basada en la siguiente publicaciones asociadas a esta tesis:

- Castro-Cabrera, P. A., Castellanos-Dominguez, C. G., Mera, C. A., Franco-Marín, L. E., and Orozco-Alzate, M. (2021). *Adaptive classification using incremental learning for seismic-volcanic signals with concept drift*. Journal of Volcanology and Geothermal Research. Vol. 413, p. 107211.
DOI: <https://doi.org/10.1016/j.jvolgeores.2021.107211>

6.1. Aprendizaje adaptativo en entornos no-estacionarios

El aprendizaje adaptativo es una estrategia metodológica de aprendizaje, que se da principalmente en entornos mixtos y en línea, y está basado en sistemas adaptativos, capaces de acondicionarse a los entornos cambiantes donde se desempeñan. Aunque la literatura no muestra una única taxonomía sobre estos campos de estudio, de manera general, podría definirse dentro del aprendizaje adaptativo, aquellos enfoques, métodos o estrategias que manejan flujo de datos y que típicamente incorporan uno o más de los siguientes componentes [Bifet and Gavalda, 2009]: ventanas para recordar ejemplos recientes; métodos para detectar cambios de distribución en la entrada; y métodos para mantener estimaciones actualizadas para algunas estadísticas de la entrada. Lo anterior se puede ver como una base para resolver los tres problemas centrales de un sistema adaptativo: qué recordar u olvidar; cuándo hacer la actualización del modelo; y cómo hacer la actualización del modelo.

Dentro del aprendizaje automático, el aprendizaje supervisado tiene un gran potencial en una amplia variedad de dominios. Sin embargo, como se ha referenciado previamente, su rendimiento puede disminuir drásticamente si este aprendizaje se utiliza con datos que provienen de entornos dinámicos, con datos no estacionarios, como los provenientes de un contexto volcánico. En particular, dentro del aprendizaje adaptativo, destaca el aprendizaje incremental o aprendizaje en línea, que se considera un paradigma de aprendizaje supervisado, donde el proceso de aprendizaje se lleva a cabo y se ajusta cada vez que aparecen nuevos ejemplos. En general, una tarea de aprendizaje es incremental si los ejemplos de entrenamiento utilizados para resolverla están disponibles a lo largo del tiempo, generalmente uno a la vez [Ade and Deshmukh, 2013]. La principal diferencia entre el aprendizaje incremental y el no incremental es que no se supone que haya disponible un conjunto de entrenamiento suficiente antes del proceso de aprendizaje; por el contrario, los ejemplos de entrenamiento aparecen con el tiempo.

Podría generalizarse que un algoritmo ideal construido dentro del paradigma del aprendizaje adaptativo debería tener las siguientes características: adaptar nueva información cuando esté disponible, capacidad para trabajar con datos no etiquetados, capacidad para procesar datos multidimensiona-

les, complejidad limitada, aprender de manera incremental a partir de datos empíricos y gestionar cambios en los conceptos.

6.1.1. Exigencia de sistemas adaptativos en entorno sismo-volcánico

Los volcanes son sistemas no lineales altamente complejos donde su comportamiento refleja una diversidad de procesos internos ocultos que pueden conducir a su actividad eruptiva y agitación. El monitoreo de volcanes se basa en el paradigma de que varios parámetros observables tienen un vínculo causal más o menos directo con estos procesos complejos y con las variables internas del sistema, así como con una serie de procesos de forzamiento y modulación. Aunque la inestabilidad de un volcán a menudo está relacionada con procesos dependientes de la velocidad, no siempre es así, ya que a veces la simple ausencia o presencia de algunos parámetros observables puede proporcionar información muy valiosa sobre la dinámica de estos sistemas.

La riqueza de los datos sísmicos registrados durante una erupción requiere una clasificación precisa. La morfología, el entorno tectónico y la composición de los volcanes contribuyen a dar forma a la señal sísmica, por ejemplo, debido a la atenuación de la energía de alta frecuencia. Los sistemas de monitoreo de aprendizaje automático actuales han destacado los cambios topográficos o las variaciones sísmicas del medio como una influencia significativa en el rendimiento de la detección. Concretamente, [Hibert et al. \[2017\]](#) identificaron un cambio sustancial en el mecanismo físico de los eventos registrados en Piton de La Fournaise como el principal factor que influye en el rendimiento predictivo. De manera similar, [Malfante et al. \[2018\]](#) describen los cambios de sismicidad a lo largo del tiempo en el volcán Ubinas como la principal disminución de la precisión a lo largo de los períodos eruptivos.

Desde una perspectiva de aprendizaje automático, los cambios dentro del entorno sísmico producen distribuciones de probabilidad que son muy distintas del entrenamiento original de los datos. Esto conduce a supuestos demasiado simplificados que no reflejan la situación actual, disminuyendo así la detección correcta y causando bajo rendimiento en la clasificación. Como resultado, estas limitaciones estadísticas podrían socavar la capacidad de producir una metodología objetiva para clasificar señales de manera consistente con altos niveles de confianza, que en última instancia puede extenderse a metodologías de alerta temprana más refinadas [[Bueno et al., 2019](#)].

6.2. Aprendizaje incremental

Cuando observamos el aprendizaje humano, vemos claramente que es incremental. Las personas aprenden la descripción de un concepto a partir de los hechos y refinan gradualmente esas descripciones cuando se dispone de nuevos hechos y observaciones. La información recién obtenida se utiliza para refinar la estructura y los modelos del conocimiento, y rara vez provoca la reformulación de todo el conocimiento que la persona tiene sobre el tema en cuestión. Hay dos razones principales por las que los humanos deben aprender de forma incremental: 1) flujo secuencial de información y 2) memoria y capacidad de procesamiento limitadas. El aprendizaje incremental es una capacidad

importante para la inteligencia similar al cerebro, ya que los sistemas biológicos pueden aprender continuamente a lo largo de su vida y acumular conocimiento con el tiempo.

Los objetivos clave de la investigación del aprendizaje incremental son: 1) transformar el conocimiento aprendido previamente, mediante los datos recibidos actualmente, para facilitar el aprendizaje a partir de nuevos datos, y 2) acumular experiencia a lo largo del tiempo para respaldar el proceso de toma de decisiones y lograr la generalización global a través del aprendizaje para lograr objetivos. Durante la situación de aprendizaje incremental, los datos sin procesar que provienen del entorno con el que interactúa el sistema inteligente se vuelven disponibles de manera incremental durante una vida útil indefinidamente larga. Por lo tanto, el proceso de aprendizaje es fundamentalmente diferente del proceso de aprendizaje estático tradicional, donde la distribución de datos representativos está disponible durante el tiempo de entrenamiento para desarrollar las fronteras de decisión.

El aprendizaje incremental ha atraído recientemente una creciente atención tanto de la academia como de la industria. Desde el punto de vista de la AI, hay al menos dos razones principales por las que el aprendizaje incremental es importante. En primer lugar, desde la perspectiva de la minería de datos, muchas de las aplicaciones informáticas de uso intensivo de datos de hoy en día requieren que el algoritmo de aprendizaje sea capaz de aprender de forma incremental a partir de datos de flujo dinámico a gran escala, y para construir la base de conocimientos con el tiempo para beneficiar el aprendizaje y la toma de decisiones en el futuro. En segundo lugar, desde la perspectiva de la AI, los sistemas biológicos inteligentes pueden aprender información de forma incremental a lo largo de su vida, acumular experiencia, desarrollar asociaciones espacio-temporales y coordinar vías senso-motoras para lograr objetivos (comportamiento orientado a objetivos).

El término incremental se ha aplicado tanto a tareas de aprendizaje como a algoritmos de aprendizaje, lo que genera cierta confusión. Giraud-Carrier [2000] define formalmente que *“una tarea de aprendizaje es incremental si los ejemplos de entrenamiento usados para resolverla están disponibles con el tiempo, generalmente uno a la vez”*. Se debe tener en cuenta que, si se está preparado para esperar el tiempo suficiente, cualquier tarea de aprendizaje incremental puede, en principio, convertirse en una no incremental. Por lo tanto, para las tareas de aprendizaje incremental, existe la suposición implícita de que esperar es indeseable y/o poco práctico. En particular, la naturaleza de la aplicación puede hacer inviable la generación oportuna de un número suficientemente grande de ejemplos representativos, ya sea porque el entorno cambia en el tiempo (y, por lo tanto, el aprendizaje se vuelve sensible al contexto) o porque la velocidad a la que los ejemplos están disponibles puede ser demasiado lenta.

Los siguientes son ejemplos de tareas de aprendizaje incremental [Giraud-Carrier, 2000]. En los primeros tres, la incrementalidad se debe a cambios en el objetivo a lo largo del tiempo. En el último, el objetivo no cambia, pero la adquisición de datos es inoportuna:

- *Modelado/perfilado de usuarios*. En el tratamiento de usuarios, el comportamiento de hoy no es necesariamente una buena indicación del de mañana. Los expertos argumentan que el comportamiento y los intereses de los usuarios varían radicalmente en tan solo seis meses.

Por lo tanto, la útil tarea de conocer los perfiles de los usuarios requiere un seguimiento en línea de ellos individualmente.

- *Robótica*. En todos los casos, excepto en los más simples, el entorno de un robot cambia y, a menudo, es impredecible. Por lo tanto, para sobrevivir (por ejemplo, realizando una navegación sin colisiones) y para llevar a cabo sus tareas con éxito, un robot debe ser capaz de reaccionar y adaptarse gradualmente a las señales ambientales.
- *Agentes inteligentes*. Los agentes son implementos de software caracterizados tanto por la reactividad como por la proactividad. Por lo tanto, al igual que con los robots, la incrementalidad es inherente al aprendizaje de los agentes. Las aplicaciones de agentes tradicionales donde el aprendizaje es útil incluyen la gestión de redes (por ejemplo, equilibrio de carga, enrutamiento) e interfaces de usuario inteligentes.
- *Estimación de proyectos de software*. Estimar el costo, el esfuerzo y la duración de los proyectos de software es en gran medida una cuestión de experiencia. Sin embargo, debido a los plazos bastante largos de tales proyectos, los datos útiles están disponibles poco a poco, con el tiempo. Se ha argumentado que la construcción de una línea de base adecuada para la estimación puede tomar hasta tres años. Sin embargo, incluso la experiencia limitada es mejor que ninguna experiencia en pro de mejorar la precisión de las estimaciones.

6.3. Estrategias usadas para el aprendizaje en entornos no-estacionarios

Un algoritmo de aprendizaje incremental se puede definir como uno que cumple con los siguientes criterios:

- Podrá aprender y actualizarse con cada nuevo dato con o sin etiqueta.
- Conservará los conocimientos previamente adquiridos.
- No debe requerir el acceso a los datos originales.
- Generará una nueva clase o agrupamientos cuando sea necesario. Dividirá o fusionará grupos según se requiera.
- Será de naturaleza dinámica con el entorno cambiante.

Un algoritmo que posea estas propiedades sería una herramienta indispensable para los investigadores en las áreas de PR y ML, ya que prácticamente un número ilimitado de aplicaciones puede beneficiarse de un algoritmo de aprendizaje incremental tan versátil [Polikar et al., 2001].

La necesidad de obtener sistemas inteligentes capaces de adaptarse a nuevas situaciones ha motivado la generación de algoritmos adaptativos en tiempo real que manejen flujos de datos a alta velocidad.

En este sentido, el aprendizaje incremental, en general, produce una secuencia de modelos de aprendizaje h_1, h_2, \dots, h_t para cada dato de entrenamiento del flujo de datos. Se han desarrollado varias técnicas dentro del marco de aprendizaje incremental para tratar problemas y tareas, tales como: representación de datos [Zúñiga et al., 2013; Zeng and Li, 2014; He et al., 2015; Das et al., 2018], reducción de dimensión y selección de características [Ozawa et al., 2009; Joseph and Ozawa, 2014; Leng et al., 2014; Fujiwara et al., 2019], agrupamientos [Mehrkanoon et al., 2015; Yu et al., 2015], entre otros, los cuales han sido utilizados en diferentes aplicaciones como: robótica [Amirat et al., 2016; Feng et al., 2019], procesamiento de imágenes [Diaz-Chito et al., 2014; Zhang et al., 2017], procesamiento de *Big Data* [Li et al., 2018; Nallaperuma et al., 2019] (consulte [Gepperth and Hammer, 2016; Losing et al., 2018] para ampliar el estado del arte sobre el aprendizaje incremental). Las reglas de fusión de ensamble de clasificadores son otra estrategia de adaptabilidad incremental que incorpora varios aprendices entrenados con diversas particiones de datos de entrenamiento, cuyos juicios individuales se combinan adecuadamente en una hipótesis de conjunto final, utilizando un algoritmo de votación por mayoría.

Una de las estrategias de ensamble más conocidas se implementa en la familia de algoritmos *Learn++*, inspirada originalmente en AdaBoost [Schapire, 2013]. Desde su primera versión [Polikar et al., 2001], todos los algoritmos de *Learn++* mantienen algunas generalidades en común, como la expansión del conjunto con clasificadores entrenados incrementalmente a partir de lotes de datos recientes (no se requiere acceso a datos históricos) y el uso de reglas específicas de voto mayoritario ponderado, siendo el tipo de regla y la condición de actualización de la distribución para elegir los datos de entrenamiento para los miembros del ensamble subsecuente, las principales características que distinguen entre las diferentes versiones del algoritmo *Learn++*. En el Anexo C se describe el pseudo-código del algoritmo *Learn++* a fin de exhibir las peculiaridades básicas de esta familia de algoritmos.

Para el aprendizaje en entornos no estacionarios bajo la influencia de cambios de conceptos, se creó la versión *Learn++.NSE*. Este algoritmo trata con las no estacionariedades agregando, en cada momento t (cuando llega el lote de datos más reciente), un nuevo clasificador para ser entrenado. Los clasificadores se combinan dinámicamente mediante voto mayoritario ponderado para formar un ensamble de clasificadores. Si bien los detalles de este algoritmo están recogidos en [Elwell and Polikar, 2011], explicamos brevemente sus aspectos más relevantes:

- Aunque *Learn++.NSE* es independiente del clasificador base, se recomienda no utilizar clasificadores de poda.
- Los pesos de votación se encuentran evaluando la tasa de error individual para cada clasificador del ensamble mientras se mantiene una baja complejidad computacional.
- Dependiendo de la naturaleza del cambio, la versión *NSE* puede retener, construir o descartar (temporalmente) conocimiento que puede usarse para categorizar correctamente nuevos datos.
- *Learn++.NSE* utiliza una función de pérdida ajustada en el tiempo para determinar la ponderación en una estrategia de voto mayoritario.

- Este ajuste favorece a los clasificadores que se han desempeñado bien en los últimos tiempos; sin embargo, también permite reactivar aquellos clasificadores que tuvieron un mal desempeño en épocas anteriores y reutilizarlos cuando ocurre un *contexto recurrente* (reaparición de distribuciones anteriores).

6.4. Algoritmo incremental adaptativo para el manejo del cambio de concepto en registros sísmicos volcánicos

El estado del arte reporta numerosas propuestas taxonómicas para categorizar diferentes métodos que tratan el problema del cambio de concepto, como las presentadas en [Gama et al., 2014; Ditzler et al., 2015; Gunn et al., 2018; Khamassi et al., 2018]. Para el desarrollo experimental de este capítulo, tomamos en consideración el planteamiento expuesto en [Ditzler et al., 2015], donde se explica que los algoritmos diseñados para el manejo del cambio de concepto se asocian a un enfoque metodológico activo –que contempla separadamente una etapa de detección del cambio y otra de adaptación– o a uno pasivo que actualiza continuamente el modelo al momento de arribo de nuevos datos sin tener un requerimiento expreso de una detección del cambio previa. Los algoritmos incrementales obedecen a esta última condición, y por sus múltiples ventajas (ver detalles en [Losing et al., 2018]), hemos optado por este tipo de técnicas para desarrollar el algoritmo propuesto y diseñar el marco experimental que lo pone a prueba.

En [Mera et al., 2019], se usa Learn++.NSE como base para generar un algoritmo incremental para enfrentar un problema de dos clases dentro del marco de aprendizaje de múltiples instancias, al que llamaron Learn++.MIL. Al igual que su predecesor, este algoritmo procesa lotes de datos utilizando un enfoque de detección pasiva [Ditzler et al., 2015]: cada lote disponible entrena a un nuevo clasificador que se agrega al ensamble. Es decir, al aceptar que la distribución de datos subyacente puede cambiar en cualquier momento, se lleva a cabo una adaptación continua del modelo cuando llegan nuevos datos. De manera similar, el algoritmo Learn++.MIL se ocupa de contextos recurrentes a través de pesos asignados a cada clasificador con respecto al ensamble total, y determina qué clasificadores del pasado pueden ser útiles para la distribución de datos actual.

Como problema adicional, Learn++.MIL considera y propone una solución para una situación generalizada en las aplicaciones del mundo real: la falta de etiquetas de clase verdaderas disponibles inmediatamente después de que se adquieren los datos. Para ello, utiliza un ensamble dinámico (o temporal) construido a partir de clasificadores del pasado, que actúa mientras las verdaderas etiquetas no están listas para su uso. Esta característica del algoritmo lo hace muy apropiado para la aplicación en la que se enfoca esta tesis.

Para aplicar el algoritmo Learn++ a la tarea de clasificación de eventos sísmico-volcánicos, aprovechando los beneficios logrados en la versión MIL, proponemos algunas modificaciones adicionales en una nueva versión que denominamos Learn++.SIMC, que permite el procesamiento de *instancias únicas* dentro de una *aplicación multiclase*.

Dado que los algoritmos de Learn++ son independientes del modelo de clasificación, es posible utilizar diferentes tipos de clasificadores base. En nuestro caso, los clasificadores multi-instancia utilizados en Learn++.MIL fueron cambiados por clasificadores convencionales que han mostrado resultados satisfactorios en el estado del arte de la clasificación de señales sísmico-volcánicas, como el k -NN y SVM, entre otros. El pseudocódigo con las modificaciones propuestas se muestra en el Algoritmo 1.

El algoritmo se entrena mediante el uso de lotes de datos (también llamados *batches*), denotados como T^t , que se generan en un entorno no estacionario. Inicialmente se asume la falta de conocimiento de las etiquetas de clase verdaderas (excepto para el primer lote). Otro parámetro de entrada es λ , valor definido entre 0 y 1, que sumado y restado de $P(\omega_j)$, determinará el valor de φ_k^t . El “Clasificador Base” se llamará aprendiz (*learner*); aquí se puede utilizar cualquier algoritmo de clasificación deseado. Incluso se puede organizar una lista de varios clasificadores; éstos se podrían utilizar ordenadamente y de forma mutuamente excluyente, pero sólo se elegirá el siguiente clasificador de la lista cuando el actualmente empleado supere $\epsilon_k^t > 0,5$ (esto se hace en el Paso 5).

En el primer paso, cuando $t > 1$, el algoritmo crea un conjunto temporal $H_*^{(t-1)}$ a partir de aprendices individuales (h_k) que fueron entrenados en momentos anteriores k , con $k \leq t$. Como novedad, en la versión Learn++.SIMC, extendimos la aplicación del enfoque a un problema multiclase usando las probabilidades previas de clase $P(\omega_j)$, que determinan si los clasificadores individuales h_k pueden reconocer conceptos pasados en el lote actual. Para generar el ensamble temporal $H_*^{(t-1)}$, calculamos la proporción φ_k^t de ejemplos en el lote t que se identifican con h_k como parte del concepto j . Entonces, podemos definir qué tan similar es φ_k^t con respecto a $P(\omega_j)$ calculado en el lote $t - 1$. Para este propósito, establecemos los valores α_1 y α_2 que definen el intervalo de aceptación de la probabilidad previa de cada clase φ_k^t (calculada usando un valor de tolerancia λ). Así, luego de acumular y sumar en ψ , la obtención de la proporción φ_k^t (representado por un 1 lógico) para todas las clases dentro del intervalo definido, se determina si el clasificador h_k se suma al ensamble temporal $H_*^{(t-1)}$.

Posteriormente, a partir del Paso 2, cuando se dispone de las etiquetas verdaderas, se realiza la clasificación con el ensamble temporal y se calcula el error e^t . En consecuencia, mediante el valor de e^t , será posible determinar si el entorno actual proviene de una distribución subyacente previamente conocida (es decir, un concepto recurrente) –evidenciada cuando e^t es bajo–, o se está enfrentando un nuevo entorno que necesita ser aprendido (cuando e^t es alto). En el Paso 3, las instancias mal clasificadas se penalizan con $H_*^{(t-1)}$. Cada instancia procesada tiene un peso asociado w_i^t . Aquellas instancias mal clasificadas quedan con sus pesos invariantes; por el contrario, las correctamente clasificadas aumentan su peso en un factor e^t . Posteriormente, se calcula una distribución de penalización \mathbf{D}^t normalizando los pesos; se normalizan para aumentar el peso de las instancias mal clasificadas. Luego, para aprender los conceptos objetivo en el entorno actual, en el paso siguiente (Paso 4), se entrena un nuevo clasificador h_t ($k = t$) utilizando el conjunto de datos actual T^t .

En el Paso 5, se realizan varios cálculos para evaluar el desempeño de los clasificadores h_k ($k = 1 \dots t$) que componen el ensamble: ϵ_k^t es el error del clasificador h_k sobre el conjunto de datos T^t

Algoritmo 1: Algoritmo Learn++.SIMC**Entradas:**

- ▶ T^t : lote de datos de entrenamiento para cada tiempo t
 $T^t = \{(\mathbf{x}_1^t, y_1^t), \dots, (\mathbf{x}_m^t, y_m^t)\}; y_i^t \in \{\omega_1, \omega_2, \dots, \omega_c\}; m$ es el número de instancia por lote, el cual puede cambiar cada tiempo t
- ▶ λ : valor de tolerancia
- ▶ **Clasificador Base**: un clasificador tradicional

Salida : H^t : un clasificador incremental

```

1 for  $t = 1, 2, \dots$  do
2   if ( $t > 1$ ) then
3     Paso 1. Se construye un ensemble temporal:
4     for  $k = t - 1, t - 2, \dots, 1$  do
5       for  $j = 1, 2, \dots, c$  do
6          $\varphi_k^t = \sum_{i=1}^m \frac{1}{m} \cdot \mathbb{1}\{h_k(\mathbf{x}_i^t) = \omega_j\}$ , donde  $\mathbb{1}\{\cdot\}$  es la función indicatriz
7          $\alpha_1, \alpha_2 = P^{t-1}(\omega_j) \pm \lambda$ 
8         if ( $\alpha_1 \leq \varphi_k^t \leq \alpha_2$ ) then
9            $\lfloor$  Bandera( $j$ ) = 1
10        if ( $\psi = \frac{1}{c} \sum_{j=1}^c \text{Bandera}(j) > 1$ ) then
11           $\lfloor$  Adicione  $h_k$  al ensemble temporal  $H_*^{t-1}$  con peso  $\varphi_k^t$ 
12        Paso 2. El error se obtiene de la clasificación con  $H_*^{t-1}$ :
13        
$$e^t = \sum_{i=1}^m \frac{1}{m} \cdot \mathbb{1}\{H_*^{t-1}(\mathbf{x}_i^t) \neq y_i^t\}$$

14        Paso 3. Actualice y normalice los pesos de las instancias únicas:
15        
$$w_i^t = \frac{1}{m} \cdot \begin{cases} e^t, & \text{si } H_*^{t-1}(\mathbf{x}_i^t) = y_i^t \\ 1, & \text{En otro caso} \end{cases}$$

16        
$$\mathbf{D}^t = \mathbf{w}^t / \sum_{i=1}^m w_i^t$$

17        Paso 4. Use Clasificador Base para obtener  $h_t$ 
18        Paso 5. Evalúe todos los clasificadores existentes en los nuevos datos  $T^t$ :
19        for  $k = t, t - 1, \dots, 1$  do
20           $\epsilon_k^t = \sum_{i=1}^m \mathbf{D}^t \cdot \mathbb{1}\{h_k(\mathbf{x}_i^t) \neq y_i^t\}$ 
21          if ( $k = t$  y  $\epsilon_k^t \geq 0,5$ ) then
22             $\lfloor$  Genere un nuevo  $h_t$ 
23          if ( $k \neq t$  y  $\epsilon_k^t \geq 0,5$ ) then
24             $\lfloor$   $\epsilon_k^t = 1/2$ 
25            
$$\beta_k^t = \frac{\epsilon_k^t}{1 - \epsilon_k^t}; W_k^t = \log\left(\frac{1}{\beta_k^t}\right)$$

26        Paso 6. Obtenga el ensemble final:
27        
$$H^t(\mathbf{x}_i^t) = \arg \max_c \sum_k W_k^t \mathbb{1}(h_k(\mathbf{x}_i^t) = c)$$


```

y se obtiene sumando los pesos w_i^t de las instancias mal clasificadas por h_k . Esto determina qué tan bien se desempeña h_k en el entorno actual; los clasificadores h_k con el mejor desempeño serán considerados más relevantes que otros. Si el clasificador más nuevo h_t obtiene $\epsilon_k^t \geq 0,5$, se descarta y se debe entrenar uno nuevo para reemplazarlo; para los demás clasificadores del ensamble (h_k , con $k < t$) que obtienen $\epsilon_k^t \geq 0,5$, se fija el error de clasificación en $\epsilon_k^t = 0,5$ para su posterior normalización. A continuación, se calcula el error normalizado β_k^t para cada clasificador, a partir de ϵ_k^t . El peso del clasificador h_k , denotado como W_k^t , es otra medida que indica qué tan bueno es h_k en el entorno actual, y se calcula con el logaritmo recíproco de β_k^t ($\log(\cdot)$ estabiliza valores enormes generados por el recíproco). Si el h_k evaluado no es efectivo en el entorno actual ($\beta_k^t \approx 1$), se eliminará temporalmente pero no se descartará, ya que se reutilizará en un entorno donde h_k vuelva a ser relevante (cuando su voto ponderado en el ensamble sea alto).

Finalmente, en el Paso 6, se obtiene un ensamble final (también llamado hipótesis compuesta o final H^t), que se define como el voto de la mayoría ponderada de los clasificadores h_k , de acuerdo con el peso W_k^t asignado en el momento actual t , para cada aprendiz h_k . H^t se usará para clasificar los nuevos datos entrantes hasta que llegue un nuevo conjunto de datos de entrenamiento desde un nuevo entorno. Vale la pena aclarar que nuestro algoritmo Learn++.SIMC ha omitido un paso de la versión NSE, en el cual se calcula la función sigmoidea del error normalizado (tal como lo hizo el algoritmo Learn++.MIL). Esto se debe a que el desempeño del clasificador h_k puede considerarse un índice suficiente para determinar la relevancia del clasificador en el entorno actual y, por lo tanto, es importante incluirlo en el ensamble final H^t .

6.5. Marco experimental

La configuración experimental utilizada sigue el concepto de sistemas de reconocimiento de patrones [Duin and Pekalska, 2007], que adaptamos para incluir la inferencia en entornos cambiantes. La Figura 6-1 presenta el esquema de validación propuesto que está ajustado al reconocimiento de sismos volcánicos e incluye las etapas de adquisición de datos, pre-procesamiento, extracción (y selección) de características y clasificación adaptativa. A su vez, la última etapa contiene el ajuste de parámetros necesario para implementar la clasificación adaptativa por partes y la estrategia de aprendizaje adaptativo incremental que realiza el algoritmo Learn++.SIMC desarrollado. Dado que nuestra contribución se centra en esta última etapa, la descripción experimental y los resultados informados se enfocan principalmente al impacto del aprendizaje incremental en el rendimiento de la clasificación.

Además de la presentación del esquema metodológico anterior, vale la pena entender por qué un enfoque como el propuesto es apropiado para la aplicación que se trata en esta tesis. El personal experto de los observatorios vulcanológicos se dedica las 24 horas del día al monitoreo volcánico, y por ende, a la ejecución de tareas primarias, incluyendo la asignación manual de etiquetas a los eventos sísmicos que ocurren. Esto se puede hacer casi en tiempo real durante los períodos de reposo volcánico relativo. Sin embargo, en periodos de reactivación son muy frecuentes los incrementos repentinos en el número de sismos por día, así como los llamados enjambres (gran

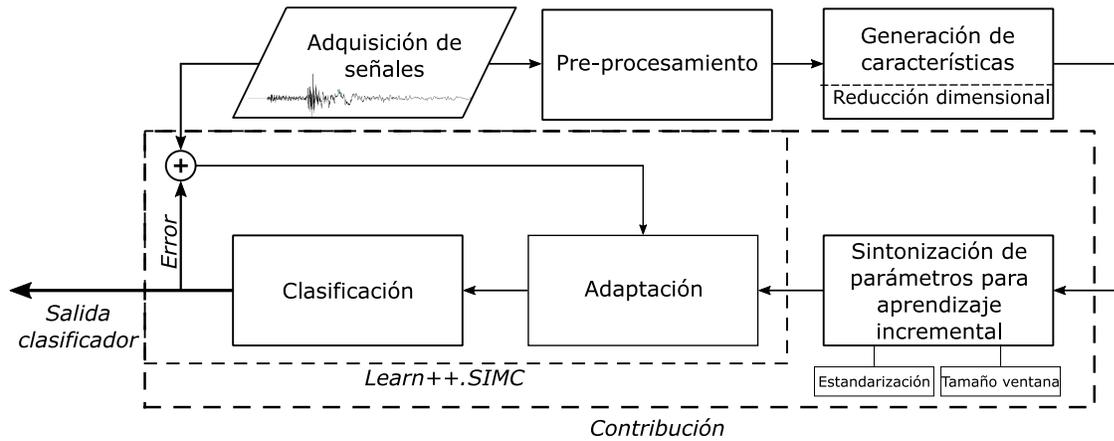


Figura 6-1.: Esquema de clasificación adaptativa de eventos sísmicos usando el algoritmo incremental Learn++.SIMC.

número de sismos en cortos periodos de tiempo). El número limitado de expertos en una situación como ésta implica que un número creciente de eventos sísmicos permanezcan acumulados sin ser procesados ni etiquetados durante días e incluso semanas. Por ello, el supuesto de ausencia de etiquetas verdaderas durante determinados periodos de tiempo, considerado como condición inicial de nuestro planteamiento, se torna muy conveniente y necesario para esta aplicación.

6.5.1. Base de datos y pre-procesamiento

Como se explicó en el Capítulo 5, en el capítulo actual solo se hizo uso de la base de datos del volcán Villarrica, por la razones previamente expuestas. El conjunto de datos utilizado consiste en señales sísmicas adquiridas entre enero de 2010 y abril de 2017 de la red sismológica OVDAS de la estación de referencia, obtenidas con un sismómetro de banda ancha de tres componentes. Los datos se registraron continuamente a una frecuencia de muestreo de 100 muestras por segundo, utilizando un convertidor analógico-digital de 16 bits en un rango dinámico de 80 dB .

Durante la validación, empleamos los registros del componente Z debido a su mayor relación señal-ruido (SNR). Eliminamos además los registros con las siguientes limitaciones: *i*) los datos de la estación de referencia no se distinguían en más de cuatro estaciones sísmicas; *ii*) registros que contienen principalmente ruido sísmico (estación fuera de servicio); y *iii*) datos que tienen un nivel de SNR por debajo de un umbral mínimo (establecido heurísticamente por expertos). Adicionalmente, a todos los registros se aplicó un filtro de paso de banda Butterworth de orden diez dentro del ancho de banda entre 0,5 y 25 Hz .

Como resultado, examinamos 237255 registros de actividad sísmica que se etiquetan de la siguiente manera: 101 eventos pertenecientes a la clase VT, 213655 eventos LP y 23499 eventos TR. La Figura 6-2 muestra el número de eventos registrados consecutivamente cada mes desde enero de 2013 hasta abril de 2017 (marca de tiempo de 52 meses), manteniendo las proporciones de las clases (se toman datos desde 2013 debido al análisis de periodos de estabilidad e inestabilidad

efectuado en el capítulo anterior). La clase VT (amarillo) no se muestra en la figura debido a la menor proporción de eventos de esta naturaleza en comparación con las otras dos clases.

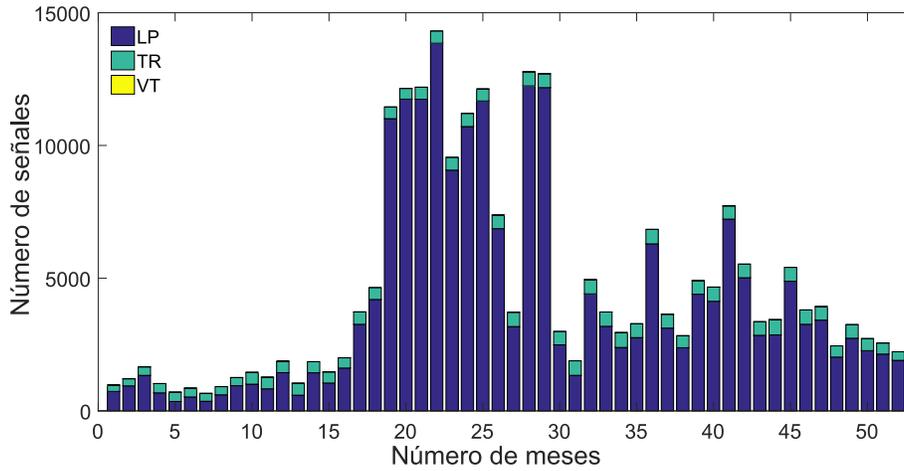


Figura 6-2.: Número de eventos sísmicos ocurridos en orden cronológico.

Ordenamiento de datos

Si bien los experimentos de validación se realizan fuera de línea, los datos se ordenan para preservar el orden cronológico de las instancias, lo que permite una simulación de escenarios en línea. Así, el conjunto de datos se divide en lotes ordenados cronológicamente, según el tiempo de llegada (adquisición) de cada instancia. Los lotes, T^t , están definidos por ventanas de tiempo de tamaño m (sin solapamiento). Vale la pena señalar que no usamos ventanas superpuestas porque impiden la ubicación secuencial de eventos sísmicos en el tiempo y, por lo tanto, una interpretación temporal inconsistente de los cambios de concepto ocurridos.

Para simular una configuración real y en línea, se asigna una marca de tiempo t a cada lote (T^t) así como a cada instancia que lo compone: $T^t = \{(\mathbf{x}_1^t, y_1^t), \dots, (\mathbf{x}_i^t, y_i^t)\}$. De esta manera, cada iteración del algoritmo representa la adquisición de un nuevo lote de datos, simulando que T llega en cada paso de tiempo t . A continuación, se aplica el método de evaluación “Holdout”; es decir, la primera mitad de cada uno de ellos se considera como conjunto de entrenamiento ($\mathbf{x}_{\text{train}}^t$) y los datos restantes como conjunto de prueba ($\mathbf{x}_{\text{test}}^t$).

Extracción y selección de características

De la misma manera como se ejecutó el marco experimental del Capítulo 5, los experimentos de este capítulo se llevaron a cabo empleando el conjunto de 105 características, detalladas en el Capítulo 4. Así mismo, se empleó el algoritmo ReliefF (ver pseudo-código en Anexo B) para hacer la reducción dimensional del espacio de características inicial a uno de 4, con los atributos más relevantes.

6.5.2. Experimentos diseñados

En esta sección, se describen los detalles relacionados al diseño de los experimentos, en los que se exponen las ventajas del aprendizaje incremental para la discriminación de eventos sísmico-volcánicos, haciendo uso de un escenario simulado en línea.

Haciendo referencia al Paso 4 del Algoritmo 1, dispusimos una lista de tres clasificadores representativos como aprendices base, elegidos de acuerdo con la taxonomía propuesta en [Orozco-Alzate et al., 2012]: k -NN, SVM y clasificador normal bayesiano lineal (LDC). Colocamos k -NN en la parte superior de esa lista de clasificadores para priorizarlo debido a su implementación directa, su buen rendimiento de reconocimiento (debido a la no linealidad de sus límites de decisión) y a que, dada su complejidad, se considera independiente del número de clases a evaluar. Dado que, en nuestros experimentos, k -NN nunca cumplió la condición de ser sustituido por otro algoritmo de clasificación como Clasificador Base, todos los resultados informados fueron generados por ese clasificador. De esta manera, damos crédito de los resultados al marco metodológico del enfoque de aprendizaje, más que a la robustez de un clasificador.

Experimentos 1 y 2: Ajuste de parámetros

El primer aspecto a determinar es la estrategia de normalización de datos; la definición de este punto corresponderá al *Experimento 1*. Asumiendo la distribución de datos normal de cada lote, se emplea la normalización Z -score, es decir, $Z = (x_i - \mu)/\sigma$, donde μ es la media de los datos y σ es la desviación estándar. Debido a la variabilidad de la distribución de datos a lo largo del tiempo, se debe utilizar una normalización de los atributos también variable en el tiempo, pero se debe tener presente que esta normalización puede deteriorar severamente el rendimiento del clasificador si el escalamiento no se logra correctamente. Se prueban, entonces, las siguientes estrategias de disposición de datos para la normalización:

1. El cálculo estacionario de μ y σ se realiza en todo el conjunto de datos, tratándolo como una matriz única de características.
2. Asumiendo cada lote t como un sub-conjunto de datos, se calculan μ y σ en la primera mitad (conjunto de entrenamiento $\mathbf{x}_{\text{train}}^t$); el conjunto de prueba $\mathbf{x}_{\text{test}}^t$ (datos complementarios), se normaliza con respecto a los μ y σ previamente calculados.

3. Se considera como $\mathbf{x}_{\text{train}}^t$ el lote que arriba en $t = 1$, y sobre éste se calcula μ y σ ; \mathbf{x}_{test} será cada nuevo lote que arribe posteriormente, y será normalizado con respecto al μ y σ antes calculados.
4. Definiendo $\mathbf{x}_{\text{train}}^t$ y $\mathbf{x}_{\text{test}}^t$ dentro de cada lote t , se calcula μ y σ en cada sub-conjunto y se normaliza con respecto a sus correspondientes parámetros.

El segundo parámetro libre para ajustar es la longitud de las ventanas deslizantes, m . Esta variable determina el tamaño del lote y debe ajustarse para realizar una distinción precisa entre la clase de eventos sísmicos. Para un mejor seguimiento de la evolución del proceso no estacionario, ajustamos el tamaño de la ventana en términos del rango de tiempo (es decir, en semanas) en lugar del número de instancias que es lo comúnmente utilizado, en adelante designada como τ . Como se sugiere en [Bifet and Gavaldà, 2007], ajustamos heurísticamente τ en función de la mejor precisión de clasificación lograda por el algoritmo k -NN. Por lo tanto, se prueban los siguientes valores de longitud: $\tau \in \{2, 4, 6, 8\}$, es decir, $\tau = 4$ significa que cada ventana deslizante contendrá las m instancias correspondientes a 4 semanas de registros de eventos sísmicos. El ajuste de la longitud de la ventana deslizante constituye el *Experimento 2*.

Experimentos 3 y 4: Clasificación adaptativa mediante aprendizaje incremental

Una vez que se seleccionan la mejor estrategia de normalización de datos y la longitud de la ventana, evaluamos el impacto del uso del aprendizaje incremental para identificar eventos sísmicos. Para ello, realizamos los siguientes dos experimentos:

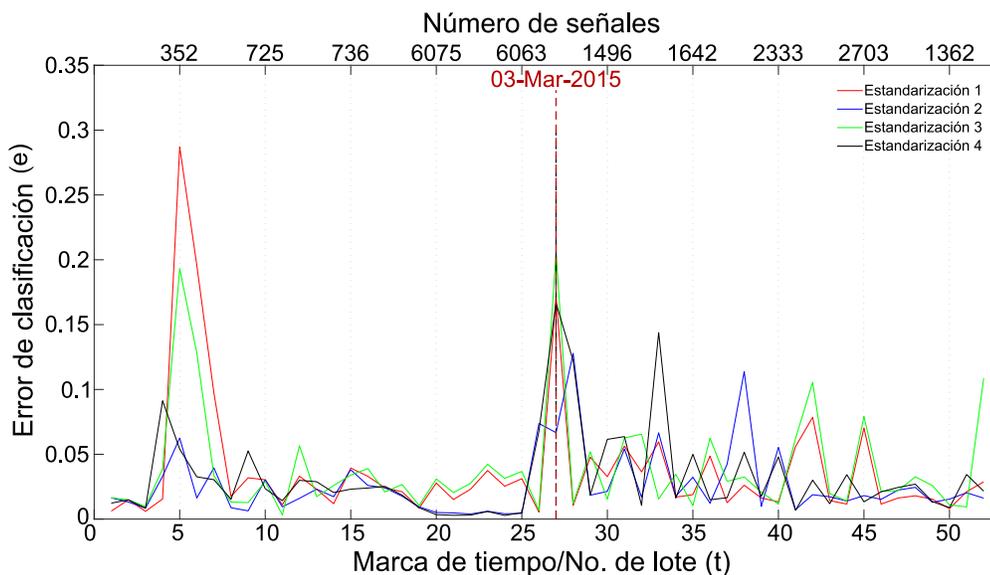
- *Experimento 3*: Se lleva a cabo la comparación entre la estrategia de clasificación adaptativa propuesta y el algoritmo k -NN dentro de un esquema de aprendizaje tradicional (no adaptativo). Para simular una configuración real y en línea, el algoritmo Learn++.SIMC se entrena y se prueba usando directamente el conjunto de datos descrito anteriormente, basado en lotes. En el caso del clasificador k -NN, el entrenamiento se realiza una sola vez, empleando $\mathbf{x}_{\text{train}}^t$ (el lote en el tiempo $t = 1$), mientras que la validación se realiza sucesivamente sobre cada uno de los lotes (en $t \in \{1, 2, \dots\}$).
- *Experimento 4*: Se hace la comparación del enfoque Learn++.SIMC evaluado en dos escenarios: aprendizaje incremental usando un ensamble de clasificadores contra un caso no incremental donde se usa solo un algoritmo de aprendizaje en cada lote. Es decir, empleamos al aprendiz por separado, sin incorporar el clasificador al ensamble. En este escenario, cada nuevo clasificador se entrena usando los datos de ese momento ($t - 1$), mientras que la prueba se realiza en el siguiente lote t para evitar el sobre-entrenamiento que puede ocurrir entre dos lotes vecinos, como es sugerido por Mera et al. [2019].

6.6. Resultados y discusión

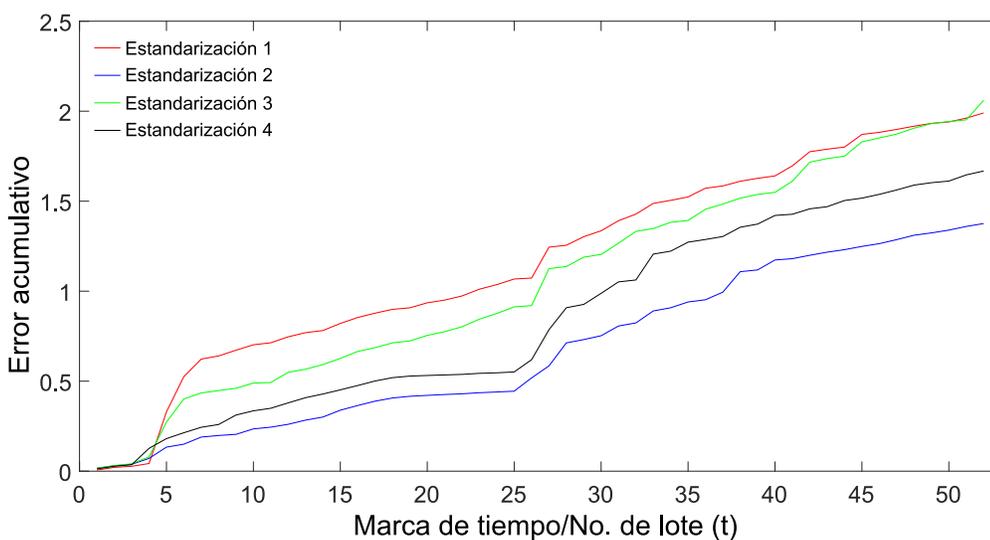
6.6.1. Experimento 1: Elección de la estrategia de normalización

La Figura **6-3** muestra el rendimiento de clasificación logrado por la estrategia de normalización de datos considerada. Para mostrar solo la influencia de cada una de ellas, fijamos la longitud de la ventana deslizante τ en 4 semanas (es decir, un mes según la marca de tiempo del evento sísmico). Además, como la resolución temporal varía en la prueba de cada estrategia, surge la necesidad de realizar el procedimiento de re-muestreo ascendente en tres de cuatro series de datos para alinearlos cronológicamente.

Cada una de las marcas de tiempo utilizadas en las gráficas, generadas en todos los experimentos, representan el número del lote que se está considerando en el tiempo t , luego de dividir todo el período evaluado en T^t lotes (cada uno dependiendo del tamaño definido para las ventanas deslizantes). Para referenciar el mayor cambio abrupto que ocurre dentro del período analizado, hemos resaltado una fecha particular en algunas gráficas, que indica la ubicación temporal del episodio eruptivo más reciente del volcán. Además, dado que cada lote contiene un conjunto de datos que proviene de un rango de tiempo de adquisición, mostramos en el eje x la fecha correspondiente al último evento sísmico para una notación más clara de la temporalidad en relación con cada valor de precisión calculado. El eje horizontal superior muestra el número de datos procesados en cada lote para cada marca de tiempo correspondiente.



(a) Error de clasificación promedio por lote.



(b) Error acumulativo.

Figura 6-3.: Influencia de la estrategia de normalización de datos en el rendimiento de la clasificación.

En este punto, vale la pena mencionar que una discusión detallada de todos los resultados experimentales implica tener un conocimiento *a priori* sobre la dinámica de los datos y, por lo tanto, el comportamiento del volcán. De esta forma, es posible explicar los cambios tanto suaves como abruptos que puede tener una serie de tiempo construida a partir de una estimación. Basándonos en la experiencia de los expertos analistas del OVDAS, se establece la actividad sísmica base para definir aquellas alteraciones en los eventos sísmicos que indican cambios en el comportamiento del volcán.

Este experimento y los siguientes se realizan utilizando un clasificador 3-NN, cuyo número adecuado de vecinos se ha definido en función del mínimo error de clasificación, tras probar los valores de $k \in \{1, 3, 5, 7, 9\}$.

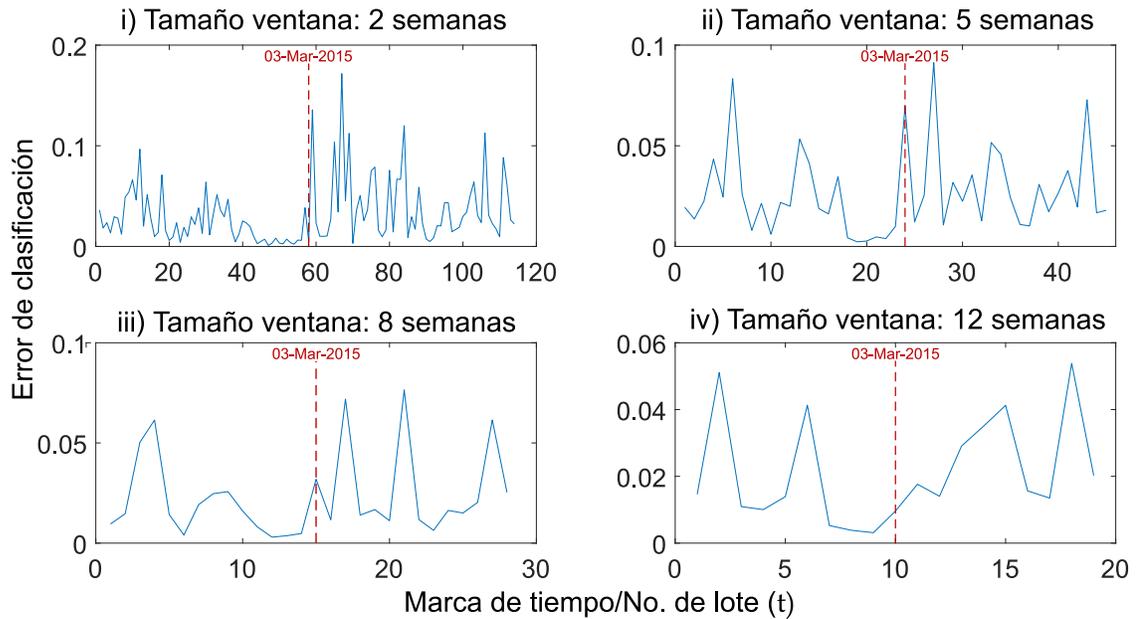
Como se mencionó previamente, lo que se desea evaluar son los beneficios de cada estrategia a través de la minimización del error en cada momento valorando el conocimiento previo que se tiene disponible sobre las alteraciones de la dinámica del volcán. La Figura **6-3a** presenta el error promedio de los 52 lotes estimados dentro del período analizado. Como se puede observar, de manera general, en los errores ilustrados de las 4 estrategias, se puede inferir que la estandarización de datos elegida influye en la precisión de una etapa de clasificación posterior, siendo aún más visible cuando se aplica un enfoque de aprendizaje incremental en el escenario en línea simulado.

Sin embargo, la similitud entre las líneas negras y azules en la Figura **6-3a** no permite identificar la estrategia de estandarización más eficiente. Por esta razón, calculamos la suma acumulativa de cada vector de error, que se muestra en la Figura **6-3b**, mostrando que ahora se puede valorar la contribución total del error a medida que pasa el tiempo. Además, ahora queda claro que la Estandarización 2 (línea azul) supera a las otras estrategias. Este resultado puede ser explicado modelando cada lote como un subconjunto de datos que llega en el momento t y tiene una distribución distinta de los datos que llegan en el momento $t + 1$. Entonces, la estimación de los parámetros de estandarización, de forma independiente, implica un mejor ajuste de la escala de datos en el tiempo t para cada subconjunto.

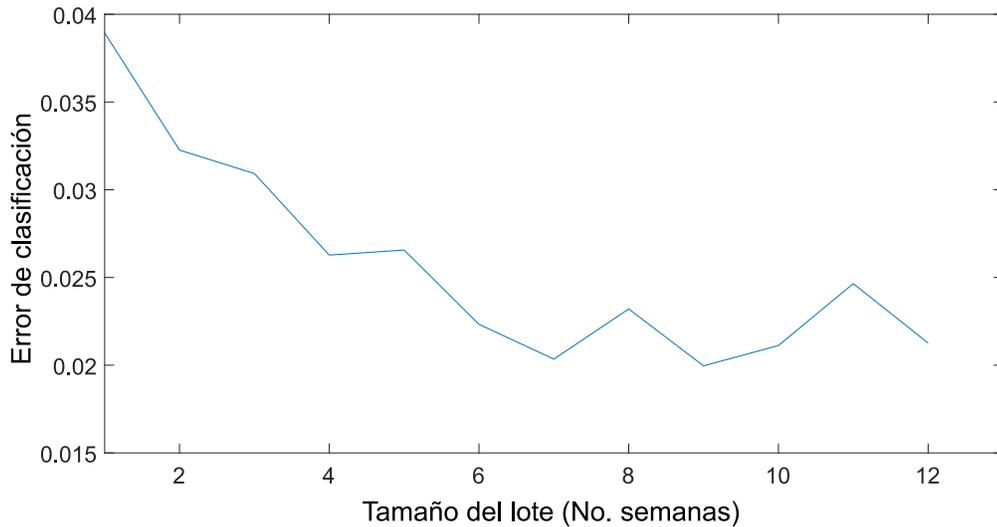
Por otro lado, la línea azul está en consonancia con la información histórica *a priori* sobre el volcán, presentando fluctuaciones menores del error de clasificación e desde enero de 2013 hasta enero de 2015 (estas fluctuaciones se interpretan como cambios suaves de dinámica volcánica). A partir de esa fecha, observamos una fuerte pendiente con un pico alrededor de marzo de 2015, cuando ocurrió el fenómeno eruptivo más energético de todo el período evaluado (3 de marzo de 2015). A partir de ese momento, la gráfica de e refleja unas fluctuaciones descendentes sostenidas, evidenciando el estado de inestabilidad en el que permaneció el sistema volcánico durante varios meses hasta que volvió nuevamente a su comportamiento base.

6.6.2. Experimento 2: Ajuste de la longitud de la ventana de datos

En primera instancia, vale la pena recordar las siguientes premisas para la interpretación de los resultados, como lo sugiere [Kuncheva and Faithfull \[2014\]](#): *i*) la detección de cambios depende de la longitud de la ventana: cuanto más grande es la ventana, menos sensible a los cambios, y *ii*) el detrimento del desempeño del clasificador es susceptible de ocurrir ante cambios, los cuales son más notorios en los datos. Por lo tanto, los cambios en la distribución de datos deben estar razonablemente correlacionados con el error de clasificación.



(a) Error promedio bajo diferentes resoluciones de tiempo.



(b) Error medio de cada serie de tiempo con diferente resolución temporal.

Figura 6-4.: Selección de longitud de la ventana deslizante.

Se ponen a prueba doce períodos de tiempo diferentes, que van de 1 a 12 semanas. Como se muestra en la Figura 6-4a, un tamaño de ventana más grande reduce progresivamente el error del clasificador, mientras que su rendimiento tiende a estabilizarse (línea menos fluctuante) como consecuencia de una resolución temporal más baja. Sin embargo, a medida que aumenta el tamaño de la ventana, se pierden varios detalles del proceso no estacionario analizado y, por lo tanto, los cambios abruptos son menos detectables (se puede apreciar comparando la gráficas *i)* contra la *iv)* en la Figura 6-4a). Esta conexión entre la longitud de la ventana y el error cometido se ve

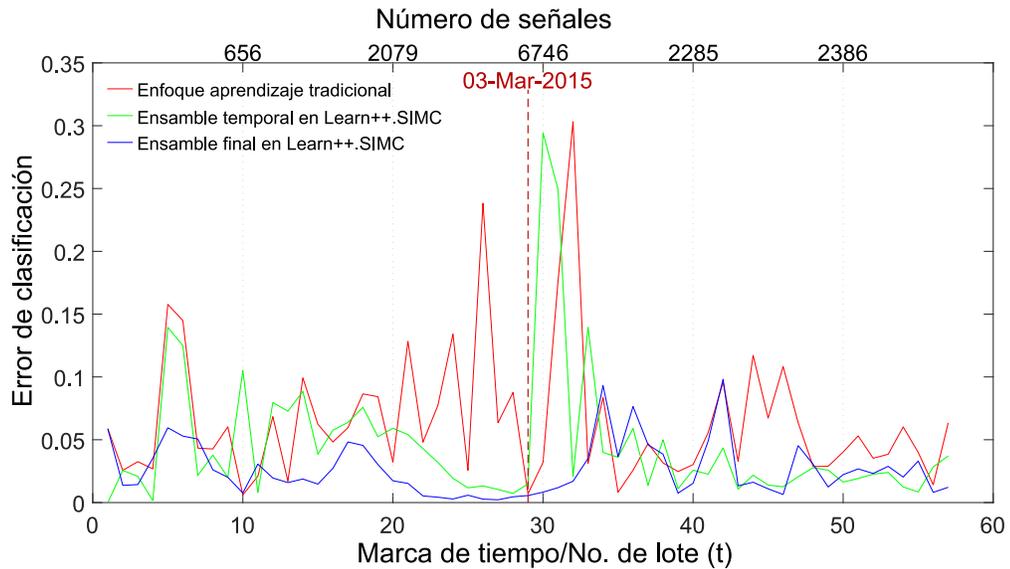
claramente en la Figura 6-4b, donde se mantiene una dependencia monótonamente decreciente hasta el lote 7; del lote 8 en adelante, hay ausencia de tal relación.

En consecuencia, podemos inferir que un tamaño de ventana apropiado mantiene un equilibrio entre la minimización de errores y la sensibilidad de detección de cambios. Aunque el tamaño del lote de 9 semanas alcanza el error más bajo (1,19%), el gráfico muestra que se consigue un error suficientemente bajo para ventanas mayores o iguales a 4 semanas (con una diferencia del 5% entre ambos casos). Por el contrario, se mejora notablemente la resolución temporal, consiguiendo la detección de cambios bruscos generados en pequeños intervalos de tiempo. Por consiguiente, hemos fijado el tamaño de la ventana a 4 semanas en los experimentos posteriores.

6.6.3. Experimento 3: Comparación de estrategia adaptativa vs. aprendizaje tradicional

En este experimento se estima la precisión del clasificador 3-NN desempeñándose dentro de un enfoque de aprendizaje incremental, utilizando nuestro algoritmo Learn++.SIMC. Dicho rendimiento se compara con el obtenido con el mismo clasificador actuando bajo un esquema de aprendizaje tradicional, como se presenta en la Figura 6-5. Como se observa en la Figura 6-5a, las estrategias incrementales manejan mejor los cambios en un proceso no estacionario que un clasificador tradicional (no incremental) (línea azul versus línea roja). Este hecho es especialmente notorio alrededor de la marca de tiempo 30, cuando ocurrió el episodio eruptivo del volcán.

Las variaciones en el desempeño del clasificador adaptativo son inevitables, considerando que datos drásticamente diferentes se unen en una sola serie de tiempo. Sin embargo, incluso en esas circunstancias, nuestra propuesta logra una reducción de error de hasta 0,28 cuando ocurre el cambio abrupto (justo después de la erupción). Esta mayor reducción en el error corresponde al caso en el que nuestro algoritmo obtiene un error de 0,01696 mientras que, por el contrario, el enfoque de aprendizaje tradicional obtuvo un desempeño pobre, obteniendo un error de 0,3033 (ver Figura 6-5a nuevamente). Además, el gráfico muestra cómo el enfoque propuesto intenta mantener un rendimiento estable frente a cambios posteriores. Esta capacidad resulta de las estrategias incrementales basadas en ensambles que, en cada marca de tiempo, agregan un nuevo aprendiz a la base de conocimiento; cada miembro del ensamble ha aprendido la dinámica de los datos provenientes de un lote procesado, logrando así una mayor capacidad de generalización para clasificar los datos que llegan en tiempos posteriores. Por el contrario, un clasificador entrenado bajo un enfoque tradicional no es capaz de anticipar cambios en la distribución de datos y, por lo tanto, no podría responder de manera efectiva ante ellos porque ha sido entrenado con una sola porción de los datos provenientes del pasado (es decir, aprende una dinámica específica de datos), y no puede ampliar su base de conocimientos en el futuro.



(a) Error de clasificación promedio por lote.

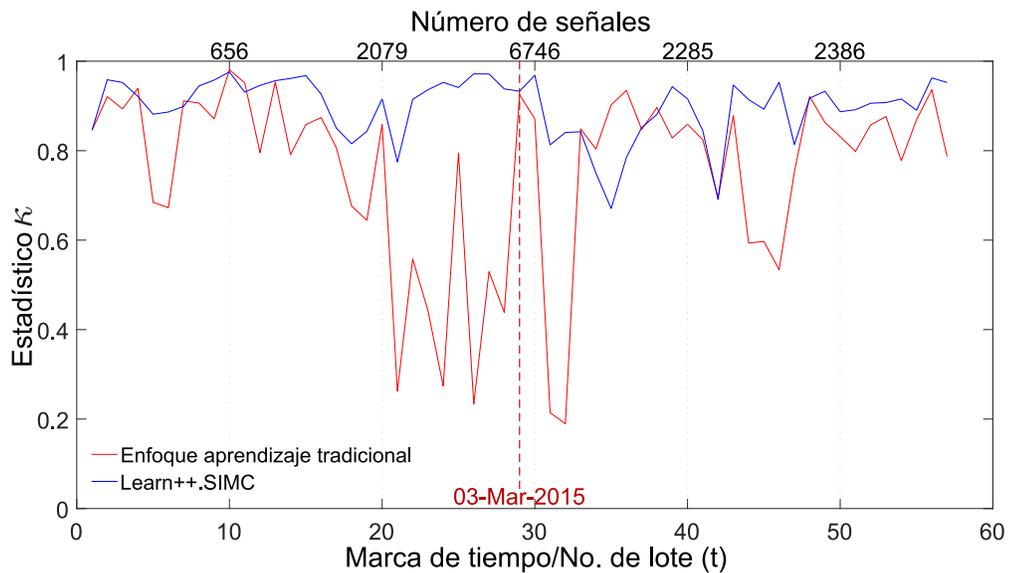
(b) Ventana deslizante del estadístico κ .

Figura 6-5.: Comparación del rendimiento del clasificador 3-NN entrenado y probado dentro de un marco de aprendizaje incremental contra el mismo clasificador que trabaja bajo un enfoque de aprendizaje tradicional.

Por su parte, la Figura 6-5b compara el comportamiento de ambas estrategias de clasificación utilizando el estadístico κ , que indica que la predicción del clasificador tradicional se vuelve comparable a la de un “adivinator aleatorio”, comenzando en un momento específico. Además, podemos sugerir que el estadístico κ también evalúa la consistencia o estabilidad de los datos. El gráfico muestra una variación sustancial (ver línea roja) desde la marca de tiempo 20, que corresponde a una fecha aproximada a principios de junio de 2014. Un análisis detallado de la relación entre el

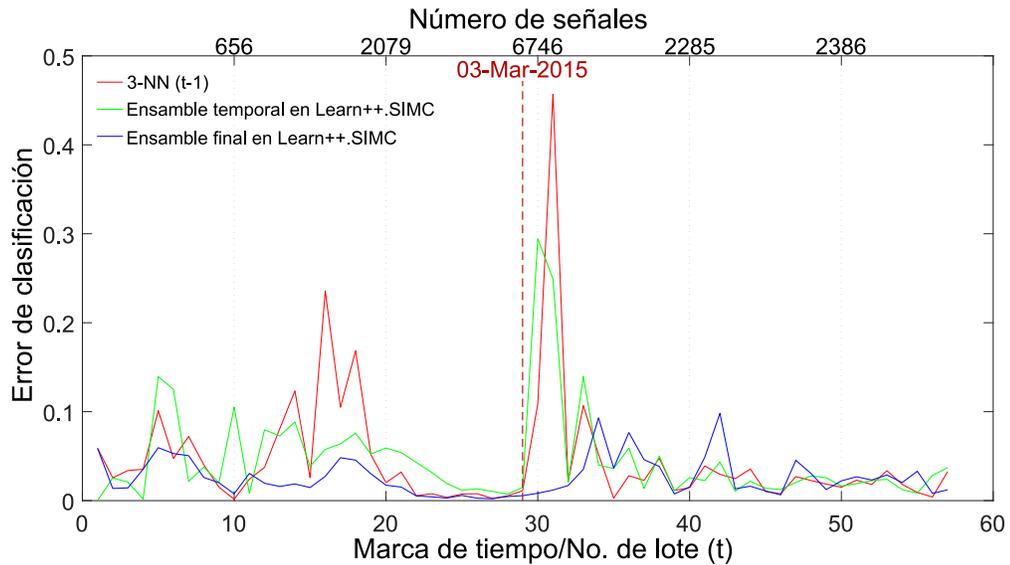
estadístico κ y los datos históricos muestra que, a partir de junio, hubo un aumento progresivo de la sismicidad tipo LP que continuó durante los meses posteriores hasta la erupción. Este hecho, que ha sido confirmado por el panel de expertos del OVDAS, explica el cambio de concepto que puede no ser bien contrarrestado por la estrategia de aprendizaje tradicional pero que, por el contrario, es mejor manejada por el ensamble de clasificadores que aprenden incrementalmente.

Adicionalmente, la Figura 6-5a también muestra el error del ensamble temporal, que indica un mejor rendimiento en contraste con el clasificador 3-NN entrenado tradicionalmente. Como era de esperarse, tiene un rendimiento más bajo que el ensamble total generado al final de la ejecución del Learn++.SIMC. De esta manera, se confirma que la metodología incremental es una mejor estrategia de clasificación (más precisa) que la basada en el aprendizaje tradicional, incluso cuando las etiquetas verdaderas no están disponibles durante un tiempo determinado. Una vez que dichas etiquetas están disponibles, los resultados son aún mejores.

6.6.4. Experimento 4:

La Figura 6-6 muestra el error de clasificación y el estadístico κ tanto para nuestra estrategia basada en ensamble incremental como para el clasificador adaptativo único. El diagrama mostrado en la Figura 6-6a revela que, aunque el clasificador adaptativo único tiene un rendimiento apropiado, Learn++.SIMC saca ventaja sobre el primero, ya que este último puede rastrear de manera más efectiva los cambios abruptos (por ejemplo, el presentado alrededor de la marca de tiempo 30) así como los cambios suaves, como los que ocurren en periodos posteriores al episodio eruptivo. Este resultado confirma que una cuidadosa selección y ponderación de los aprendices previos es ciertamente beneficiosa al clasificar nuevos datos, como se puede confirmar a través del estadístico κ que se muestra en la Figura 6-6b, donde un comportamiento aleatorio del único clasificador adaptativo (línea roja) se observa ante cambios abruptos, en contraste con la regularidad en las predicciones que exhibe la línea azul generada a partir de la estrategia incremental propuesta. En este sentido, se está asegurando el uso de información del pasado suficientemente relevante. Y así, la capacidad de generalización del clasificador se ve reforzada al agregar un nuevo miembro del ensamble, que ha aprendido la dinámica de los datos actuales, generando un clasificador aún más robusto.

Asimismo, el desempeño del ensamble temporal (ver Figura 6-6a, línea verde) apoya la premisa explicada anteriormente. Mediante el uso adecuado de los clasificadores seleccionados y ponderados del pasado, el ensamble temporal proporciona una mayor precisión que la clasificación adaptativa única, aunque todavía no supera los resultados de la estrategia del ensamble total. Como resultado, planteamos la hipótesis de que durante los periodos que preceden a la erupción (el cambio abrupto), pueden tener lugar algunas etapas de inestabilidad del sistema volcánico (que presumiblemente pueden considerarse ambientes no recurrentes). Este hecho requiere conocimiento sobre la dinámica de los datos actuales. Es decir, si bien el conocimiento previo del etiquetamiento de los datos actuales es relevante, no es determinante para mantener un desempeño de clasificación consistente en el tiempo. Por el contrario, tras el episodio eruptivo, las dos estrategias de clasificación comparadas tienen un comportamiento similar. Esto puede estar ligado a la existencia de conceptos recurrentes



(a) Error de clasificación promedio por lote.

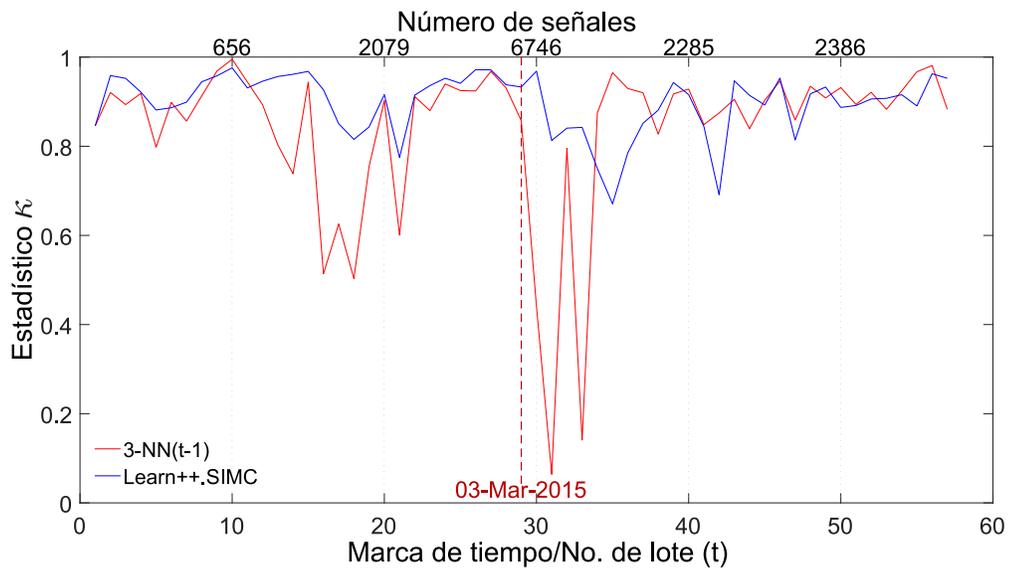
(b) Ventana deslizante del estadístico κ .

Figura 6-6.: Comparación de rendimiento del clasificador 3-NN entrenado y probado dentro de un marco de aprendizaje incremental contra el mismo clasificador que es adaptativo pero no incremental.

(quizás por la tendencia del sistema volcánico a retomar su línea base de estabilidad), que son manejados por los clasificadores del ensamble temporal, y por tanto, por el ensamble completo.

6.7. Resumen del capítulo

Una metodología de aprendizaje incremental basada en un ensamble de clasificadores se ha presentado como una alternativa costo-eficiente para identificar eventos sísmico-volcánicos generados en un contexto evolutivo como el volcánico. El cambio del concepto (que es inherente a este contexto) se maneja seleccionando y ponderando dinámicamente a los clasificadores previos que se agregan a un ensamble capaz de lidiar con estados recurrentes y clasificar sismos volcánicos mientras que las etiquetas verdaderas aún no están disponibles.

Los resultados experimentales muestran la capacidad del enfoque propuesto para detectar y contrarrestar cambios suaves y abruptos durante una tarea de clasificación. En general, las evaluaciones muestran que nuestra propuesta toma ventaja sobre una metodología de aprendizaje convencional al mantener una precisión más estable y reducir los picos de error. Asimismo, en comparación con otro enfoque de aprendizaje adaptativo, nuestro algoritmo es capaz de mantener la estabilidad de la precisión, logrando una reducción de error de hasta 0,28 cuando enfrenta cambios abruptos. Por otro lado, el estadístico κ ha mostrado la consistencia de los datos históricos conforme a la precisión, lo que explica el comportamiento aleatorio de los otros clasificadores evaluados durante periodos en los que ocurren cambios abruptos. La mejora en el desempeño es una consecuencia de la adición selectiva de aprendices previos ponderados al ensamble, lo cual es muy conveniente en contextos recurrentes, mientras que la base de conocimientos se amplía con nuevos clasificadores que identifican e integran conceptos recientes a partir de datos actuales.

Como trabajo futuro, está abierta la posibilidad de probar nuestra metodología con datos de otros volcanes. Asimismo, el uso de clasificadores mucho más robustos que k -NN es una alternativa a explorar, ya que potencialmente podrían mejorar el rendimiento de la estrategia de clasificación adaptativa e incremental propuesta.

Parte III.

Conclusiones, Anexos y Bibliografía

7. Conclusiones y trabajo futuro

En el presente capítulo se plantean las conclusiones finales del trabajo investigativo realizado en esta tesis, y se proponen tareas y desarrollos que podrían llevarse a cabo como trabajos futuros relacionados al aprendizaje automático de sismos volcánicos, con el fin de continuar generando avances relevantes y conocimiento aplicado en esta área en particular.

7.1. Conclusiones

En esta tesis se llevó a cabo un trabajo investigativo donde se plantea y discute el problema del cambio del concepto, el cual se presumía inherente a un entorno cambiante como el volcánico, y que inevitablemente se involucra en el desempeño de los sistemas de clasificación automática entrenados bajo enfoques de aprendizaje supervisado tradicionales. La rigurosa revisión del estado del arte realizada hizo evidente la necesidad de disponer de sistemas automáticos de clasificación que satisfagan las “condiciones realistas” del problema de la clasificación de sismos de origen volcánico, como requerimiento esencial en la vigilancia volcánica y la predicción de erupciones. Por este motivo, en esta tesis se propuso y desarrolló una metodología de reconocimiento de patrones a partir de registros de eventos volcánicos, que considera la adaptación de un modelo basado en aprendizaje incremental que puede enfrentar cambios suaves y abruptos subyacentes a la sismicidad volcánica a lo largo de periodos de tiempo extensos.

En primera instancia, se hizo un análisis sobre la necesidad de generar una adecuada representación de patrones para lograr un rendimiento óptimo en un sistema de reconocimiento automático para la identificación de sismos de origen volcánico. Para el caso de las señales sismo-volcánicas, se encontró que se han propuesto un número considerable de representaciones, sin embargo, no se había dado una comparación directa entre las diversas formas de caracterización planteadas, lo cual se logró hacer en este trabajo y que constituye un aporte de esta tesis. Se presentó una comparación de cuatro representaciones basadas principalmente en características espectrales y morfológicas, de la cual se concluye que la mejor representación de este tipo de señales está en el dominio tiempo-frecuencia y es la basada en sub-bandas de espectrales (espectrogramas promediados). Por otra parte, la aplicación del marco experimental en dos bases de datos reales provenientes de dos volcanes diferentes, mostró que no se puede hacer una generalización sobre cuáles son los atributos específicos con los cuales representar una señal sismo-volcánica; necesariamente se debe hacer un estudio particular para cada volcán y de un compendio amplio de descriptores —mediante algoritmos de selección de

características— para determinar cuáles son las idóneas. Esto se explica en las grandes variaciones que se presentan de un volcán a otro por factores como su geología, diferente ubicación de cámaras magmáticas, distintas fuentes sismogénicas, entre otros; factores que por cierto, lo configuran como un contexto evolutivo con cambios subyacentes, donde los cambios de concepto son inherentes.

Por otra parte, el presente trabajo investigativo mostró la existencia de cambios de concepto que permanecen subyacentes a los registros sísmicos obtenidos durante periodos de tiempo prolongados. En esta tesis se demostró cómo, dentro de un entorno volcánico, un modelo de aprendizaje deteriora su desempeño (incrementando su tasa de error) cuando el volcán se enfrenta a una dinámica diferente, como ocurre en fases de crisis eruptiva. Además, se demostró mediante dos métodos no supervisados (uno de ellos propuesto por nosotros) que, al establecer umbrales adecuados, se pueden identificar cambios de conceptos en ciertos períodos que provocan alteraciones en el contexto. El problema del cambio de concepto ha sido reconocido en diferentes comunidades académicas y estudiado en diferentes dominios de aplicación, sin embargo, en el área de la sismología volcánica el asunto aún está abierto a profundizar su estudio.

Uno de los principales aportes de esta tesis es el desarrollo de una metodología de clasificación adaptativa basada en aprendizaje incremental, creada a partir de un ensamble de clasificadores, la cual se ha presentado como una alternativa costo-eficiente para identificar eventos sísmico-volcánicos generados en un contexto evolutivo como el volcánico. Nuestra propuesta configura dinámicamente un ensamble que se robustece a partir de clasificadores temporales ponderados que logra manejar estados recurrentes y que puede operar —bajo un desempeño estable— durante el tiempo que no estén disponible las etiquetas verdaderas de clase. Se logró demostrar experimentalmente la capacidad del enfoque propuesto para detectar y contrarrestar cambios suaves y abruptos durante una tarea de clasificación, mostrando que nuestra propuesta toma ventaja sobre una metodología de clasificación basada en aprendizaje convencional, al mantener una precisión más estable y reducir picos de error.

Además de los factores geofísicos que pueden afectar la morfología espectral y de forma de onda de los registros que entrenan un modelo de aprendizaje (cambio de sensores, instalación de nuevas estaciones sísmicas, entre otros), no se puede olvidar que las fuentes sismogénicas también pueden ejercer algún tipo de efecto en el desempeño de un sistema de clasificación automática de sismos. En este trabajo no fue posible considerar este factor debido a la estadística pobre que proveían las bases de datos al discriminar los registros por las diferentes fuentes activas al momento de su adquisición, sin embargo, no debe descartarse que el deterioro en la clasificación entre algunos tipos de clases resalta el problema de la activación concurrente y la separación poco clara de fuentes distintivas de las que provienen las señales.

7.2. Trabajo futuro

Una perspectiva a futuro es el uso de algoritmos de aprendizaje semisupervisados o no supervisados para minimizar la dependencia hacia un conjunto de datos etiquetados, lo que hoy limita el uso

de modelos supervisados. El uso de modelos de aprendizaje automático también se puede utilizar para procesar señales continuas en lugar de eventos discretos.

Recientes investigaciones en el campo del cambio del concepto se enfocan en problemas más desafiantes, como por ejemplo, detectar con precisión el cambio del concepto en conjuntos de datos no estructurados y ruidosos, comprender cuantitativamente el cambio del concepto de una manera explicable, y reaccionar eficazmente al cambio adaptando el conocimiento relacionado. Todas estas nuevas perspectivas podrían ser aplicadas al dominio de la clasificación automática de sismos volcánicos.

Dado que la metodología propuesta contempla, en una de sus etapas, la adición y remoción de algoritmos de clasificación de manera práctica, se mantiene abierta la posibilidad de probar con clasificadores mucho más robustos que el k -NN, de tal manera que un clasificador más versátil, operando dentro de un método adaptativo e incremental eficaz como el planteado, potencialice su desempeño y se logren aún mejores resultados. Una alternativa, es experimentar con las redes neuronales líquidas [Dhar, 2023], una estrategia recientemente explorada en ML que, a diferencia de las redes neuronales tradicionales (que fijan sus parámetros tras la etapa de entrenamiento), son capaces de seguir aprendiendo aún después de su entrenamiento, dado que sus parámetros se adaptan a nueva información o entorno de manera continua.

A. Algoritmo STA/LTA

El algoritmo STA/LTA, cuya sigla abrevia su nombre en inglés *short-time average/long-time average*, es uno de los algoritmos de activación más ampliamente usados en la automatización del proceso de detección de sismos. También es comúnmente empleado en software de procesamiento de redes sísmicas de movimiento débil, al igual que en sistemas sísmicos portátiles, aunque también se usa en aplicaciones de movimiento fuerte. Al mejorar la detección de terremotos débiles, el uso de este algoritmo disminuye el número de detecciones falsas provocadas por el ruido sísmico, minimizando así el trabajo de los analistas.

En términos generales, el algoritmo STA/LTA, originalmente propuesto por [Allen \[1978\]](#), calcula de manera continua el promedio de la amplitud absoluta de una señal sísmica en dos ventanas de tiempo móviles consecutivas. La ventana de tiempo corto (STA) representa el promedio actual de una duración corta durante la cual podría ocurrir un evento, y es sensible a los eventos sísmicos. Por su parte, la ventana de largo tiempo (LTA) proporciona información sobre la amplitud temporal del ruido sísmico; ésta representa el promedio previo de mayor duración para evaluar el ruido sísmico. Cuando la proporción de ambos excede un valor preestablecido, entonces se “declara” un evento y se procede a la extracción de éste para ser registrado en un archivo o para los fines pertinentes para los que se ha aplicado el STA/LTA. La captura exitosa de eventos sísmicos dependerá de la configuración adecuada de los parámetros de activación (para ampliar información de este algoritmo, ver [Trnkoczy \[2009\]](#); [Rodríguez \[2011\]](#)).

En la literatura se conocen otros algoritmos de activación más sofisticados [[Dai and MacBeth, 1995](#); [Di Stefano et al., 2006](#); [Lomax et al., 2012](#); [Wang et al., 2019](#); [Wu et al., 2022](#)], pero no suelen ser utilizados de manera masiva en los registradores de datos sísmicos del mercado ni en observatorios sismológicos/vulcanológicos. Sólo algunos de ellos se emplean en los paquetes de software en tiempo real disponibles en la red. Cuando están en manos de un experto, pueden mejorar significativamente la relación eventos/falsos desencadenantes, particularmente para un tipo determinado de eventos sísmicos. Sin embargo, la complejidad en el ajuste de los parámetros operativos con señales reales y las condiciones de ruido sísmico ha generado dificultad en su manejo y permanece sujeto a errores en la práctica. Esta es probablemente la principal razón por la que el algoritmo de activación STA/LTA continua siendo uno de los más populares.

El algoritmo STA/LTA básicamente se fundamenta en la aplicación de las siguientes ecuaciones:

$$STA(i) = \frac{1}{ns} \sum_{j=i-ns}^i s_j^2$$

$$LTA(i) = \frac{1}{nl} \sum_{j=i-nl}^i s_j^2 \quad (A-1)$$

$$STA/LTA = \frac{STA(i)}{LTA(i)}$$

Como se indica en la ecuación A-1, inicialmente se calcula la amplitud absoluta de las muestras de la señal entrante; luego, se calcula el promedio de amplitudes absolutas en ambas ventanas; y posteriormente, se calcula una relación de ambos valores (relación STA/LTA). Esta relación se compara continuamente con un valor de umbral seleccionado por el usuario, el cual se denomina *nivel de umbral de activación de STA/LTA*. Si la relación excede este umbral, se declara un activador de canal (en el caso de registradores sísmicos, que es la aplicación usual de este algoritmo). Un canal activado no necesariamente significa que un registrador o red sísmica deba iniciar a registrar señales sísmicas; la mayoría de estos dispositivos cuentan con un mecanismo de “votación de activación” que define cuántos y qué canales deben estar en estado *activado* antes de que el instrumento o la red realmente comience a registrar datos.

Una vez que la señal sísmica se atenúa gradualmente, el canal se desactiva. Esto sucede cuando la relación STA/LTA actual cae por debajo de otro parámetro denominado: *el nivel de umbral de desactivación de STA/LTA*. Por supuesto, el nivel del umbral de desactivación de STA/LTA debe ser inferior (o rara vez igual) que el nivel de umbral de activación. Además de estos dos parámetros, las redes sísmicas y los registradores usualmente requiere datos previos (PEM) y posteriores (PET) al evento por lo que se crean dos parámetros más a considerar. Estos cuatro criterios son seleccionados por el usuario, lo que permite la máxima flexibilidad de operación y el uso más eficiente del espacio de almacenamiento disponible.

B. Algoritmo ReliefF

ReliefF (propuesto por [Kononenko \[1994\]](#)) es un algoritmo de selección de características que pertenece a una familia de algoritmos originada a partir de su primera versión denominada Relief [[Kira and Rendell, 1992](#)], la cual implementa métodos estadísticos para encontrar los atributos de mejor calidad, evitando al máximo las búsquedas heurísticas. En términos generales, los algoritmos Relief son eficientes en la estimación de atributos; son especialmente buenos en la detección de dependencias entre características y controlando la fuerte interacción que pueda haber entre ellas. Aunque su uso común se ha enfocado a la selección de características, los algoritmos Relief han sido exitosamente aplicados en una variedad de entornos como: la selección de divisiones en la fase de construcción de árboles de decisiones, la guía en la inducción constructiva en el aprendizaje de árboles de regresión, servir como método de ponderación de atributos, la programación lógica inductiva, entre otros (ver [[Robnik-Šikonja and Kononenko, 2003](#)] para más detalles de esta familia de algoritmos).

A continuación se define brevemente el algoritmo ReliefF y se describe el pseudo-código mostrado en el Algoritmo 2. La idea básica y común entre los algoritmos Relief es estimar la calidad de los atributos de acuerdo a qué tan bien distinguen entre instancias o ejemplos cercanos. Para tal fin, en la versión ReliefF se selecciona aleatoriamente una instancia R_i (línea 3); posteriormente, se buscan sus k vecinos más cercanos de la misma clase, denotados como H_j (línea 4), y de igual forma, se deben encontrar los k vecinos más cercanos de cada una de las diferentes clases, que se llamarán “errores más cercanos” y se denotarán como $M_j(C)$ (primer ciclo *for*, líneas 5 y 6). Se actualiza la estimación de calidad $W[A]$ para todos los atributos A dependiendo de los valores para R_i , los aciertos H_j y errores $M_j(C)$ (segundo ciclo *for*, líneas 7, 8 y subsiguiente). Este proceso se repite α veces, indicando la cantidad total de atributos a evaluar.

La fórmula de actualización es similar a la de la versión Relief, exceptuando que se promedia la contribución de todos los aciertos y todos los errores. La contribución para cada clase de errores se pondera con la probabilidad *a priori* de dicha clase $P(C)$, la cual es estimada a partir del conjunto de entrenamiento. Dado que el propósito es que las contribuciones de los aciertos y errores en cada iteración sean $[0, 1]$, al igual que simétricas, es necesario asegurar que la suma de los pesos de las probabilidades de los errores sea igual a 1. Dado que la clase de los aciertos está ausente en la suma, se debe dividir cada peso de probabilidad por el factor $1 - P(\text{class}(R_i))$ (que representa la suma de probabilidades para las clases erradas).

Algoritmo 2: Algoritmo RealiefF

Entrada: Un vector de atributos y de clase para cada instancia

Salida : Vector de pesos W de la calidad de los atributos

```

1 Se inicializa el vector de pesos  $W[A] = 0$ 
2 for  $i = 1, \dots, m$  do
3   Se selecciona aleatoriamente una instancia  $R_i$ ;
4   Se encuentran los  $k$  vecinos más cercanos a  $H_j$ ;
5   for cada clase  $C \neq \text{class}(R_i)$  do
6     Se encuentran los errores más cercanos para cada clase:  $M_j(C)$ 
7   for  $A = 1, \dots, \alpha$  do
8      $W[A] = W[A] - \sum_{j=1}^k \text{diff}(A, R_i, H_j) / (m \cdot k) +$ 
        $\sum_{C \neq \text{class}(R_i)} \left[ \frac{P(C)}{1 - P(\text{class}(R_i))} \sum_{j=1}^k \text{diff}(A, R_i, M_j(C)) \right] / (m \cdot k)$ 

```

Todo el proceso se repite m veces, o cual representa el número total de ejemplos; no obstante, este parámetro también podría ser definido por el usuario. La selección de k aciertos y errores es la diferencia básica con Relief; ésto garantiza una mayor solidez del algoritmo con respecto al ruido. Además, la versión ReliefF sirve para problemas multiclase (contrarestando la limitante biclase que tenía la versión original del algoritmo). El parámetro k , definido por el usuario, controla la localidad de las estimaciones. Para la mayoría de los propósitos se puede establecer con seguridad en 10 [Kononenko, 1994].

C. Algoritmo Learn++

Learn++ es el algoritmo base que dio origen a una familia de algoritmos (conocida bajo este mismo nombre) que se caracteriza por ser un ensamble de clasificadores que se entrenan de forma incremental (sin acceso a datos anteriores) en lotes de datos entrantes y se combinan con alguna regla de votación mayoritaria ponderada; ésta es la propiedad común entre todos los algoritmos que conforman la familia de algoritmos Learn++. Las principales características distintivas entre los miembros de esta familia de algoritmos son: 1) la regla de actualización de la distribución para elegir datos que entrenarán a los posteriores miembros del ensamble, y 2) el mecanismo para determinar los pesos de votación.

La evolución de esta familia de algoritmos se da de la siguiente manera (ver [Elwell and Polikar, 2011] para detalles): la versión original del Learn++ es un algoritmo similar a AdaBoost [Ying et al., 2013], mediante el cual se aprende a partir de una distribución estacionaria, cuyos datos se adquieren de forma incremental en forma de lotes (*batches*). Después, surgió Learn++.NC, desarrollado para aprender nuevas clases (de ahí el acrónimo en su nombre, “*New Clase*” - *NC*), a partir de nuevos datos provenientes de clases existentes que permanecían estacionarias. Learn++.NC emplea un mecanismo de consulta y votación ponderado dinámicamente para determinar qué clasificadores deberían o no votar por una instancia determinada en función del (des)acuerdo entre clasificadores entrenados con diferentes clases. En la siguiente versión del algoritmo, denominado Learn++.MF, los miembros del ensamble se entrenan con diferentes subconjuntos de características, de tal forma que las características faltantes (“*Missing Features*” - *MF*) se pueden acomodar combinando miembros del ensamble entrenados con las características disponibles actualmente. Si bien las anteriores versiones del algoritmo Learn++ realizan algún tipo de aprendizaje incremental, ninguno de ellos aprende a partir de un entorno no estacionario, y Learn++.NSE (“*NonStationary Environment*” - *NSE*) se desarrolló específicamente para satisfacer esta necesidad. Finalmente, inspirados en la versión NSE, se crea el algoritmo Learn++.MIL (“*Multiple Instance Learning*” - *MIL*) [Mera et al., 2019], que es el punto de partida para crear el algoritmo propuesto en esta tesis: Learn++.SIMC.

Para ilustrar el fundamento de esta familia de algoritmos, a continuación se detalla la versión original de Learn++ (ver Algoritmo 3). Como entradas del algoritmo se requiere *i*) una secuencia de m instancias entrenadas x_i con su correspondiente etiqueta verdadera y_i ; *ii*) un algoritmo de clasificación débil denominado **WeakLearn** que configura un clasificador base (puede ser cualquier clasificador supervisado); y *iii*) un entero T_k que especifica el número de clasificadores (hipótesis) que componen el ensamble. El algoritmo parte desde la inicialización de la distribución de pesos de acuerdo con los conjuntos de entrenamiento TR_t y de prueba TE_t que se conforman en la t^{th}

Algoritmo 3: Algoritmo Learn++

Entrada: Para cada base de datos tomada \mathcal{D}_k , $k = 1, 2, \dots, K$:

- ▶ Secuencia de m ejemplos de entrenamiento $S = [(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)]$
- ▶ Algoritmo de aprendizaje débil **WeakLearn**
- ▶ $T_k \in \mathbb{Z}$ especificando el número de hipótesis.

Salida : Hipótesis final H_{final}

```

1 for  $k = 1, 2, \dots, K$  do
2   Se inicializa  $w_1(1) = D_1(1) = \frac{1}{m}$ ,  $\forall i, i = 1, 2, \dots, m$ 
3   Llamar a Init_dist if  $k > 1$  para inicializar distribución cuando una nueva base está
   disponible
4   for  $t = 1, 2, \dots, T_k$  do
5     Paso 1.  $D_t = \vec{w}_t / \sum_{i=1}^m w_t(i)$  para que  $D_t$  sea una distribución
6     Paso 2. Escoger conjunto de entrenamiento  $TR_t$  y de prueba  $TE_t$  para  $D_t$ 
7     Paso 3. Llamar subrutina WeakLearn para entrenarla con  $TR_t$ 
8     Paso 4. Obtener hipótesis  $h_t : X \rightarrow Y$  y calcular error  $h_t : \varepsilon_t = \sum_{i:h_t(x_i) \neq (y_i)} D_t(i)$ 
   sobre  $TR_t + TE_t$ 
9     if  $\varepsilon_t > 1/2$  then
10      | Descartar  $h_t$  y volver a Paso 2
11      | Calcular error normalizado  $\beta_t = \varepsilon_t / (1 - \varepsilon_t)$ 
12      | Paso 5. Aplicar el voto mayoritario ponderado y obtener la hipótesis compuesta
    $H_t = \arg \max_{y \in Y} \sum_{t:h_t(x)=y} \log(1/\beta_t)$ 
13      | Paso 6. Calcular el error de la hipótesis compuesta
    $E_t = \sum_{i:H_t(x_i) \neq y_i} D_t(i) = \sum_{i=1}^m D_t(i) [H_t(x_i) \neq y_i]$ 
14      | Paso 7. Calcular  $B_t = E_t / (1 - E_t)$  y actualizar los pesos:
   
$$w_{t+1}(i) = w_t(i) \times \begin{cases} B_t, & \text{if } H_t(x_i) = y_i \\ 1, & \text{en otro caso} \end{cases}$$

15      | 
$$= w_t(i) \times B_t^{1 - |H_t(x_i) \neq y_i|}$$

16      | Aplicar voto mayoritario ponderado, y
17      | Calcular la hipótesis final:
18      |  $H_{final}(x) = \arg \max_{y \in Y} \sum_{k=1}^K \sum_{t:h_t(x)=y} \log \frac{1}{\beta_t}$ 

```

iteración del algoritmo. A menos que se especifique de otra manera, la distribución se inicializa de manera uniforme. Cuando una nueva base de datos ingresa, los pesos se ajustan mediante la subrutina **Init_dist**, la cual inicializa la distribución de los pesos por una transición suave (cuando llega una nueva base de datos, salta al paso 5 y corre el resto del ciclo **for**).

En el *Paso 1*, en cada iteración t , los pesos w_t son normalizado a partir de la iteración previa con el fin de asegurar una distribución legítima que se denominará D_t . En el *Paso 2*, se conforman unos nuevos conjuntos de entrenamiento (TR_t) y validación (TE_t) de acuerdo a la distribución D_t . Posteriormente, en el *Paso 3*, se logra un nuevo clasificador entrenado a partir de TR_t y del llamado a la subrutina **WeakLearn**; así se conforma la hipótesis h_t . Luego, se calcula el error de tal hipótesis haciendo uso de la base de datos completa ($TR_t + TE_t$) sumando los pesos de la distribución de las instancias mal clasificadas. Se condiciona el error de tal manera que sea menor a la mitad de los datos de entrenamiento para normalizar el error; en caso contrario, la hipótesis es descartada y se escogen nuevos TR_t y TE_t (*Paso 4*). Luego, en el *Paso 5* se combinan todas las hipótesis h_t generadas mediante el voto mayoritario ponderado para obtener la hipótesis compuesta H_t , aunque esta votación es menos democrática, ya que cada hipótesis tiene un peso de votación que es inversamente proporcional a su error normalizado. De la misma manera que se hace en el *Paso 4*, el error de la hipótesis compuesta se calcula mediante la suma de los pesos de las distribuciones de las instancias mal clasificadas (*Paso 6*). El error compuesto normalizado B_t se calcula en el *Paso 7* como lo muestra la ecuación mostrada en ese paso, y luego se usa este error en la definición de las reglas de actualización de los pesos de las instancias, como también se muestra en el *Paso 7*; con estas reglas el algoritmo se obliga a enfocarse en aquellas instancias que han sido erróneamente clasificadas (mal aprendidas); es decir, que la probabilidad de que sean seleccionadas en un siguiente conjunto de entrenamiento, aumenta efectivamente. Finalmente, la hipótesis final H_{final} (salida del algoritmo) se conforma combinando todas las hipótesis compuestas generadas usando el voto mayoritario ponderado. Para mayor detalle de este algoritmo, revisar [Elwell and Polikar, 2011].

Bibliografía

- Ade, R. and Deshmukh, P. (2013). Methods for incremental learning: a survey. *International Journal of Data Mining & Knowledge Management Process*, 3(4):119.
- Agliz, D., Atmani, A., et al. (2013). Seismic signal classification using multi-layer perceptron neural network. *International Journal of Computer Applications*, 79(15).
- Akhouayri, E.-S., Agliz, D., Zonta, D., Atmani, A., et al. (2015). A fuzzy expert system for automatic seismic signal classification. *Expert Systems with Applications*, 42(3):1013–1027.
- Alarcón, A., Rodríguez, E., and Escallón, J. (2000). Atlas de amenaza volcánica en Colombia. *Ingeominas*.
- Allen, R. V. (1978). Automatic earthquake recognition and timing from single traces. *Bulletin of the seismological society of America*, 68(5):1521–1532.
- Álvarez, I., Cortés, G., De la Torre, A., Benitez, C., García, L., Lesage, P., Arámbula, R., and González, M. (2009). Improving feature extraction in the automatic classification of seismic events. Application to Colima and Arenal volcanoes. In *2009 IEEE International Geoscience and Remote Sensing Symposium*, volume 4, pages IV–526. IEEE.
- Alvarez, I., Garcia, L., Cortes, G., Benitez, C., and De la Torre, Á. (2012). Discriminative feature selection for automatic classification of volcano-seismic signals. *IEEE Geoscience and Remote Sensing Letters*, 9(2):151–155.
- Amirat, Y., Daney, D., Mohammed, S., Spalanzani, A., Chibani, A., and Simonin, O. (2016). Assistance and service robotics in a human environment. *Robotics and Autonomous Systems*, 75(PA):1–3.
- Anantrasirichai, N., Biggs, J., Albino, F., and Bull, D. (2019). A deep learning approach to detecting volcano deformation from satellite imagery using synthetic datasets. *Remote Sensing of Environment*, 230:111179.
- Ansari, A., Noorzad, A., and Zafarani, H. (2009). Clustering analysis of the seismic catalog of Iran. *Computers & Geosciences*, 35(3):475–486.
- Ashenden, C. L., Lindsay, J. M., Sherburn, S., Smith, I. E., Miller, C. A., and Malin, P. E. (2011). Some challenges of monitoring a potentially active volcanic field in a large urban area: Auckland volcanic field, New Zealand. *Natural Hazards*, 59(1):507–528.

- Avesani, R., Azzoni, A., Bicego, M., and Orozco-Alzate, M. (2012). Automatic classification of volcanic earthquakes in HMM-induced vector spaces. In *Iberoamerican Congress on Pattern Recognition*, pages 640–647. Springer.
- Avossa, C., Giudicepietro, F., Marinaro, M., and Scarpetta, S. (2003). Supervised and unsupervised analysis applied to Strombolian EQ. In *Italian Workshop on Neural Nets*, pages 173–178. Springer.
- Awadallah, S., Moure, D., and Torres-González, P. (2019). An internet of things (IoT) application on volcano monitoring. *Sensors*, 19(21):4651.
- Batista, G. E., Prati, R. C., and Monard, M. C. (2004). A study of the behavior of several methods for balancing machine learning training data. *ACM SIGKDD Explorations Newsletter*, 6(1):20–29.
- Bellahsene, H. and Taleb-Ahmed, A. (2018). ARMA order model detection using minimum of kurtosis: Application on seismic data. *Arabian Journal of Geosciences*, 11(24):776.
- Benítez, M. C., Ramírez, J., Segura, J. C., Ibanez, J. M., Almendros, J., García-Yeguas, A., and Cortes, G. (2006). Continuous HMM-based seismic-event classification at Deception Island, Antarctica. *IEEE Transactions on Geoscience and Remote Sensing*, 45(1):138–146.
- Benson, P. M., Vinciguerra, S., Meredith, P. G., and Young, R. P. (2010). Spatio-temporal evolution of volcano seismicity: A laboratory study. *Earth and Planetary Science Letters*, 297(1-2):315–323.
- Beyreuther, M., Carniel, R., and Wassermann, J. (2008). Continuous hidden Markov models: Application to automatic earthquake detection and classification at Las Cañadas caldera, Tenerife. *Journal of Volcanology and Geothermal Research*, 176(4):513–518.
- Beyreuther, M. and Wassermann, J. (2008). Continuous earthquake detection and classification using discrete hidden Markov models. *Geophysical Journal International*, 175(3):1055–1066.
- Bhatti, S. M., Khan, M. S., Wuth, J., Huenupan, F., Curilem, M., Franco, L., and Yoma, N. B. (2016). Automatic detection of volcano-seismic events by modeling state and event duration in hidden Markov models. *Journal of Volcanology and Geothermal Research*, 324:134–143.
- Bicego, M., Acosta-Munoz, C., and Orozco-Alzate, M. (2012). Classification of seismic volcanic signals using hidden Markov models-based generative embeddings. *IEEE Transactions on Geoscience and Remote Sensing*, 51(6):3400–3409.
- Bicego, M., Londoño-Bonilla, J. M., and Orozco-Alzate, M. (2015). Volcano-seismic events classification using document classification strategies. In *International Conference on Image Analysis and Processing*, pages 119–129. Springer.
- Bifet, A. and Gavaldá, R. (2007). Learning from time-changing data with adaptive windowing. In *Proceedings of the 2007 SIAM international conference on data mining*, pages 443–448. SIAM.

- Bifet, A. and Gavalda, R. (2009). Adaptive learning from evolving data streams. In *Advances in Intelligent Data Analysis VIII: 8th International Symposium on Intelligent Data Analysis, IDA 2009, Lyon, France, August 31-September 2, 2009. Proceedings 8*, pages 249–260. Springer.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- Bormann, P. and Wielandt, E. (2013). Seismic signals and noise. In *New Manual of Seismological Observatory Practice 2 (NMSOP2)*, pages 1–62. Deutsches GeoForschungsZentrum GFZ.
- Brown, S. K., Jenkins, S. F., Sparks, R. S. J., Odbert, H., and Auker, M. R. (2017). Volcanic fatalities database: Analysis of volcanic threat with distance and victim classification. *Journal of Applied Volcanology*, 6(1):1–20.
- Bueno, A., Benitez, C., De Angelis, S., Moreno, A. D., and Ibanez, J. M. (2019). Volcano-seismic transfer learning and uncertainty quantification with bayesian neural networks. *IEEE Transactions on Geoscience and Remote Sensing*, 58(2):892–902.
- Bunke, H. (1993). Structural and syntactic pattern recognition. *Handbook of Pattern Recognition and Computer Vision*, pages 163–209.
- Canario, J. P., Mello, R., Curilem, M., Huenupan, F., and Rios, R. (2020). In-depth comparison of deep artificial neural network architectures on seismic events classification. *Journal of Volcanology and Geothermal Research*, 401:106881.
- Carmona, E., Almendros, J., Serrano, I., Stich, D., and Ibáñez, J. M. (2012). Results of seismic monitoring surveys of Deception Island volcano, Antarctica, from 1999-2011. *Antarctic Science*, 24(5):485.
- Carniel, R. (2014). Characterization of volcanic regimes and identification of significant transitions using geophysical data: a review. *Bulletin of Volcanology*, 76(8):1–22.
- Carniel, R. and Guzmán, S. (2020). Chapter machine learning in volcanology: A review.
- Castaño, L. M., Ospina, C. A., Cadena, O. E., Galvis-Arenas, B., Londono, J. M., Laverde, C. A., Kaneko, T., and Ichihara, M. (2020). Continuous monitoring of the 2015–2018 Nevado del Ruiz activity, Colombia, using satellite infrared images and local infrasound records. *Earth, Planets and Space*, 72:1–18.
- Castro Cabrera, P. A. (2011). Extracción y selección de características discriminantes para la detección de TDAH en registros de potenciales evocados cognitivos. Master’s thesis, Universidad Nacional de Colombia.
- Catalan, L., Araiz, M., Aranguren, P., Padilla, G. D., Hernandez, P. A., Perez, N. M., Garcia de la Noceda, C., Albert, J. F., and Astrain, D. (2020). Prospects of autonomous volcanic monitoring stations: Experimental investigation on thermoelectric generation from fumaroles. *Sensors*, 20(12):3547.

- Caudron, C., Lecocq, T., Syahbana, D. K., McCausland, W., Watlet, A., Camelbeeck, T., Bernard, A., et al. (2015). Stress and mass changes at a “wet” volcano: Example during the 2011–2012 volcanic unrest at Kawah Ijen volcano (Indonesia). *Journal of Geophysical Research: Solid Earth*, 120(7):5117–5134.
- Chen, Y., Liu, W., Zhang, G., Cheng, Z., and Chen, W. (2016). Seismic time-frequency analysis using improved complete ensemble empirical mode decomposition. In *78th EAGE Conference and Exhibition 2016*, pages 1–5. European Association of Geoscientists & Engineers.
- Chouet, B. A. and Matoza, R. S. (2013). A multi-decadal view of seismic methods for detecting precursors of magma movement and eruption. *Journal of Volcanology and Geothermal Research*, 252:108–175.
- Chu-Salgado, C. A., Orozco-Alzate, M., and Londoño-Bonilla, J. M. (2009). Combinación fija de clasificadores para la discriminación de señales sísmicas volcánicas. *Boletín de Ciencias de la Tierra*, (27):37–48.
- Cortés, G., García, L., Álvarez, I., Benítez, C., de la Torre, Á., and Ibáñez, J. (2014). Parallel system architecture (PSA): An efficient approach for automatic recognition of volcano-seismic events. *Journal of Volcanology and Geothermal Research*, 271:1–10.
- Curilem, G., Vergara, J., Fuentealba, G., Acuña, G., and Chacón, M. (2009). Classification of seismic signals at Villarrica volcano (Chile) using neural networks and genetic algorithms. *Journal of Volcanology and Geothermal Research*, 180(1):1–8.
- Curilem, M., Vergara, J., San Martín, C., Fuentealba, G., Cardona, C., Huenupan, F., Chacón, M., Khan, M. S., Hussein, W., and Yoma, N. B. (2014). Pattern recognition applied to seismic signals of the Llaima volcano (Chile): An analysis of the events’ features. *Journal of Volcanology and Geothermal Research*, 282:134–147.
- Dai, H. and MacBeth, C. (1995). Automatic picking of seismic arrivals in local earthquake data using an artificial neural network. *Geophysical journal international*, 120(3):758–774.
- Das, A. K., Sengupta, S., and Bhattacharyya, S. (2018). A group incremental feature selection for classification using rough set theory based genetic algorithm. *Applied Soft Computing*, 65:400–411.
- Davis, S. and Mermelstein, P. (1980). Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 28(4):357–366.
- Dayan, P., Sahani, M., and Deback, G. (1999). Unsupervised learning. *The MIT Encyclopedia of the Cognitive Sciences*, pages 857–859.
- Debnath, L. (2003). *Wavelets and signal processing*. Springer Science & Business Media.
- Del Pezzo, E., Esposito, A., Giudicepietro, F., Marinaro, M., Martini, M., and Scarpetta, S. (2003). Discrimination of earthquakes and underwater explosions using neural networks. *Bulletin of the Seismological Society of America*, 93(1):215–223.

- Dhar, P. (2023). Liquid neural network adapts on the go. *IEEE Spectrum*.
- Di Stefano, R., Aldersons, F., Kissling, E., Baccheschi, P., Chiarabba, C., and Giardini, D. (2006). Automatic seismic phase picking and consistent observation error assessment: application to the Italian seismicity. *Geophysical Journal International*, 165(1):121–134.
- Diaz-Chito, K., Ferri, F. J., and Diaz-Villanueva, W. (2014). Incremental generalized discriminative common vectors for image classification. *IEEE Transactions on Neural Networks and Learning Systems*, 26(8):1761–1775.
- Diersen, S., Lee, E.-J., Spears, D., Chen, P., and Wang, L. (2011). Classification of seismic windows using artificial neural networks. *Procedia Computer Science*, 4:1572–1581.
- Ditzler, G., Roveri, M., Alippi, C., and Polikar, R. (2015). Learning in nonstationary environments: A survey. *IEEE Computational Intelligence Magazine*, 10(4):12–25.
- Dong, L., Wesseloo, J., Potvin, Y., and Li, X. (2016). Discrimination of mine seismic events and blasts using the Fisher classifier, naive Bayesian classifier and logistic regression. *Rock Mechanics and Rock Engineering*, 49(1):183–211.
- Donovan, A., Oppenheimer, C., and Bravo, M. (2012). Science at the policy interface: Volcano-monitoring technologies and volcanic hazard management. *Bulletin of Volcanology*, 74(5):1005–1022.
- Duda, R. O., Hart, P. E., et al. (2006). *Pattern classification*. John Wiley & Sons.
- Duin, R. P., Orozco-Alzate, M., and Londono-Bonilla, J. M. (2010). Classification of volcano events observed by multiple seismic stations. In *2010 20th International Conference on Pattern Recognition*, pages 1052–1055. IEEE.
- Duin, R. P. and Pekalska, E. (2005). Open issues in pattern recognition. In *Computer Recognition Systems*, pages 27–42. Springer.
- Duin, R. P. and Pekalska, E. (2007). The science of pattern recognition. Achievements and perspectives. In *Challenges for Computational Intelligence*, pages 221–259. Springer.
- Duque Escobar, G. (2012). Gestión del riesgo por sismos, volcanes y laderas en la política ambiental de Manizales. *Boletín Ambiental Instituto de Estudios Ambientales (IDEA)*, (104).
- Dymarski, P. (2011). *Hidden Markov models: theory and applications*. BoD–Books on Demand.
- Elwell, R. and Polikar, R. (2011). Incremental learning of concept drift in nonstationary environments. *IEEE Transactions on Neural Networks*, 22(10):1517–1531.
- Erazo Bravo, Y. J. (2019). Estudio comparativo de algoritmos para la segmentación de señales volcánicas orientado a la clasificación de sismos. Master’s thesis, Universidad de Nariño.
- Esmaili, S., Krishnan, S., and Raahemifar, K. (2004). Content based audio classification and retrieval using joint time-frequency analysis. In *2004 IEEE International Conference on Acoustics, Speech, and Signal Processing*, volume 5, pages V–665. IEEE.

- Espinoza Lara, P. E., Rolim Fernandes, C. A., Inza, A., Mars, J. I., Métaixian, J.-P., Dalla Mura, M., and Malfante, M. (2020). Automatic multichannel volcano-seismic classification using machine learning and EMD. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13:1322–1331.
- Esposito, A., Giudicepietro, F., Scarpetta, S., D’auria, L., Marinaro, M., and Martini, M. (2006). Automatic discrimination among landslide, explosion-quake, and microtremor seismic signals at Stromboli volcano using neural networks. *Bulletin of the Seismological Society of America*, 96(4A):1230–1240.
- Esposito, A. M., D’Auria, L., Giudicepietro, F., Peluso, R., and Martini, M. (2013). Automatic recognition of landslides based on neural network analysis of seismic signals: An application to the monitoring of Stromboli volcano (southern Italy). *Pure and Applied Geophysics*, 170(11):1821–1832.
- Esposito, A. M., Giudicepietro, F., D’Auria, L., Scarpetta, S., Martini, M. G., Coltelli, M., and Marinaro, M. (2008). Unsupervised neural analysis of very-long-period events at Stromboli volcano using the self-organizing maps. *Bulletin of the Seismological Society of America*, 98(5):2449–2459.
- Ezin, E. C., Giudicepietro, F., Petrosino, S., Scarpetta, S., and Vanacore, A. (2002). Automatic discrimination of earthquakes and false events in seismological recording for volcanic monitoring. In *Italian Workshop on Neural Nets*, pages 140–145. Springer.
- Fagerlund, S. (2007). Bird species recognition using support vector machines. *EURASIP Journal on Advances in Signal Processing*, 2007:1–8.
- Falcin, A., Métaixian, J.-P., Mars, J., Stutzmann, É., Komorowski, J.-C., Moretti, R., Malfante, M., Beauducel, F., Saurel, J.-M., Dessert, C., et al. (2021). A machine-learning approach for automatic classification of volcanic seismicity at La Soufrière volcano, Guadeloupe. *Journal of Volcanology and Geothermal Research*, 411:107151.
- Falsaperla, S., Graziani, S., Nunnari, G., and Spampinato, S. (1996). Automatic classification of volcanic earthquakes by using multi-layered neural networks. *Natural Hazards*, 13(3):205–228.
- Favereau, M., Robledo, L. F., and Bull, M. T. (2018). Analysis of risk assessment factors of individuals in volcanic hazards: Review of the last decade. *Journal of Volcanology and Geothermal Research*, 365:57–64.
- Feng, F., Chan, R. H., Shi, X., Zhang, Y., and She, Q. (2019). Challenges in task incremental learning for assistive robotics. *IEEE Access*, 8:3434–3441.
- Fernández, J., Pepe, A., Poland, M. P., and Sigmundsson, F. (2017). Volcano geodesy: Recent developments and future challenges. *Journal of Volcanology and Geothermal Research*, 344:1–12.
- Firoozabadi, A. D., Seguel, F., Soto, I., Guevara, D., Huenupan, F., Curilem, M., and Franco, L. (2017). Evaluation of Llaima volcano activities for localization and classification of LP, VT and TR events. *Journal of Electrical Engineering*, 68(5):325–338.

- Fujinaga, I. and MacMillan, K. (2000). Realtime recognition of orchestral instruments. In *2000 International Computer Music Conference, ICMC 2000. Berlin, Germany. August 27 - September 1*.
- Fujiwara, T., Chou, J.-K., Shilpika, S., Xu, P., Ren, L., and Ma, K.-L. (2019). An incremental dimensionality reduction method for visualizing streaming multidimensional data. *IEEE Transactions on Visualization and Computer Graphics*, 26(1):418–428.
- Gaddes, M., Hooper, A., and Bagnardi, M. (2019). Using machine learning to automatically detect volcanic unrest in a time series of interferograms. *Journal of Geophysical Research: Solid Earth*, 124(11):12304–12322.
- Gama, J., Medas, P., Castillo, G., and Rodrigues, P. (2004). Learning with drift detection. In *Advances in Artificial Intelligence—SBIA 2004: 17th Brazilian Symposium on Artificial Intelligence, Sao Luis, Maranhao, Brazil, September 29-October 1, 2004. Proceedings 17*, pages 286–295. Springer.
- Gama, J., Žliobaitė, I., Bifet, A., Pechenizkiy, M., and Bouchachia, A. (2014). A survey on concept drift adaptation. *ACM Computing Surveys*, 46(4):44.
- García, C. and Mendez-Fajury, R. (2017). If I understand, I am understood: Experiences of volcanic risk communication in Colombia. In *Observing the Volcano World*, pages 335–351. Springer.
- Gepperth, A. and Hammer, B. (2016). Incremental learning algorithms and applications. In *European Symposium on Artificial Neural Networks (ESANN)*, Bruges, Belgium.
- Giacco, F., Esposito, A., Scarpetta, S., Guidicepetro, F., and Marinaro, M. (2009). Support vector machines and MLP for automatic classification of seismic signals at Stromboli volcano. In *Neural Nets WIRN09: Proceedings of the 19th Italian Workshop on Neural Nets, Vietri Sul Mare, Salerno, Italy May 28-30 2009*, volume 204, page 116. IOS Press.
- Giraud-Carrier, C. (2000). A note on the utility of incremental learning. *AI Communications*, 13(4):215–223.
- Grangeon, J. and Lesage, P. (2019). A robust, low-cost and well-calibrated infrasound sensor for volcano monitoring. *Journal of Volcanology and Geothermal Research*, 387:106668.
- Gunn, I. A., Arnaiz-González, Á., and Kuncheva, L. I. (2018). A taxonomic look at instance-based stream classifiers. *Neurocomputing*, 286:167–178.
- Gutiérrez, L., Ibañez, J., Cortés, G., Ramírez, J., Benítez, C., Tenorio, V., and Isaac, A. (2009). Volcano-seismic signal detection and classification processing using hidden Markov models. Application to San Cristóbal volcano, Nicaragua. In *2009 IEEE International Geoscience and Remote Sensing Symposium*, volume 4, pages IV–522. IEEE.
- Gutiérrez, L., Ramírez, J., Benítez, C., Ibañez, J., Almendros, J., and García-Yeguas, A. (2006). HMM-based classification of seismic events recorded at Stromboli and Etna volcanoes. In *2006 IEEE International Symposium on Geoscience and Remote Sensing*, pages 2765–2768. IEEE.

- Han, N. C., Muniandy, S. V., and Dayou, J. (2011). Acoustic classification of Australian anurans based on hybrid spectral-entropy approach. *Applied Acoustics*, 72(9):639–645.
- Havskov, J. and Alguacil, G. (2016). Seismic sensors. In *Instrumentation in Earthquake Seismology*, pages 13–100. Springer.
- Havskov, J. and Ottemoller, L. (2010). Instruments and waveform data. In *Routine data processing in earthquake seismology: With sample data, exercises and software*. Springer Science & Business Media.
- He, X., Beausery, P., and Smolarz, A. (2015). Dynamic feature subspaces selection for decision in a nonstationary environment. *International Journal of Pattern Recognition and Artificial Intelligence*, 29(06):1551009.
- Heiken, G. (2016). Understanding volcanoes and volcanic hazards. In *Oxford Research Encyclopedia of Natural Hazard Science*.
- Herrmann, R. B. (2013). Computer programs in seismology: An evolving tool for instruction and research. *Seismological Research Letters*, 84(6):1081–1088.
- Hibert, C., Provost, F., Malet, J.-P., Maggi, A., Stumpf, A., and Ferrazzini, V. (2017). Automatic identification of rockfalls and volcano-tectonic earthquakes at the Piton de La Fournaise volcano using a random forest algorithm. *Journal of Volcanology and Geothermal Research*, 340:130–142.
- Hoogenboezem, R. M. (2010). Automatic classification of segmented seismic recordings at the Nevado del Ruiz volcano, Columbia. Master’s thesis, Delft University of Technology, Delft, The Netherlands.
- Ibáñez, J. M., Benítez, C., Gutiérrez, L. A., Cortés, G., García-Yeguas, A., and Alguacil, G. (2009). The classification of seismo-volcanic signals using hidden Markov models as applied to the Stromboli and Etna volcanoes. *Journal of Volcanology and Geothermal Research*, 187(3-4):218–226.
- Ibs-von Seht, M. (2008). Detection and identification of seismic signals recorded at Krakatau volcano (Indonesia) using artificial neural networks. *Journal of Volcanology and Geothermal Research*, 176(4):448–456.
- Japkowicz, N. and Shah, M. (2011). *Evaluating learning algorithms: A classification perspective*. Cambridge University Press.
- Jiao, P. and Alavi, A. H. (2020). Artificial intelligence in seismology: Advent, performance and future trends. *Geoscience Frontiers*, 11(3):739–744.
- Joseph, A. A. and Ozawa, S. (2014). A fast incremental kernel principal component analysis for data streams. In *2014 International Joint Conference on Neural Networks (IJCNN)*, pages 3135–3142. IEEE.
- Kalra, M., Kumar, S., and Das, B. (2020). Seismic signal analysis using empirical wavelet transform for moving ground target detection and classification. *IEEE Sensors Journal*, 20(14):7886–7895.

- Karpatne, A., Ebert-Uphoff, I., Ravela, S., Babaie, H. A., and Kumar, V. (2018). Machine learning for the geosciences: Challenges and opportunities. *IEEE Transactions on Knowledge and Data Engineering*, 31(8):1544–1554.
- Khamassi, I., Sayed-Mouchaweh, M., Hammami, M., and Ghédira, K. (2018). Discussion and review on evolving data streams and concept drift adapting. *Evolving Systems*, 9(1):1–23.
- Kira, K. and Rendell, L. A. (1992). A practical approach to feature selection. In *Machine learning proceedings*, pages 249–256. Elsevier.
- Kong, Q., Trugman, D. T., Ross, Z. E., Bianco, M. J., Meade, B. J., and Gerstoft, P. (2019). Machine learning in seismology: Turning data into insights. *Seismological Research Letters*, 90(1):3–14.
- Kononenko, I. (1994). Estimating attributes: Analysis and extensions of Relief. In *European conference on machine learning*, pages 171–182. Springer.
- Kortström, J., Uski, M., and Tiira, T. (2016). Automatic classification of seismic events within a regional seismograph network. *Computers & Geosciences*, 87:22–30.
- Kuncheva, L. (2010). Teaching and research practices in pattern recognition (personal views and experiences). Report: School of Computer Science. Bangor University, UK.
- Kuncheva, L. (2019). *Pattern Recognition and Neural Networks*. Lulu.com.
- Kuncheva, L. I. (2013). Change detection in streaming multivariate data using likelihood detectors. *IEEE Transactions on Knowledge and Data Engineering*, 25(5):1175–1180.
- Kuncheva, L. I. and Faithfull, W. J. (2014). PCA feature extraction for change detection in multidimensional unlabeled data. *IEEE Transactions on Neural Networks and Learning Systems*, 25(1):69–80.
- Lamb, O. D., Varley, N. R., Mather, T. A., Pyle, D. M., Smith, P. J., and Liu, E. J. (2014). Multiple timescales of cyclical behaviour observed at two dome-forming eruptions. *Journal of Volcanology and Geothermal Research*, 284:106–121.
- Langer, H. and Falsaperla, S. (2003). Seismic monitoring at Stromboli volcano (Italy): A case study for data reduction and parameter extraction. *Journal of Volcanology and Geothermal Research*, 128(1-3):233–245.
- Langer, H., Falsaperla, S., Masotti, M., Campanini, R., Spampinato, S., and Messina, A. (2009). Synopsis of supervised and unsupervised pattern classification techniques applied to volcanic tremor data at Mt Etna, Italy. *Geophysical Journal International*, 178(2):1132–1144.
- Langer, H., Falsaperla, S., Powell, T., and Thompson, G. (2006). Automatic classification and a-posteriori analysis of seismic event identification at Soufriere Hills volcano, Montserrat. *Journal of Volcanology and Geothermal Research*, 153(1-2):1–10.

- Lara, F., Lara-Cueva, R., Larco, J. C., Carrera, E. V., and León, R. (2021). A deep learning approach for automatic recognition of seismo-volcanic events at the Cotopaxi volcano. *Journal of Volcanology and Geothermal Research*, 409:107142.
- Lara-Cueva, R., Benítez, D. S., Paillacho, V., Villalva, M., and Rojo-Álvarez, J. L. (2017). On the use of multi-class support vector machines for classification of seismic signals at Cotopaxi volcano. In *2017 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC)*, pages 1–6. IEEE.
- Lary, D. J. (2010). Artificial intelligence in geoscience and remote sensing. *Geoscience and Remote Sensing: New Achievements*, page 105.
- Lary, D. J., Alavi, A. H., Gandomi, A. H., and Walker, A. L. (2016). Machine learning in geosciences and remote sensing. *Geoscience Frontiers*, 7(1):3–10.
- Lehr, J., Eckel, F., Thorwart, M., and Rabbel, W. (2019). Low-frequency seismicity at Villarrica volcano: Source location and seismic velocities. *Journal of Geophysical Research: Solid Earth*, 124(11):11505–11530.
- Leng, Y., Zhang, L., and Yang, J. (2014). Locally linear embedding algorithm based on OMP for incremental learning. In *2014 International Joint Conference on Neural Networks (IJCNN)*, pages 3100–3107. IEEE.
- Li, P., Chen, Z., Yang, L. T., Gao, J., Zhang, Q., and Deen, M. J. (2018). An incremental deep convolutional computation model for feature learning on industrial big data. *IEEE Transactions on Industrial Informatics*, 15(3):1341–1349.
- Lokmer, I., Saccorotti, G., Di Lieto, B., and Bean, C. J. (2008). Temporal evolution of long-period seismicity at Etna volcano, Italy, and its relationships with the 2004–2005 eruption. *Earth and Planetary Science Letters*, 266(1-2):205–220.
- Lomax, A., Satriano, C., and Vassallo, M. (2012). Automatic picker developments and optimization: Filterpicker—a robust, broadband picker for real-time seismic monitoring and earthquake early warning. *Seismological Research Letters*, 83(3):531–540.
- Londoño, J. M. (2010). Aspectos relevantes de la actividad del volcán Nevado del Ruiz. 1985-2008. *Glaciares, nieves y hielos de América Latina. Cambio climático y amenazas*, page 261.
- Londono, J. M. (2016). Evidence of recent deep magmatic activity at Cerro Bravo-Cerro Machín volcanic complex, central Colombia. Implications for future volcanic activity at Nevado del Ruiz, Cerro Machín and other volcanoes. *Journal of Volcanology and Geothermal Research*, 324:156–168.
- López-Pérez, M., García, L., Benítez, C., and Molina, R. (2020). A contribution to deep learning approaches for automatic classification of volcano-seismic events: Deep gaussian processes. *IEEE Transactions on Geoscience and Remote Sensing*, 59(5):3875–3890.

- Losing, V., Hammer, B., and Wersing, H. (2018). Incremental on-line learning: A review and comparison of state of the art algorithms. *Neurocomputing*, 275:1261–1274.
- Loughlin, S. C., Sparks, R. S. J., Brown, S. K., Jenkins, S. F., and Vye-Brown, C. (2015). *Global volcanic hazards and risk*. Cambridge University Press.
- Lu, J., Liu, A., Dong, F., Gu, F., Gama, J., and Zhang, G. (2018). Learning under concept drift: A review. *IEEE Transactions on Knowledge and Data Engineering*, 99:1–18.
- Malfante, M., Dalla Mura, M., Métaixian, J.-P., Mars, J. I., Macedo, O., and Inza, A. (2018). Machine learning for volcano-seismic signals: Challenges and perspectives. *IEEE Signal Processing Magazine*, 35(2):20–30.
- Manley, G. F., Mather, T. A., Pyle, D. M., Clifton, D. A., Rodgers, M., Thompson, G., and Londono, J. M. (2022). A deep active learning approach to the automatic classification of volcano-seismic events. *Frontiers in Earth Science*, 10:78.
- Martínez, V. L., Titos, M., Benítez, C., Badi, G., Casas, J. A., Craig, V. H. O., and Ibáñez, J. M. (2021). Advanced signal recognition methods applied to seismo-volcanic events from Planchon Peteroa volcanic complex: Deep Neural Network classifier. *Journal of South American Earth Sciences*, 107:103115.
- Maxwell, A. E., Warner, T. A., and Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*, 39(9):2784–2817.
- McNutt, S. R. (1996). Seismic monitoring and eruption forecasting of volcanoes: A review of the state-of-the-art and case histories. In *Monitoring and Mitigation of Volcano Hazards*, pages 99–146. Springer.
- McNutt, S. R. (2002). Volcano seismology and monitoring for eruptions. *International Geophysics Series*, 81(A):383–406.
- McNutt, S. R. (2005). Volcanic seismology. *Annual Review of Earth and Planetary Sciences*, 32:461–491.
- Mehrkanoon, S., Agudelo, O. M., and Suykens, J. A. (2015). Incremental multi-class semi-supervised clustering regularized by Kalman filtering. *Neural Networks*, 71:88–104.
- Mera, C., Orozco-Alzate, M., and Branch, J. (2019). Incremental learning of concept drift in Multiple Instance Learning for industrial visual inspection. *Computers in Industry*, 109:153–164.
- Messina, A. and Langer, H. (2011). Pattern recognition of volcanic tremor data on Mt. Etna (Italy) with KAnalysis - A software program for unsupervised classification. *Computers & Geosciences*, 37(7):953–961.
- Minakami, T. (1974). Seismology of volcanoes in Japan. *Physical Volcanology*, 6:1–27.

- Nallaperuma, D., Nawaratne, R., Bandaragoda, T., Adikari, A., Nguyen, S., Kempitiya, T., De Silva, D., Alahakoon, D., and Pothuhera, D. (2019). Online incremental machine learning platform for big data-driven smart traffic management. *IEEE Transactions on Intelligent Transportation Systems*, 20(12):4679–4690.
- Ogata, K. and Yang, Y. (2002). *Modern control engineering*, volume 4. Prentice Hall India.
- Ohrnberger, M. (2001). Continuous automatic classification of seismic signals of volcanic origin at Mt. Merapi, Java, Indonesia. *Dissertation*, page 168.
- Oppenheim, A. V., Willsky, A. S., and Nawab, S. H. (1998). *Señales y sistemas segunda edición*. Prentice-Hall.
- Orozco-Alzate, M. (2008). *Generalized dissimilarity representations for pattern recognition*. Universidad Nacional de Colombia - Sede Manizales. Tesis de doctorado.
- Orozco-Alzate, M., Acosta-Muñoz, C., and Londoño-Bonilla, J. M. (2012). *Earthquake Research and Analysis - Seismology, Seismotectonic and Earthquake Geology*, chapter 19: The Automated Identification of Volcanic Earthquakes: Concepts, Applications and Challenges, pages 377–402. InTech.
- Orozco-Alzate, M., Castro-Cabrera, P. A., Bicego, M., and Londoño-Bonilla, J. M. (2015). The DTW-based representation space for seismic pattern classification. *Computers & Geosciences*, 85:86–95.
- Orozco-Alzate, M., García, M. E., Duin, R. P., and Castellanos, C. G. (2006). Dissimilarity-based classification of seismic signals at Nevado del Ruiz volcano. *Earth Sciences Research Journal*, 10(2):57–66.
- Orozco-Alzate, M., Londoño-Bonilla, J. M., Nale, V., and Bicego, M. (2019). Towards better volcanic risk-assessment systems by applying ensemble classification methods to triaxial seismic-volcanic signals. *Ecological Informatics*, 51:177–184.
- Orozco-Alzate, M., Skurichina, M., and Duin, R. P. (2008). Spectral characterization of volcanic earthquakes at Nevado del Ruiz volcano using spectral band selection/extraction techniques. In *Iberoamerican Congress on Pattern Recognition*, pages 708–715. Springer.
- O’Shaughnessy, D. (1988). Linear predictive coding. *IEEE Potentials*, 7(1):29–32.
- Oussous, A., Benjelloun, F.-Z., Lahcen, A. A., and Belfkih, S. (2018). Big data technologies: A survey. *Journal of King Saud University-Computer and Information Sciences*, 30(4):431–448.
- Ozawa, S., Kawashima, Y., Pang, S., and Kasabov, N. (2009). Adaptive incremental principal component analysis in nonstationary online learning environments. In *2009 International Joint Conference on Neural Networks*, pages 2394–2400. IEEE.
- Pekalska, E., Duin, R. P., and Paclik, P. (2006). Prototype selection for dissimilarity-based classifiers. *Pattern Recognition*, 39(2):189–208.

- Polikar, R., Upda, L., Upda, S. S., and Honavar, V. (2001). Learn++: An incremental learning algorithm for supervised neural networks. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 31(4):497–508.
- Porro-Munoz, D., Duin, R. P., Orozco-Alzate, M., Talavera, I., and Londono-Bonilla, J. M. (2010a). Classifying three-way seismic volcanic data by dissimilarity representation. In *20th International Conference on Pattern Recognition*, pages 814–817. IEEE.
- Porro-Munoz, D., Duin, R. P., Orozco-Alzate, M., Talavera, I., and Londono-Bonilla, J. M. (2010b). The dissimilarity representation as a tool for three-way data classification: A 2d measure. In *Joint IAPR International Workshops on Statistical Techniques in Pattern Recognition (SPR) and Structural and Syntactic Pattern Recognition (SSPR)*, pages 569–578. Springer.
- Porro-Muñoz, D., Duin, R. P., Talavera, I., and Orozco-Alzate, M. (2011). Classification of three-way data by the dissimilarity representation. *Signal Processing*, 91(11):2520–2529.
- Ramírez-Rojas, A., Flores-Márquez, E. L., Sarlis, N. V., and Varotsos, P. A. (2018). The complexity measures associated with the fluctuations of the entropy in natural time before the deadly México m8. 2 earthquake on 7 september 2017. *Entropy*, 20(6):477.
- Richardson, J. P., Waite, G. P., and Palma, J. L. (2014). Varying seismic-acoustic properties of the fluctuating lava lake at Villarrica volcano, Chile. *Journal of Geophysical Research: Solid Earth*, 119(7):5560–5573.
- Riggelsen, C., Ohrnberger, M., and Scherbaum, F. (2007). Dynamic bayesian networks for real-time classification of seismic signals. In *European Conference on Principles of Data Mining and Knowledge Discovery*, pages 565–572. Springer.
- Robnik-Šikonja, M. and Kononenko, I. (2003). Theoretical and empirical analysis of ReliefF and RReliefF. *Machine learning*, 53:23–69.
- Rodriguez, I. V. (2011). Automatic time-picking of microseismic data combining STA\LTA and the stationary discrete wavelet transform. In *GeoConvention, 2011*.
- Roman, D., De Angelis, S., Latchman, J., and White, R. (2008). Patterns of volcanotectonic seismicity and stress during the ongoing eruption of the Soufrière Hills volcano, Montserrat (1995–2007). *Journal of Volcanology and Geothermal Research*, 173(3-4):230–244.
- Romeo, G. (1994). Seismic signals detection and classification using artificial neural networks. *Annals of Geophysics*, 37(3).
- Romeo, G., Mele, F., and Morelli, A. (1995). Neural networks and discrimination of seismic signals. *Computers & Geosciences*, 21(2):279–288.
- Rouland, D., Legrand, D., Zhizhin, M., and Vergnolle, S. (2009). Automatic detection and discrimination of volcanic tremors and tectonic earthquakes: An application to Ambrym volcano, Vanuatu. *Journal of Volcanology and Geothermal Research*, 181(3-4):196–206.

- Ruano, A. E., Madureira, G., Barros, O., Khosravani, H. R., Ruano, M. G., and Ferreira, P. M. (2014). Seismic detection using support vector machines. *Neurocomputing*, 135:273–283.
- Salazar, A., Arroyo, R., Pérez, N., and Benítez, D. (2020). Deep-learning for volcanic seismic events classification. In *2020 IEEE Colombian Conference on Applications of Computational Intelligence (IEEE ColCACI 2020)*, pages 1–6. IEEE.
- San-Martin, C., Melgarejo, C., Gallegos, C., Soto, G., Curilem, M., and Fuentealba, G. (2010). Feature extraction using circular statistics applied to volcano monitoring. In *Iberoamerican Congress on Pattern Recognition*, pages 458–466. Springer.
- Scarpetta, S., Giudicepietro, F., Ezin, E. C., Petrosino, S., Del Pezzo, E., Martini, M., and Marinaro, M. (2005). Automatic classification of seismic signals at Mt. Vesuvius volcano, Italy, using neural networks. *Bulletin of the Seismological Society of America*, 95(1):185–196.
- Schapire, R. E. (2013). Explaining AdaBoost. In *Empirical Inference*, pages 37–52. Springer.
- SERNAGEOMIN, RNVV, and OVDAS (2015). Reportes de actividad volcánica. <http://sitiohistorico.sernageomin.cl/volcan.php?pagina=5&iId=22>.
- Sharma, B., Kumar, A., and Murthy, V. (2010). Evaluation of seismic events detection algorithms. *Journal of the Geological Society of India*, 75(3):533–538.
- Sheldrake, T. E., Sparks, R., Cashman, K., Wadge, G., and Aspinall, W. (2016). Similarities and differences in the historical records of lava dome-building volcanoes: Implications for understanding magmatic processes and eruption forecasting. *Earth-science reviews*, 160:240–263.
- Sherburn, S., Bryan, C. J., Hurst, A. W., Latter, J. H., and Scott, B. J. (1999). Seismicity of Ruapehu volcano, New Zealand, 1971–1996: A review. *Journal of Volcanology and Geothermal Research*, 88(4):255–278.
- Soto, R., Huenupan, F., Meza, P., Curilem, M., and Franco, L. (2018). Spectro-temporal features applied to the automatic classification of volcanic seismic events. *Journal of Volcanology and Geothermal Research*, 358:194–206.
- Sparks, R., Biggs, J., and Neuberg, J. (2012). Monitoring volcanoes. *Science*, 335(6074):1310–1311.
- Tárraga, M., Martí, J., Abella, R., Carniel, R., and López, C. (2014). Volcanic tremors: Good indicators of change in plumbing systems during volcanic eruptions. *Journal of Volcanology and Geothermal Research*, 273:33–40.
- Titos, M., Bueno, A., García, L., and Benítez, C. (2018). A deep neural networks approach to automatic recognition systems for volcano-seismic events. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(5):1533–1544.
- Titos, M., Bueno, A., García, L., Benítez, C., and Segura, J. C. (2019). Classification of isolated volcano-seismic events based on inductive transfer learning. *IEEE Geoscience and Remote Sensing Letters*, 17(5):869–873.

- Torres, C., Gómez, M., Narváez, M., et al. (1996). Unusual seismic signals associated with the activity at Galeras volcano, Colombia, from July 1992 to September 1994. *Annals of Geophysics*, 39(2):299 – 310.
- Triastuty, H., Iguchi, M., and Tameguri, T. (2009). Temporal change of characteristics of shallow volcano-tectonic earthquakes associated with increase in volcanic activity at Kuchinoerabujima volcano, Japan. *Journal of Volcanology and Geothermal Research*, 187(1-2):1–12.
- Trnkoczy, A. (2009). Understanding and parameter setting of STA/LTA trigger algorithm. In *New Manual of Seismological Observatory Practice (NMSOP)*, pages 1–20. Deutsches GeoForschungs-Zentrum GFZ.
- Trombly, R. (2006). *The Forecasting of Volcanic Eruptions*. iUniverse.
- Trujillo-Castrillón, N., Valdés-González, C. M., Arámbula-Mendoza, R., and Santacoloma-Salguero, C. C. (2018). Initial processing of volcanic seismic signals using hidden Markov models: Nevado del Huila, Colombia. *Journal of Volcanology and Geothermal Research*, 364:107–120.
- Tucker, S. and Brown, G. J. (2005). Classification of transient sonar sounds using perceptually motivated features. *IEEE Journal of Oceanic Engineering*, 30(3):588–600.
- Ursino, A., Langer, H., Scarfi, L., Di Grazia, G., and Gresta, S. (2001). Discrimination of quarry blasts from tectonic microearthquakes in the Hyblean Plateau (Southeastern Sicily). *Annals of Geophysics*, 44(4).
- Valade, S., Ley, A., Massimetti, F., D’Hondt, O., Laiolo, M., Coppola, D., Loibl, D., Hellwich, O., and Walter, T. R. (2019). Towards global volcano monitoring using multisensor sentinel missions and artificial intelligence: The mounts monitoring system. *Remote Sensing*, 11(13):1528.
- Van Daele, M., Moernaut, J., Silversmit, G., Schmidt, S., Fontijn, K., Heirman, K., Vandoorne, W., De Clercq, M., Van Acker, J., Wolff, C., et al. (2014). The 600 yr eruptive history of Villarrica volcano (Chile) revealed by annually laminated lake sediments. *Geological Society of America Bulletin*, 126(3-4):481–498.
- Vargas, C. A., Caneva, A., Monsalve, H., Salcedo, E., and Mora, H. (2018). Geophysical networks in Colombia. *Seismological Research Letters*, 89(2A):440–445.
- Venzke, E. (2013). Global volcanism program. Volcanoes of the world, v. 4.11. 0 (08 jun 2022).
- Verleysen, M. and François, D. (2005). The curse of dimensionality in data mining and time series prediction. In *International work-conference on artificial neural networks*, pages 758–770. Springer.
- Vila, J., Macià, R., Kumar, D., Ortiz, R., Moreno, H., and Correig, A. M. (2006). Analysis of the unrest of active volcanoes using variations of the base level noise seismic spectrum. *Journal of Volcanology and Geothermal Research*, 153(1-2):11–20.
- Wang, J., Xiao, Z., Liu, C., Zhao, D., and Yao, Z. (2019). Deep learning for picking seismic arrival times. *Journal of Geophysical Research: Solid Earth*, 124(7):6612–6624.

- West, M. E. (2013). Recent eruptions at Bezymianny Volcano — A seismological comparison. *Journal of Volcanology and Geothermal Research*, 263:42–57.
- Wilson, G., Wilson, T., Deligne, N., and Cole, J. (2014). Volcanic hazard impacts to critical infrastructure: A review. *Journal of Volcanology and Geothermal Research*, 286:148–182.
- Withers, M., Aster, R., Young, C., Beiriger, J., Harris, M., Moore, S., and Trujillo, J. (1998). A comparison of select trigger algorithms for automated global seismic phase and event detection. *Bulletin of the Seismological Society of America*, 88(1):95–106.
- Wu, H., Xiao, W., and Ren, H. (2022). Automatic time picking for weak seismic phase in the strong noise and interference environment: An hybrid method based on array similarity. *Sensors*, 22(24):9924.
- Yıldırım, E., Gülbağ, A., Horasan, G., and Doğan, E. (2011). Discrimination of quarry blasts and earthquakes in the vicinity of Istanbul using soft computing techniques. *Computers & Geosciences*, 37(9):1209–1217.
- Ying, C., Qi-Guang, M., Jia-Chen, L., and Lin, G. (2013). Advance and prospects of AdaBoost algorithm. *Acta Automatica Sinica*, 39(6):745–758.
- Yu, M., Yang, C., and Li, Y. (2018). Big data in natural disaster management: A review. *Geosciences*, 8(5):165.
- Yu, Z., Luo, P., You, J., Wong, H.-S., Leung, H., Wu, S., Zhang, J., and Han, G. (2015). Incremental semi-supervised clustering ensemble for high dimensional data clustering. *IEEE Transactions on Knowledge and Data Engineering*, 28(3):701–714.
- Zaugg, S., Van Der Schaar, M., Houégnigan, L., Gervaise, C., and André, M. (2010). Real-time acoustic classification of sperm whale clicks and shipping impulses from deep-sea observatories. *Applied Acoustics*, 71(11):1011–1019.
- Zeng, X.-Q. and Li, G.-Z. (2014). Incremental partial least squares analysis of big streaming data. *Pattern recognition*, 47(11):3726–3735.
- Zhang, J., Chen, L., Wang, C., Zhuo, L., Tian, Q., and Liang, X. (2017). Road recognition from remote sensing imagery using incremental learning. *IEEE Transactions on Intelligent Transportation Systems*, 18(11):2993–3005.
- Zhu, L., Peng, Z., and McClellan, J. (2018). Deep learning for seismic event detection of earthquake aftershocks. In *2018 52nd Asilomar Conference on Signals, Systems, and Computers*, pages 1121–1125. IEEE.
- Zimroz, R., Madziarz, M., Żak, G., Wyłomańska, A., and Obuchowski, J. (2015). Seismic signal segmentation procedure using time-frequency decomposition and statistical modelling. *Journal of Vibroengineering*, 17(6):3111–3121.
- Žliobaitė, I., Pechenizkiy, M., and Gama, J. (2016). An overview of concept drift applications. In *Big data analysis: new algorithms for a new society*, pages 91–114. Springer.

-
- Zobin, V. M. (2012). Volcano-tectonic earthquakes at andesitic volcanoes. In *Introduction to volcanic seismology*, volume 6. Elsevier.
- Zúñiga, M. D., Bremond, F., and Thonnat, M. (2013). Hierarchical and incremental event learning approach based on concept formation models. *Neurocomputing*, 100:3–18.