



Optimización de los parámetros libres de un clasificador de micro sismos basado en autoencoders, empleando espacios latentes

Mejía Martínez, Angie Nicole

Departamento de Eléctrica, Electrónica y Telecomunicaciones

Carrera de Ingeniería en Electrónica y Telecomunicaciones

“Trabajo de titulación previo a la obtención del título de Ingeniera en Electrónica y Telecomunicaciones”

Ing. Bernal Oñate, Carlos Paúl

16 de febrero de 2024



Plagiarism and AI Content Detection Report

Tesis Mejia Martinez Angie.pdf

Scan details

Scan time: February 15th, 2024 at 16:50 UTC

Total Pages: 51

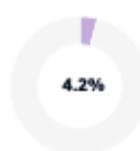
Total Words: 12642

Plagiarism Detection



Types of plagiarism	Words
Identical	0.6% 76
Minor Changes	0% 1
Paraphrased	2.8% 359
Omitted Words	0% 0

AI Content Detection



Text coverage	Words
AI text	4.2% 533
Human text	95.8% 12109

[Learn more](#)

🔍 Plagiarism Results: (14)

🌐 **Determinacion del volumen del casquete de hielo del volcan Cotopaxi** 0.7%

https://horizon.documentation.ird.fr/exl-doc/pleins_textes/divers12-05/D10039894.pdf

Caceres, B.; Ramirez, J.; Francou, Bernard; Eissen, Jean-Philippe; Taupin, Jean-Denis; Jordan, E.; Ungerechts, L.; Maisincho, L.; Barba, D.; Cadier, Eric; Bucher, Rodolphe; Penafiel, A.; Samaniego, Pablo; Mothes, P.
DETERMINACIÓN DEL VOLUMEN DEL , CASQUETE DE HIELO DEL VOLCAN COTOPAXI INAMHI Instituto Nacional de Meteorología e Hidrología IRD Instit...

🌐 **Plantilla PFC** 0.6%

https://upcommons.upc.edu/bitstream/handle/2117/395736/afg_borr%c3%a0s_garc%c3%ada.pdf?sequence=...

Rafael Ruiz

TRABAJO DE FINAL DE GRADO Grado en Ingeniería Mecánica APLICACIÓN DE ALGORITMOS DE MACHINE LEARNING PARA EL ANÁLISIS PREDICTIVO Memoria...

🌐 **Desarrollo y Análisis de Clasificadores de Señales de Audio** 0.5%

<https://riunet.upv.es/bitstream/handle/10251/90005/aguirre%20-%20desarrollo%20y%20an%c3%a1lisis%20d...>

Fabián Aguirre Martín

UNIVERSIDAD POLITÉCNICA DE VALENCIA ESCUELA POLITÉCNICA SUPERIOR DE GANDIA Máster en Ingeniería Acústica Desarrollo y análisis de clasif...

🌐 **match-redesneuronales.pdf** 0.4%

https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monografias/match-redesneu...

Universidad Tecnológica Nacional – Facultad Regional Rosario Departamento de Ingeniería Química Grupo de Investigación Aplicada a la Inge...



Certified by
Copyleaks

About this report
help.copyleaks.com

copyleaks.com
in f o t



Departamento de Eléctrica, Electrónica y Telecomunicaciones

Carrera de Ingeniería en Electrónica y Telecomunicaciones

Certificación

Certifico que el trabajo de titulación: "**Optimización de los parámetros libres de un clasificador de micro sismos basado en autoencoders, empleando espacios latentes**" fue realizado por la señorita **Mejía Martínez, Angie Nicole**; el mismo que cumple con los requisitos legales, teóricos, científicos, técnicos y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, además fue revisado y analizado en su totalidad por la herramienta de prevención y/o verificación de similitud de contenidos; razón por la cual me permito acreditar y autorizar para que se lo sustente públicamente.

Sangolquí, 16 de febrero de 2024



Firmado digitalmente por:
**CARLOS PAUL BERNAL
OÑATE**

.....
Bernal Oñate, Carlos Paúl

C. C. 170977563-7



Departamento de Eléctrica, Electrónica y Telecomunicaciones

Carrera de Ingeniería en Electrónica y Telecomunicaciones

Responsabilidad de Autoría

Yo, **Mejía Martínez, Angie Nicole**, con cédula de ciudadanía n°172076278-8, declaro que el contenido, ideas y criterios del trabajo de titulación: **Optimización de los parámetros libres de un clasificador de micro sismos basado en autoencoders, empleando espacios latentes** es de mi autoría y responsabilidad, cumpliendo con los requisitos legales, teóricos, científicos, técnicos, y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

Sangolquí, 16 de febrero de 2024

.....
Mejía Martínez, Angie Nicole

C.C.: 172076278 - 8



Departamento de Eléctrica, Electrónica y Telecomunicaciones

Carrera de Ingeniería en Electrónica y Telecomunicaciones

Autorización de Publicación

Yo **Mejía Martínez, Angie Nicole**, con cédula de ciudadanía n° 172076278 – 8, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: **Optimización de los parámetros libres de un clasificador de micro sismos basado en autoencoders, empleando espacios latentes** en el Repositorio Institucional, cuyo contenido, ideas y criterios son de mi responsabilidad.

Sangolquí, 16 de febrero de 2024

.....
Mejía Martínez, Angie Nicole

C.C.: 172076278 – 8

Dedicatoria

El trabajo de investigación está dedicado a Gloria Martínez, quien, en vida, siempre estuvo a mi lado apoyándome a cumplir cada idea o sueño que me proponía, por más difícil sea el proceso, pero siempre con una sonrisa en su rostro y con la confianza de que tarde o temprano lo conseguiría. De igual forma a mi madre Patricia y a mi hermana Estefanía, son y serán el impulso para poder mejorar a diario y con ello cumplir mis objetivos.

Agradecimientos

En primer lugar, doy gracias a Dios por permitirme llegar a este momento de mi vida, para poder continuar superando con sabiduría y perseverancia cada adversidad que se me presente.

A mi madre Patricia quien con su amor incondicional a estado para mí, en cada pequeño paso que daba, apoyándome e indicándome lo correcto e incorrecto, enseñándome a mejorar y dar mi mejor versión, sin retroceder en las decisiones que tomo y con las palabras adecuadas para continuar con lo que me propongo. También agradezco por la paciencia que ha tenido para enseñarme cada pequeña cosa, a pesar del cansancio siempre buscar una forma de calmar mi frustración y nunca rendirme.

A mi hermana Estefanía, por escuchar cada una de mis tonterías y saber aconsejarme, a pesar de estar ocupada, sin importar la distancia o la hora, por ser mi mejor amiga, nunca abandonarme ni por los disgustos y continuar protegiéndome, Te agradezco por ser mi ejemplo a seguir, quien me impulsa a competir, seguir esforzándome en mejorar y nunca rendirme.

A mis abuelitos Oswaldo y Emperatriz por el amor incondicional, los valores que supieron inculcar en mí, para continuar mis estudios y siempre estar al pendiente como mis segundos padres, cuando mi madre no podía hacerlo.

A mi tutor Paúl Bernal, por cada una de sus enseñanzas, tiempo, dedicación y paciencia en el proceso de elaboración del presente trabajo de titulación, así como su amistad y los consejos que supo darme para continuar creciendo en mi desarrollo profesional.

A cada uno de los amigos que han perdurado y hecho más fácil mi vida, con su apoyo incondicional, paciencia y las diversas experiencias que me han permitido compartir junto a ustedes, siempre al incluirme en cada uno de sus planes inesperados, a pesar de las ocupaciones o los desplantes.

Índice de Contenido

Resumen.....	16
Abstract.....	17
Capítulo I.....	18
Definición de Proyecto.....	18
Introducción.....	18
Antecedentes.....	20
Justificación e Importancia.....	21
Alcance.....	22
Objetivos.....	23
Objetivo General.....	23
Objetivos Específicos.....	23
Capitulo II.....	24
Marco Teórico.....	24
Volcán Cotopaxi.....	24
Actividad Eruptiva del Volcán Cotopaxi.....	25
Peligros del volcán Cotopaxi.....	25
Flujos Piroclásticos.....	25
Caídas de Piroclásticos.....	25
Flujos de lodo y escombros (Lahares).....	25
Monitoreo.....	26
Eventos Sismo–volcánicos.....	27

Volcano–Tectónicos (VT)	27
Largo periodo (LP).....	27
Eventos híbridos (HB)	28
Terremotos Regionales (RG)	28
Rupturas de Glaciar (ICE)	28
Características Espectrales	29
Centroide Espectral	29
Dispersión Espectral.....	29
Asimetría Espectral	30
Curtosis Espectral	30
Entropía	31
Planitud Espectral.....	31
Cresta Espectral	32
Flujo Espectral	32
Pendiente Espectral	32
Disminución Espectral.....	33
Reducción Espectral.....	33
Escalas Psicoacústicas.....	33
Escala Bark.....	33
Escala Mel	34
Escala ERB.....	34

	10
Machine Learning.....	35
Aprendizaje Supervisado	35
Aprendizaje No Supervisado.....	36
Aprendizaje Reforzado.....	36
Deep Learning.....	37
Redes Neuronales.....	37
Función de activación	39
Función Sigmoidea.....	39
Función Lineal Saturada	40
Algoritmos de Clasificación.....	41
Autoencoder	41
Árbol de decisión	42
Validación Cruzada de k–interacciones.....	42
Matriz de Confusión	43
Métricas de Desempeño	44
Exactitud	44
Precisión	45
Sensibilidad	45
Especificidad.....	45
BER.....	45
Espacios Latentes.....	46

	11
t-SNE.....	46
PCA.....	47
UMAP.....	48
Capitulo III.....	49
Materiales y Metodología.....	49
Generador	49
Base de datos.....	50
Extracción de Características	51
Preprocesamiento	51
Procesamiento.....	52
Características Espectrales.....	52
Entrenamiento de los modelos de clasificación.....	54
Validación cruzada de k iteraciones.....	54
Parámetros del Autoencoder.....	54
Espacios latentes	56
Capitulo IV.....	61
Análisis de Resultados	61
Pruebas de los Espacios Latentes	65
Conclusiones y Recomendaciones	79
Conclusiones.....	79
Recomendaciones	80

Trabajos Futuros	81
Referencias	82

Índice de Tablas

Tabla 1. <i>Ejemplo de Matriz de Confusión</i>	44
Tabla 2. <i>Parámetros del Autoencoder DT.</i>	55
Tabla 3. <i>Precisión, Exactitud, Sensibilidad, Escalabilidad y BER en las diferentes variaciones de Autoencoders en training</i>	61
Tabla 4. <i>Precisión, Exactitud, Sensibilidad, Escalabilidad y BER en las diferentes variaciones de Autoencoders en test</i>	62
Tabla 5. <i>Comparación de porcentaje de desempeño previos y posterior a la investigación</i>	63
Tabla 6. <i>Datos de posición, dispersión distancia de los centroides training (TR) reales y sintéticos.</i>	66
Tabla 7. <i>Datos de posición coordenadas esféricas y distancia de los centroides training (TR) reales y sintéticos.</i>	67
Tabla 8. <i>Datos de posición, dispersión y distancia de los centroides test (TS) reales y sintéticos.</i>	68
Tabla 9. <i>Datos de posición coordenadas esféricas y distancia de los centroides training (TS) reales y sintéticos.</i>	69

Índice de Figuras

Figura 1. <i>Forma del cráter del volcán Cotopaxi</i>	24
Figura 2. <i>Estaciones de Monitoreo del Volcán Cotopaxi</i>	26
Figura 3. <i>Sismograma y Espectrograma de un evento VT</i>	27
Figura 4. <i>Eventos LP de distintos volcanes</i>	28
Figura 5. <i>Modelo de una red neuronal</i>	38
Figura 6. <i>Función de activación Sigmoidea</i>	40
Figura 7. <i>Función de activación lineal saturada</i>	40
Figura 8. <i>Representación del Autoencoder</i>	42
Figura 9. <i>Diagrama de bloques acerca de la metodología investigación</i>	49
Figura 10. <i>Características Espectrales, Curtosis, Pendiente, Cresta, Flujo, Asimetría, Disminución</i>	53
Figura 11. <i>Características Espectrales, Planitud, Extensión, Centroide, Rolloff, Entropía</i>	53
Figura 12. <i>Espacio Latente en tres dimensiones de t - SNE, en training (TR)</i>	57
Figura 13. <i>Espacio Latente en tres dimensiones de PCA, en training (TR) y test (TS)</i>	58
Figura 14. <i>Espacio Latente en tres dimensiones de UMAP, en training (TR) y test (TS)</i>	59
Figura 15. <i>Espacio latente en dos dimensiones de UMAP con sus centroides</i>	60
Figura 16. <i>Matriz de Confusión de Datos con Data Augmentation</i>	64
Figura 17. <i>Matriz de Confusión de Datos Reales y Sintéticos</i>	65
Figura 18. <i>Señales y Centroides TR Reales y Sintéticas con t – SNE plano 1 - 2</i>	70
Figura 19. <i>Señales y Centroides TR Reales y Sintéticas con t – SNE plano 1 - 3</i>	70
Figura 20. <i>Señales y Centroides TR Reales y Sintéticas con t – SNE plano 2 - 3</i>	71
Figura 21. <i>Señales y Centroides TS Reales y Sintéticas con t – SNE plano 1 - 2</i>	71
Figura 22. <i>Señales y Centroides TS Reales y Sintéticas con t – SNE plano 1 - 3</i>	72
Figura 23. <i>Señales y Centroides TS Reales y Sintéticas con t – SNE plano 2 - 3</i>	72
Figura 24. <i>Señales y Centroides TR Reales y Sintéticas con PCA plano 1 - 2</i>	73

Figura 25. <i>Señales y Centroides TR Reales y Sintéticas con PCA plano 1 - 3</i>	73
Figura 26. <i>Señales y Centroides TR Reales y Sintéticas con PCA plano 2 - 3</i>	74
Figura 27. <i>Señales y Centroides TS Reales y Sintéticas con PCA plano 1 - 2</i>	74
Figura 28. <i>Señales y Centroides TS Reales y Sintéticas con PCA plano 1 - 3</i>	75
Figura 29. <i>Señales y Centroides TS Reales y Sintéticas con PCA plano 2 - 3</i>	75
Figura 30. <i>Señales y Centroides TR Reales y Sintéticas con UMAP plano 1 - 2</i>	76
Figura 31. <i>Señales y Centroides TR Reales y Sintéticas con UMAP plano 1 - 3</i>	76
Figura 32. <i>Señales y Centroides Tr Reales y Sintéticas con UMAP plano 2 - 3</i>	77
Figura 33. <i>Señales y Centroides TS Reales y Sintéticas con UMAP plano 1 - 2</i>	77
Figura 34. <i>Señales y Centroides TS Reales y Sintéticas con UMAP plano 1 - 3</i>	78
Figura 35. <i>Señales y Centroides TS Reales y Sintéticas con UMAP plano 2 - 3</i>	78

Resumen

El Ecuador es un país que está ubicado geográficamente en el cinturón de fuego del Pacífico, lo que conlleva tener diferentes volcanes activos, entre ellos el Cotopaxi, que, al estar poblado de zonas rurales y urbanas, lo vuelve un tema de investigación, en cuanto a la predicción de un posible siniestro. Este proceso es llevado a través de diferentes sensores que predicen distintos tipos de eventos como volcans tectónico o largo periodo, mismos que permiten visualizar el comportamiento del volcán.

El clasificador de micro terremotos propuesto emplea autoencoders para llevar a cabo un aprendizaje automático, en cuanto a la predicción de una posible catástrofe, a través de la base de datos de los eventos del volcán Cotopaxi, proporcionado por el Instituto Geofísico de la Escuela Politécnica Nacional (IGEPN), se lleva a cabo el entrenamiento del clasificador, mismo que debe ser evaluado para demostrar su efectividad.

El trabajo de investigación tiene como propósito el evaluar el clasificador de micro terremotos por medio de autoencoders, para ello se hace uso de los espacios latentes, mismos que permiten conocer de forma gráfica la correlación entre los diferentes eventos. Adicional a esto se empleó un generador de eventos sísmicos del volcán Cotopaxi, con la finalidad de comparar los resultados obtenidos con la data augmentation de los datos reales y sintéticos.

El análisis es llevado a cabo en el dominio de la frecuencia y se emplea con once características espectrales, mismas que permiten conocer cada una de las variaciones que poseen los datos, además se emplean tres modelos para los espacios latentes como son UMAP, PCA y t – SNE, para poder determinar el mejor de ellos, al evaluar al clasificador y el generador de forma cualitativa y cuantitativa.

Palabras Clave: volcans tectónico, largo periodo, clasificador de micro terremotos, espacios latentes, señales sintéticas.

Abstract

Ecuador is a country that is geographically located in the Pacific Ring of Fire, which leads to have different active volcanoes, including Cotopaxi, which, being populated by rural and urban areas, makes it a subject of research, in terms of predicting a possible disaster. This process is carried out through different sensors that predict different types of events such as tectonic volcano or long period, which allow visualizing the behavior of the volcano.

The proposed micro-earthquake classifier uses autoencoders to carry out automatic learning, in terms of predicting a possible catastrophe, through the database of events of the Cotopaxi volcano, provided by the Geophysical Institute of the National Polytechnic School (IGEPN), the training of the classifier is carried out, which must be evaluated to demonstrate its effectiveness.

The purpose of the research work is to evaluate the microearthquake classifier by means of autoencoders, using latent spaces, which allow us to know graphically the correlation between the different events. In addition to this, a seismic event generator of the Cotopaxi volcano was used to compare the results obtained with the augmentation data of real and synthetic data.

The analysis is carried out in the frequency domain and is used with eleven spectral characteristics, which allow us to know each of the variations in the data, and three models are used for latent spaces such as UMAP, PCA and t - SNE, in order to determine the best of them, to evaluate the classifier and the generator qualitatively and quantitatively.

Keywords: tectonic volcano, long period, microearthquake classifier, latent spaces, synthetic signals.

Capítulo I

Definición de Proyecto

Introducción

El Ecuador, si bien es un país que posee toda clase de recursos que pueden ser extraídos de la naturaleza, también cuenta con una probabilidad bastante elevada de sufrir fenómenos naturales, tales como deslizamientos de tierra, sismos, erupciones volcánicas, aludes, entre otros. Esto, debido a tener su posición geográfica dentro del Cinturón de Fuego del Pacífico y al encontrarse atravesado por la Cordillera de los Andes, lo que lo vuelve un país prominente a los desastres naturales (Guzmán & Gallegos, s. f.). Entre los peligros que más se resaltan en el país están las erupciones volcánicas, debido a los asentamientos de personas que se han situado en las faldas o alrededores de los cráteres. Dicho problema ha hecho que se realice un monitoreo constante a las condiciones o eventos que posee cada volcán, aunque, dadas las características que presenta cada uno son diferentes y dificultosos para su análisis.

En (Minango Guatumillo, 2022), se proponen dos modelos de entrenamiento: uno supervisado y el otro no. Esto, con la finalidad de realizar la clasificación de eventos sismo-volcánicos al tomar en cuenta características psico acústicas e implementar señales volcánicas de diferentes eventos que se pueden obtener para elaborar un análisis de clasificación. Cabe mencionar que las señales volcánicas son: largo período (LP), volcano tectónico (VT), híbridos (HB), regionales (RG) y por deslizamiento glaciares (IC). Estas son empleadas en conjunto de diversas técnicas especializadas.

Entre las técnicas utilizadas en el proyecto esta k -Vecino más cercano (k -NN). Este algoritmo permite calcular la distancia de un elemento nuevo a cada uno de los que ya existen para después poder ordenar de menor a mayor las distancias y, finalmente, seleccionar el

grupo al que pertenece (*Evaluación de Técnicas de Extracción de Características Orientado a la Clasificación de Señales Sísmico-volcánicas del Volcán Nevado del Ruiz - ProQuest, s. f.-a*).

Otra técnica empleada es la de Árboles de Decisiones (DT), se implementa a la inteligencia artificial para la predicción y algunas aplicaciones; para ello, se utiliza una base de datos, con la cual se construye diagramas en forma de árbol, de esta manera se llega a la solución de un problema a través de la representación y categorización de una serie de condiciones que se dan de manera repetitiva. Estas dos técnicas tienen su finalidad en llevar a cabo un modo de aprendizaje supervisado (Sefla, s. f.), el cual es realizado a partir de los datos proporcionados por el Instituto Geofísico de la Escuela Politécnica Nacional (IGEPN), acerca del volcán Cotopaxi.

A más de las técnicas mencionadas, se han llevado diversas investigaciones con la finalidad de emplear un modo de aprendizaje no supervisado. La *Deep Neural Networks* (DNNs) una de ellas, misma que podría identificar los eventos sismo-volcánicos. Es preciso mencionar que, una de las arquitecturas de DNNs es por *autoencoders* o codificadores automáticos, se emplea la eliminación de ruidos apilados y redes profundas a través de una predicción lineal y propiedades estadísticas para poder cumplir con el propósito establecido (Titos et al., 2018).

Por último, es importante mencionar que los espacios latentes son una forma de conocer las características de los diferentes modelos de entrenamiento, depende de los parámetros que se necesite conocer, estos se vuelven efectivos debido a que permiten conocer la correlación de cada uno de los eventos de forma gráfica. Por ejemplo, en un estudio para separar fuentes musicales por medio de redes neuronales (de Leonardo Pepino y Laurence Bender), se emplean espacios latentes dado que permite observar las características que poseen las redes neuronales y cómo se lleva el proceso de separación de las fuentes

musicales para indicar de esta forma que los espacios latentes son utilizados para visualizar ampliamente el comportamiento de una red neuronal (Pepino & Bender, 2018).

Antecedentes

A continuación, se indican varias técnicas para realizar una discriminación de diferentes eventos sísmicos, las cuales consisten en la representación de señales en el dominio del tiempo, frecuencia del tiempo y Cepstral.

En (*Evaluación de Técnicas de Extracción de Características Orientado a la Clasificación de Señales Sísmico-volcánicas del Volcán Nevado del Ruiz - ProQuest*, s. f.-b), se empleó un modelo supervisado, debido a los cambios continuos que poseen los diferentes parámetros volcánicos al indicar la dificultad que se posee al pretender implementar un modelo no supervisado.

En la investigación acerca de un modelo no supervisado, (Lara-Cueva et al., 2016) emplearon el dominio del tiempo por medio de la densidad espectral de los diferentes eventos, al mismo tiempo que se basó en algoritmos de decisión con la finalidad obtener un alto porcentaje de aciertos.

En la importancia de evaluar los movimientos telúricos a través de procesos gaussianos, (Alvarez et al., 2007) utilizaron coeficientes de modelos autoregresivos con el fin de estimar la densidad espectral de la potencia.

En el sistema semiautomático y la toma de señales sísmicas, (Leon et al., 2020), recurrió a vectores características para realizar una clasificación de las señales obtenidas del sismógrafo.

En el método automático para la clasificación de eventos sísmicos, (Kortström et al., 2016), usaron una técnica de reconocimiento de patrones supervisada, la cual posee el nombre

de *Support Vector Machine*. Esta técnica emplea una distribución de la energía de la señal entre fuentes sísmicas naturales y artificiales.

Para el agrupamiento y la clasificación de eventos sísmicos volcánicos–tectónicos de largo período, (Duque et al., 2020), basaron su investigación en el uso de seis métodos diferentes con la finalidad de encontrar posibles señales superpuestas de origen no volcánico que podrían ocurrir al mismo tiempo o inmediatamente después de ocurrir algún evento sísmico-volcánico.

En el detector de correlación multicanal progresiva y un clasificador estadístico de series de tiempo, (Bui Quang et al., 2015), fundamentaron su artículo en modelos ocultos de Markov asociados para la detección y clasificación de eventos sísmicos en una estación de matriz.

En la evaluación exhaustiva de cinco métodos diferentes de selección de características, (Aribido et al., 2021), centraron su investigación en filtros en combinación con un clasificador de modelo de mezcla gaussiana para la clasificación de eventos sísmicos de período largo y volcán-tectónicos registrados en el volcán Cotopaxi, en Ecuador.

Justificación e Importancia

El uso de un modelo de entrenamiento no supervisado puede ser la solución para el problema identificado, pero se debe tener en cuenta que los volcanes son variables en cuanto a sus condiciones lo que complica su análisis. Por tanto, con los espacios latentes de las características espectrales se pueden prevenir las fallas que posee el modelo de entrenamiento e indicar posibles cambios a realizar para poder mejorarlo. Dado que los espacios latentes permiten obtener características que no se pueden interpretar directamente, estos buscan generar una representación de forma espacial cuantitativa, lo que permite encontrar las posibles mejoras o fallas que pueda tener el modelo de entrenamiento.

La aplicación de escalas psico acústicas y análisis de componentes principales (PCA), técnica de incrustación de vecinos estocásticos distribuidos (t – SNE) y la aproximación y proyección de colector uniforme (UMAP), también el uso de *autoencoders* presentan una solución frente a la clasificación sísmica de manera automática, sin embargo, se debe conocer (posterior a una evaluación) cada una de las características que poseen los modelos de entrenamiento y, con base en los resultados cambiar el método para la reducción de características o indicar el camino a tomar para poder obtener la funcionalidad efectiva del modelo no supervisado (Proaño Portilla, 2022).

Alcance

La presente investigación busca contribuir y mejorar a los estudios anteriores acerca del clasificador de micro terremotos-volcánicos, a través de las señales recopiladas el IGEPN, en el periodo de los años 2012 y 2019; además de complementar los datos con señales obtenidas a partir de un generar de este tipo de señales proporcionadas de la investigación (Galarza Cruz & Vega Vergara, 2022). El sistema se desarrollará en el *software* MATLAB® seguirá el mismo proceso implementado en la investigación de (Minango Guatumillo, 2022), la cual basa su estudio en emplear un proceso de extracción de características espectrales representadas en escalas psico acústicas como: Mel (del inglés *Melody*, permite indicar la percepción humana de los tonos), Bark o banda crítica (su nombre proviene de Heinrich Barkhausen, quien propone la medida subjetiva de la intensidad del tono) y, finalmente, la escala ERB (del inglés *Equivalent Rectangular Bandwidth*) (Glasberg & Moore, 1990). Todo ello con el propósito de definir las características que poseen mayor información para posteriormente probarlas en modelos de clasificación supervisada y no supervisada. Esto último a través de *autoencoders*.

Los resultados obtenidos de los modelos de clasificación se observarán en la matriz de confusión, por medio de métricas de desempeño se aprecia si el incremento y emparejamiento de datos a través de señales genéricas permite un mejor aprendizaje; además, y como

resultado de ello, la identificación del tipo de evento sismo-volcánico que se presenta. Es decir, si se trata de Largo Periodo, Volcano Téctonico, Terremotos Regionales, Eventos Híbridos o Rupturas de Glaciar.

Con ayuda de la implementación de espacios latentes se puede conocer el aprendizaje obtenido a partir de los modelos de clasificación y los posibles parámetros a modificar, con la finalidad de mejorar las métricas de desempeños de la investigación anterior y contribuir en la búsqueda de un sistema para una toma de decisiones más eficiente, por parte de los especialistas del IGEPN, con referencia a potenciales actividades volcánicas del Cotopaxi.

Objetivos

Objetivo General

Optimizar los parámetros libres de un clasificador de micro terremotos basado en *autoencoders*, empleando espacios latentes.

Objetivos Específicos

- Analizar la correlación de los modelos de entrenamiento de la clasificación sísmica utilizando espacios latentes de las características espectrales.
- Evaluar el desempeño de los modelos de entrenamiento al trabajar con *autoencoders*.
- Mejorar el porcentaje de desempeño al optimizar los parámetros libres de un clasificador.
- Identificar los parámetros que maximicen el porcentaje de acierto de un evento sísmico.

Capítulo II

Marco Teórico

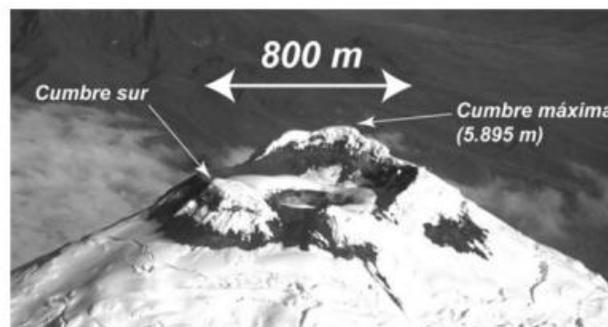
Volcán Cotopaxi

El volcán Cotopaxi tiene sitio en la Cordillera Oriental de los Andes, es el segundo más grande del Ecuador con 5897 metros sobre el nivel del mar (m.s.n.m). Está cubierto con un casquete glaciar, mismo que tiene una dimensión de aproximadamente 14km^2 y un volumen de 0.7km^3 y es la fuente de varios sistemas fluviales importantes, aunque en los últimos años se ha podido visualizar una notable reducción del mismo a causa del calentamiento global.

Su cráter es de forma circular y tiene una dimensión de aproximadamente 800m. En cuanto a la profundidad del mismo, tiene una medida superior a los 100m. En sus orillas se puede evidenciar la presencia de continuas emanaciones fumarólicas, las cuales pueden observarse en la Figura 1 (Andrade et al., 2005).

Figura 1.

Forma del cráter del volcán Cotopaxi



Nota. Tomado de (Andrade et al., 2005)

Actividad Eruptiva del Volcán Cotopaxi

Su actividad volcánica viene dada en promedio periódico cada siglo, a través de diferentes estudios se pudo determinar dos tipos de eventos principales: erupciones andesíticas (erupción moderada) y riolíticas (erupción de gran magnitud y extensión). Por tanto, se define al Cotopaxi como un volcán bimodal que tiene, en los últimos 4000 años, diferentes estilos eruptivos: desde leves con emisión de ceniza hasta fuertes con la expulsión de diferentes flujos piroclásticos, ceniza e inciertamente flujos de lava.

Peligros del volcán Cotopaxi.

Flujos Piroclásticos

Son nubes con una temperatura igual o superior a las 500° C, mismas que están formadas por una variedad de gases, ceniza y fragmentos de roca que descienden por el volcán. En el año de 1877 se pudo visualizar flujos piroclásticos en el volcán Cotopaxi. Los pobladores supieron informar que esto se asemejaba a “una olla de arroz en ebullición”; sin embargo, solo se presentó un riesgo moderado, dado que los flujos piroclásticos no han alcanzado grandes distancias.

Caídas de Piroclásticos

Es un compuesto formado por ceniza, fragmentos de roca y piedra pómez, los cuales son arrojados del volcán y pueden alcanzar una altura de aproximadamente 20 km (en caso de una fuerte erupción). El nivel de peligro que se tenga dependerá del volumen de material emitido, intensidad y duración de caída que se tengan en la erupción.

Flujos de lodo y escombros (Lahares)

Es uno de los mayores peligros que se puede presentar en cuanto al volcán Cotopaxi, los lahares pueden alcanzar un volumen considerable, con lo cual se cubre varias áreas, lo que afecta a diversas zonas pobladas (Cáceres et al., s. f.).

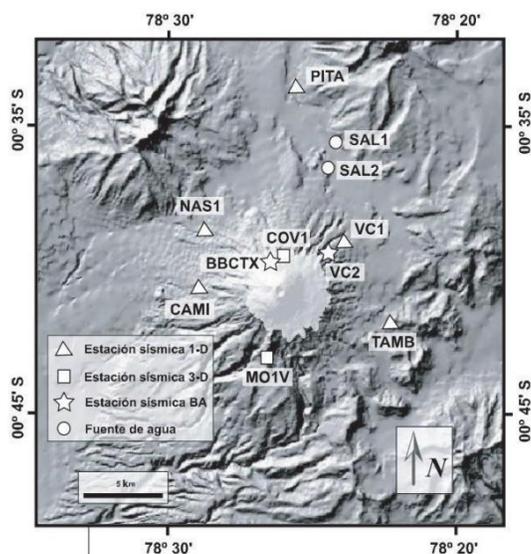
Monitoreo

El volcán Cotopaxi permanece en un monitoreo constante, se mantiene un monitoreo visual y otro de forma instrumental.

- Monitoreo Visual: Se basa en sentidos humanos, mismos que son detectados por vulcanólogos mediante observaciones permanentes.
- Monitoreo instrumental: Se lleva a cabo con instrumentos elementales como termómetros, uso de satélites y cámaras térmicas, su objetivo será determinar la sismicidad, deformación de fumarolas, aguas termales, temperatura superficial y glaciares. Este monitoreo se lo lleva a cabo las 24 horas del día por parte del Instituto Geofísico de la Escuela Politécnica Nacional. En la Figura 2 se puede apreciar las diferentes estaciones que se encargan del monitoreo del volcán Cotopaxi (Zapata Yugsi, 2022).

Figura 2.

Estaciones de Monitoreo del Volcán Cotopaxi



Nota. tomado de (Zapata Yugsi, 2022).

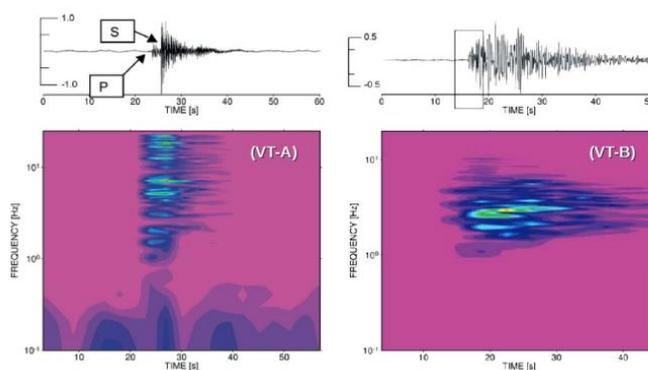
Eventos Sismo–volcánicos

Volcano–Tectónicos (VT)

Son sismos producidos en el marco local del volcán, dados por la tensión en el edificio volcánico. Esta clase de eventos causa la acumulación de energía y variaciones de presión y son capaces de reactivar fallas locales o generar fracturas y deformaciones en un medio rocoso y frágil. Por lo general, su duración es de alrededor de un minuto. En la Figura 3 se puede observar el sismograma y espectrograma de dos subclases de eventos VT (profundos y superficiales).

Figura 3.

Sismograma y Espectrograma de un evento VT



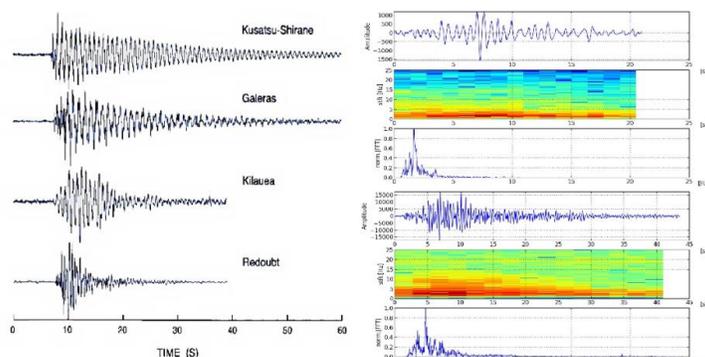
Nota. tomado de (Moreno, 2015).

Largo periodo (LP)

Caracterizados por su baja frecuencia, son superficiales y con una duración similar a los VTs. En cuanto a su contenido espectral, cuentan con un intervalo de frecuencias [0.1, 10]Hz, en la Figura 4 se puede observar diferentes LP de distintos volcanes, se aprecia también la variabilidad tanto temporal como espectral que caracteriza a la mayoría de eventos volcánicos (Moreno, 2015).

Figura 4.

Eventos LP de distintos volcanes



Nota. Tomado de (Moreno, 2015).

Eventos híbridos (HB)

Señales que poseen una banda espectral alta con frecuencias mayores a 10 Hz y comparten varias características con eventos VT y LP, dado que su proceso se relaciona al momento de fluido y al agrietamiento de material cortical o corteza de la terrestre del planeta. Además, ocurren de forma superficial y se asocian al crecimiento de domos (Centeno Quico & Rivera, 2020).

Terremotos Regionales (RG)

Los eventos de tipo RG se suscitan en los bordes tectónicos de las placas y su energía espectral se encuentra alrededor de los 10Hz (Camacho Calle, 2022).

Rupturas de Glaciar (ICE)

Eventos cuya presencia se da en volcanes de glaciar (Galarza Cruz & Vega Vergara, 2022).

Características Espectrales

Se encuentran conformadas por parámetros de frecuencia denominados como descriptores con variación en el tiempo, los cuales son calculados por medio de la transformada de Fourier de corta duración (STFT, siglas del inglés *Short – Time Fourier*), al segmentar la señal en intervalos definidos a través del tiempo (Medina et al., 2018) y los coeficientes discretos (DFT). Las variables principales que se destacan en cuanto a la parte matemática son la frecuencia de segmentos individuales en Hz y el valor espectral.

Centroide Espectral

El centroide espectral es aquel que contribuye con información acerca del espectro y define el centro de gravedad del mismo y la energía espectral. De esta forma, es considerado una distribución de probabilidad, determinada por la amplitud del espectro para cada frecuencia, es así que se obtiene la frecuencia media ponderada en amplitud. En (Lerch, 2012) se define al centroide como la suma ponderada de la frecuencia del espectro de potencia normalizado por su suma no ponderada. Esto se puede visualizar en la ecuación (1), donde b_1 y b_2 son los bordes de banda en contenedores, para el cálculo de centroide espectral y s_κ es el valor espectral en bin κ (espectro de magnitud y espectro de potencia).

$$\mu_1 = \frac{\sum_{\kappa=b_1}^{b_2} f_\kappa S_\kappa}{\sum_{\kappa=b_1}^{b_2} S_\kappa} \quad (1)$$

Dispersión Espectral

La dispersión espectral, también denominada ancho de banda instantáneo, indica la concentración de energía alrededor de la media (el centroide espectral). Se puede interpretar mediante la desviación estándar de la potencia espectral alrededor del centroide espectral. La ecuación (2) define a la dispersión espectral (Lerch, 2012).

$$\mu_2 = \sqrt{\frac{\sum_{k=b_1}^{b_2} (f_k - \mu_1)^2 S_k}{\sum_{k=b_1}^{b_2} S_k}} \quad (2)$$

Asimetría Espectral

La asimetría *Spectral Skewness* mide la simetría de la distribución de los valores de magnitud espectral aproximado a su media aritmética (Lerch, 2012). El procedimiento está definido por la ecuación (3).

$$\mu_3 = \frac{\sum_{k=b_1}^{b_2} (f_k - \mu_1)^3 S_k}{(\mu_2)^3 \sum_{k=b_1}^{b_2} S_k} \quad (3)$$

Curtosis Espectral

La curtosis espectral es un análisis en el dominio de la frecuencia basado en la Transformada Discreta de Fourier, se realizan dichos procesos a cada una de las señales separadas o divididas en M realizaciones no separadas. La curtosis también posee la capacidad de diferenciar entre frecuencias que se mantienen constantes en el tiempo, además del ruido y frecuencias que presentan un cambio brusco en cuanto a su amplitud. (Sierra Fernández, 2017). En ese caso, la curtosis se conoce como el cuarto momento central de una variable dividido por la cuarta potencia de la desviación estándar, algunas definiciones suelen restar 3 del valor calculado, quedando la distribución normal con una curtosis de 0. Al emplear la función en MATLAB® se utiliza la ecuación (4), en la que μ es la media y σ es la desviación estándar de x , $E(t)$ es el valor esperado de la cantidad t ; mientras que la curtosis espectral mide la distribución de los valores de magnitud espectral que se dan en forma de distribución gaussiana o no y se pueden observar cómo está definida en la ecuación (5)

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

$$\mu_4 = \frac{\sum_{k=b_1}^{b_2} (f_k - \mu_1)^4 s_k}{(\mu_2)^4 \sum_{k=b_1}^{b_2} s_k} \quad (5)$$

La curtosis no está definida para señales con desviación estándar igual a 0.

Entropía

La entropía es una técnica no lineal basada en la teoría de la información de Shannon, es un índice de medida de la complejidad de un sistema incierto. Esto permite el análisis y comparación de la distribución de probabilidad para proporcionar la información de cualquier distribución. El proceso se expresa como la ecuación (6).

$$entropy = \frac{-\sum_{k=b_1}^{b_2} s_k \log(s_k)}{\log(b_2 - b_1)} \quad (6)$$

La entropía permite cuantificar la imprevisibilidad de las variaciones en las señales deterministas y estocásticas. Este concepto se emplea en el espectro de potencia como una medida de la incertidumbre del tiempo en el dominio de la frecuencia (Medina et al., 2018).

Planitud Espectral

La planitud espectral o coeficiente de tonalidad es la medida contraria a la proporción de potencia tonal, un resultado aproximado a 1 pertenece al espectro con una cantidad de potencia similar a todas las bandas. En caso de tener una baja planitud o aproximada a cero, correspondería a un tono puro, para lo cual se emplea la relación entre la media geométrica y la media aritmética. La operación se encuentra definida por medio de la ecuación (7) (Roy Martínez, 2020).

$$flatness = \frac{\left(\prod_{k=b_1}^{b_2} s_k\right)^{\frac{1}{b_2-b_1}}}{\frac{1}{b_2-b_1} \sum_{k=b_1}^{b_2} s_k} \quad (7)$$

Cresta Espectral

La cresta espectral caracteriza la impulsividad de los eventos sonoros que se presentan en una medición. Está definido por la relación que existe entre el valor máximo y el valor de RMS (Raíz Cuadrática Media), en cuanto a la precisión. Se define a la cresta espectral mediante la ecuación (8) (Munive Benites, 2016).

$$crest = \frac{\max(s_{\kappa \in [b_1, b_2]})}{\frac{1}{b_2 - b_1} \sum_{\kappa=b_1}^{b_2} s_{\kappa}} \quad (8)$$

Flujo Espectral

El flujo espectral o variación espectral indica la diferencia de promedios entre cuadros STFT (Transformada de Fourier de corto tiempo) consecutivos. Se puede medir la cantidad de cambio de la forma espectral, a través del procedimiento definido en la ecuación (9), la cual muestra al resultado de la ecuación dentro del rango $0 \leq flux \leq A$, A representa la máxima magnitud espectral posible. Por ello, su salida dependerá de la normalización (p) de la señal de audio y la transformada de frecuencia.

$$flux = \left(\sum_{\kappa=b_1}^{b_2} |s_{\kappa}(t) - s_{\kappa}(t-1)|^p \right)^{\frac{1}{p}} \quad (9)$$

Pendiente Espectral

La pendiente espectral es similar a la disminución espectral, pero esta última representa el grado de decaimiento de la amplitud espectral. Se debe realizar una regresión lineal, luego de obtener la pendiente de la recta. Este proceso se define por medio de la ecuación (10) (Lerch, 2012).

$$slope = \frac{\sum_{k=b_1}^{b_2} (f_k - \mu_f)(s_k - \mu_s)}{\sum_{k=b_1}^{b_2} (f_k - \mu_f)^2} \quad (10)$$

Disminución Espectral

La disminución espectral muestra el grado de decaimiento de la amplitud espectral con respecto a la disminución de la envolvente espectral sobre frecuencia. El proceso está definido a través de la ecuación (11).

$$descrease = \frac{\sum_{k=b_1+1}^{b_2} \frac{S_k - S_{b_1}}{K - 1}}{\sum_{k=b_1+1}^{b_2} S_k} \quad (11)$$

Reducción Espectral

La reducción o distribución de probabilidad es el valor con el que se supera una probabilidad en la distribución de probabilidad acumulada, se puede emplear un *roll-off* entre 0.85 y 0.95 de probabilidad. En cuanto a términos espectrales, indica la frecuencia para el porcentaje de la distribución de energía acumulada, por lo que el resultado de la atenuación espectral es un índice bin en un rango de $0 \leq v_{SR}(n) \leq K/2 - 1$. Se puede observar su definición con la ecuación (12) (Lerch, 2012).

$$v_{SR}(n) = i \sum_{k=0}^i |X(k, n)| = k \cdot \sum_{k=0}^{K/2-1} |X(k, n)| \quad (12)$$

Nota. Se puede variar el 0.85, esto depende de la probabilidad que se desea. En el ejemplo se muestra un caso en el cual la ecuación a utilizarse para un *roll-off* está dada al 85%.

Escalas Psicoacústicas

Escala Bark

La escala de Bark permite la medida psicoacústica, se definen rasgos. Dicha escala parte de 1 hasta 24, con la finalidad de comprender y medir las bandas críticas de audición en

Hz con sus respectivos centros. Se relaciona la frecuencia absoluta con las frecuencias medidas perceptualmente, un sonido en dominio de la frecuencia puede ser llevado o convertido a uno en dominio psico acústico. De esta forma, un tono puro se puede representar como una curva de enmascaramiento psico acústico (Duque Pilataxi & Tipantuña Tenelema, 2010).

Escala Mel

La escala de Mel se basa en los principios de la percepción auditiva humana y las frecuencias, las cuales no sigue un patrón lineal, sino que posee un comportamiento no uniforme. Esta escala simboliza una aproximación de la sensibilidad auditiva y considera la respuesta no lineal del oído humano ante varias frecuencias. Su aplicación principal es en el procesamiento de audio e incluye tareas como la compresión, la separación de fuentes sonoras y la codificación de voz (Deng & Huang, 2014; Hu & Wang, 2019).

Escala ERB

La escala ERB consiste en el principio de que la percepción humana de las frecuencias no es uniforme, sino posee variaciones según la frecuencia. Esta escala tiene respuesta no lineal del oído humano a diferentes frecuencias y proporciona una medida de la resolución auditiva en cada banda de frecuencia. Se emplea principalmente en aplicaciones de procesamiento de audio, como la compresión de audio, la modelización de la audición humana y el diseño de sistemas de reproducción de sonido (Dau, Püschel, & Kohlrausch, 1996; Glasberg & Moore, 1990).

El cálculo de la escala ERB se realiza con una transformación matemática no lineal a las frecuencias en Hz, se asigna valores de ERB a diferentes frecuencias y una unidad de ERB representa una banda de frecuencia perceptualmente equivalente en términos de resolución auditiva. La escala ERB comúnmente se representa en un gráfico que indica la relación entre

las frecuencias en Hertz y las unidades de ERB (Glasberg & Moore, 1990). Para la conversión de Hz a escala ERB se emplea la ecuación (13).

$$ERB = 21.3 \log_{10} \left(1 + \frac{f}{228.7} \right) \quad (13)$$

Machine Learning

El *machine learning* o aprendizaje automático consiste en el sistema del aprendizaje de los sistemas informáticos a través de la experiencia y la mejora de su rendimiento en tareas específicas, por medio del análisis y la interpretación de grandes conjuntos de datos (Bishop, 2006). Los algoritmos de aprendizaje automático permiten la identificación de patrones y relaciones en los datos, se emplea esta información para ejecutar predicciones o tomar decisiones (Hastie, Tibshirani, & Friedman, 2021). El aprendizaje automático tiene varios tipos como: supervisado, no supervisado y reforzado.

Aprendizaje Supervisado

El aprendizaje automático supervisado indica una estrategia dentro del campo del aprendizaje automático, se basa en el entrenamiento y en la utilización de ejemplos de datos que poseen etiquetas conocidas, es decir, se proporcionan datos de entrenamiento que contienen características (*inputs*) con las correspondientes etiquetas o resultados deseados (*outputs*) asociados (Hastie, Tibshirani, & Friedman, 2021). El aprendizaje automático supervisado tiene como objetivo principal permitir el aprendizaje del modelo en cuanto a la generalización y realización de predicciones precisas acerca de nuevos datos, parte de los patrones y relaciones reconocidas en los ejemplos de entrenamiento.

El proceso de aprendizaje automático supervisado involucra la elección de un algoritmo apropiado y la etapa de entrenamiento ajusta los parámetros del modelo a través de los datos etiquetados disponibles para luego ser evaluados al emplear un conjunto de datos separado,

conocido como conjunto de prueba, con el fin de valorar su rendimiento y capacidad predictiva (Hastie et al., 2021).

Aprendizaje No Supervisado

El aprendizaje automático no supervisado trata acerca de una estrategia en el campo del aprendizaje automático, un modelo a entrenar emplea datos que carecen de etiquetas o categorías predefinidas. Se diferencia del aprendizaje supervisado por utilizar salidas esperadas en el proceso de entrenamiento. En cambio, el modelo no supervisado ha sido desarrollado con el fin de descubrir patrones, estructuras o relaciones ocultas en los datos por sí mismo (Hastie, Tibshirani, & Friedman, 2021). El aprendizaje automático no supervisado tiene como objetivo extraer información útil y significativa de los datos sin la guía explícita de las etiquetas.

En este tipo de aprendizaje, los algoritmos indagan los datos y los agrupan en categorías o identifican patrones de similitud entre las muestras. Algunas técnicas comunes incluyen el *clustering*, la detección de anomalías y la reducción de la dimensionalidad (Hastie et al., 2021), las cuales permiten examinar y comprender la estructura interna de los datos y, a su vez, proporcionar ideas que faciliten la toma de decisiones en distintas aplicaciones.

Aprendizaje Reforzado

El aprendizaje automático reforzado trata acerca de un agente de inteligencia artificial para mejorar su rendimiento por medio de la interacción con un entorno y la retroalimentación en forma de recompensas o penalizaciones (Sutton & Barto, 2018). En función de esto, se toman acciones con base a un entorno y se recibe una retroalimentación acerca de la calidad de esas acciones. Así, se emplea la información para ajustar su procedimiento y maximizar las recompensas almacenadas a lo largo del tiempo.

El aprendizaje automático reforzado tiene como objetivo el aprendizaje de una política óptima, es decir, una estrategia de maximización con respecto a la obtención de recompensas a largo plazo, estas se logran a través de técnicas como el proceso de toma de decisiones de Markov (MDP), algoritmos de valoración y métodos de búsqueda y optimización (Sutton & Barto, 2018). De esta manera, se permite el aprendizaje del agente en función a la toma de decisiones, se toma en cuenta la información disponible para optimizar su comportamiento en función de la interacción con el entorno y la retroalimentación.

Deep Learning

El *deep learning*, también conocido como aprendizaje profundo, se enfoca en el entrenamiento de redes neuronales profundas para llevar a cabo tareas complejas de procesamiento y reconocimiento de datos. A diferencia de los enfoques tradicionales de aprendizaje automático, las características se seleccionan manualmente, el aprendizaje profundo permite que el modelo aprenda automáticamente las representaciones de características a partir de los datos disponibles (Goodfellow, Bengio, & Courville, 2016).

Las redes neuronales profundas están formadas por varias capas de unidades de procesamiento llamadas neuronas, mismas que se organizan en una estructura jerárquica. Cada capa de neuronas extrae características de alto nivel a partir de las características extraídas por las capas anteriores, lo que permite un procesamiento más complejo y abstracto de los datos (LeCun, Bengio, & Hinton, 2015).

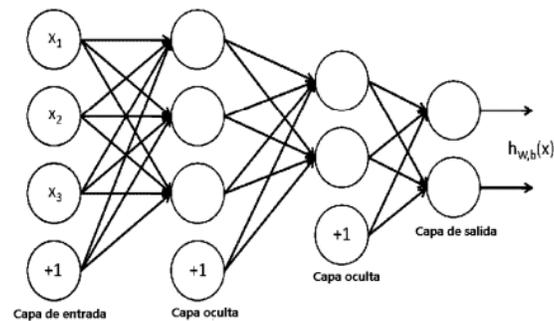
Redes Neuronales

Las redes neuronales están compuestas por neuronas, las cuales se organizan en capas y son los elementos básicos de una red neuronal con el propósito de llevar a cabo una transformación a los datos recibidos en X para predecir un valor continuo o categórico, Y , en la última capa, como se muestra en la Figura 5. Dichas capas son: Capa de *input* o entrada,

capas ocultas y capa final o de salida. La primera es la encargada de introducir la información al modelo y las dos siguientes emplean transformaciones de la información recibida y generan el resultado transformado (Fuentes, 2019).

Figura 5.

Modelo de una red neuronal



Nota. Tomado de (Restrepo Arteaga, 2015)

Existen diferentes tipos de redes neuronales que se utilizan para abordar varias clases de problemas y datos. Algunas de las redes neuronales más comunes son:

- Redes neuronales *feedforward*: También conocidas como redes neuronales de propagación hacia adelante. Es el tipo más básico de redes neuronales. Aquí, la información se dirige en una dirección, desde la capa de entrada por medio de las capas ocultas hasta la capa de salida. No hay enlaces retroalimentados en estas redes, es decir, no tienen memoria o capacidad de almacenaje información acerca de estados anteriores (Russell & Norvig, 2016).
- Redes neuronales recurrentes (RNN): A diferencia de las redes *feedforward*, las redes neuronales recurrentes poseen enlaces retroalimentados, y permiten obtener memoria y capturar la información secuencial en los datos. Estas redes son fundamentalmente

útiles en tareas como el procesamiento del lenguaje natural, la sucesión de palabras es importante (Goodfellow, Bengio, & Courville, 2016).

- Redes neuronales convolucionales (CNN): Las CNN se diseñaron para el procesamiento eficaz de datos estructurados en forma de rejillas, como imágenes. Estas redes emplean capas convolucionales para obtener características locales y capas de agrupamiento para minimizar la dimensionalidad. Se ha demostrado un rendimiento notorio en tareas de visión por computadora y reconocimiento de modelos (Goodfellow, Bengio, & Courville, 2016).

Función de activación

Es un estado de activación en el que se determina el nivel de actividad de una neurona, está se convierte la entrada global (excepto el umbral) en un valor (estado) de activación. El rango comúnmente va de 0 a 1 o -1 a 1, dado que la neurona puede estar activa o inactiva.

Existen varios tipos de función de activación como:

- Identidad
- Escalón
- Lineal saturada
- Sigmoidea
- Gaussiana
- Sinusoidal

Función Sigmoidea

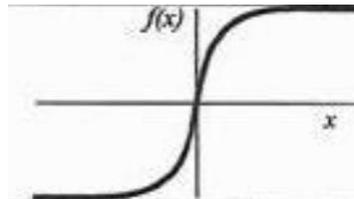
Función no lineal empleada para la captura de patrones complejos en cuanto a la regresión logística, se utiliza con mayor frecuencia en la capa de salida, se hace uso de ella comúnmente aparte de la regresión, para la clasificación de datos y la predicción de una probabilidad como salida. Es una función monótona acotada a la salida. Se puede observar su

forma en ecuación la (14) y de igual manera su comportamiento en la Figura 6 (Gutierrez, s. f.).

$$y = \frac{1}{1 + e^{-x}} \quad (14)$$

Figura 6.

Función de activación Sigmoidea



Nota. Obtenido de (Nacelle, 2009)

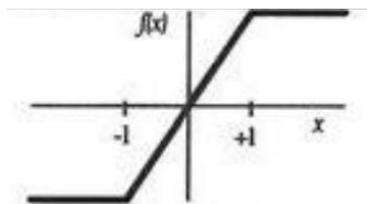
Función Lineal Saturada

Es similar a la entrada posee un rango de $[0, 1]$, dependerá si el valor es menor a 0 o mayor a 1 dará uno de estos dos valores respectivamente. Este dado por la ecuación (15) y su comportamiento se puede visualizar en la Figura 7 (Minango Guatumillo, 2022):

$$y = \begin{cases} 0, si & x < 0 \\ x, si & 0 \leq x \leq 1 \\ 1, si & x > 1 \end{cases} \quad (15)$$

Figura 7.

Función de activación lineal saturada



Nota. Obtenido de (Nacelle, 2009)

Algoritmos de Clasificación

Los algoritmos de clasificación se emplean en el aprendizaje automático para establecer elementos o instancias a categorías preestablecidas, etiquetas según sus características o atributos. Estos algoritmos se sustentan en un conjunto de datos de entrenamiento que incluye ejemplos con sus respectivas etiquetas y utilizan esta información para ejecutar predicciones o catalogar nuevos datos (Hastie, Tibshirani, & Friedman, 2021).

Existen diversos tipos de algoritmos de clasificación, como autoencoders, árbol de decisión, los vecinos más cercanos (K-NN), las máquinas de vectores de soporte (SVM) y la regresión logística, entre otros (Hastie et al., 2021). Cada algoritmo posee rasgos propios, los cuales serán más apropiados para ciertos problemas de clasificación.

Estos algoritmos operan por medio de la construcción de un modelo de aprendizaje de las relaciones entre las características de los datos de entrenamiento y las etiquetas correspondientes. El modelo resultante se emplea para clasificar nuevos datos con base a sus características. El desempeño de los algoritmos de clasificación es evaluado a través de métricas como la precisión, la recuperación (*recall*) y la matriz de confusión, etc. (Hastie et al., 2021).

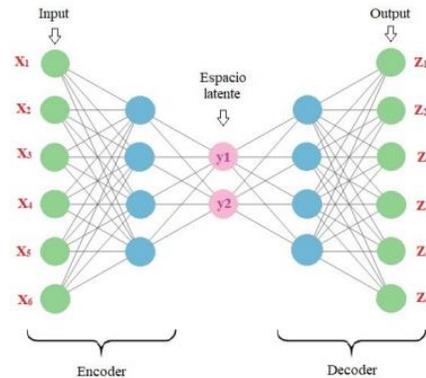
Autoencoder

El *autoencoder* o codificador automático es un tipo de red neuronal que emplea aprendizaje no supervisado y basa su funcionamiento en un codificador y un decodificador, el primero aprende un conjunto de características o una representación latente de los datos de entrada; mientras que el decodificador se prepara para la reconstrucción de los datos de entrada en función de las características. Esto se puede visualizar en la Figura 8. Con dicho proceso el *autoencoder* puede implementarse para la predicción de otras entradas a pesar de no ser vistas anteriormente (*Autoencoders (Autocodificadores)*, s. f.; Bank et al., 2021). Este

tipo de red es comúnmente empleada en el procesamiento de imágenes, detección de anomalías y análisis de datos (Hinton & Salakhutdinov, 2006).

Figura 8.

Representación del Autoencoder



Nota. Tomado de (López et al., 2023)

Árbol de decisión

Los árboles de decisión, son otro tipo de algoritmo de clasificación. Se basan en el aprendizaje automático empleados en la resolución de problemas de clasificación y regresión. Estos algoritmos se encuentran en función de una estructura de árbol compuesta por nodos y ramas, cada nodo simboliza una característica del conjunto de datos y cada rama representa una decisión basada en esa característica (Russell & Norvig, 2016).

Validación Cruzada de k-interacciones

Este tipo de validación consiste en dividir las muestras en k conjuntos, uno de estos será analizado como datos de prueba, mientras que el resto ($k - 1$) será parte de los datos de entrenamiento. Este proceso se repite por k -interacciones y así se obtiene el estadístico PRESS (del inglés, *Prediction Error Sum of Squares*), con el cual se valida el modelo de

regresión en términos de predicción de las interacciones hasta conseguir un solo resultado del modelo (Rodríguez Murillo, 2019).

Matriz de Confusión

Se encuentra constituida a partir de una imagen base que contiene N celdas y M clases, en las filas se encuentran las unidades o clases del mapa y en las columnas se ubican las clases reales o verdad y terreno. Los elementos situados en la diagonal son el número de clasificaciones que al realizarse fueron correctas, mientras que los se encuentran fuera son fugas o migraciones (Sánchez Muñoz, 2016). Existen dos tipos de error:

- Error de Omisión: Datos que, a pesar de pertenecer a la clase, no aparecen en ella. Estos se sitúan debajo de la diagonal principal de la matriz.
- Error de Comisión: Datos que no pertenecen a la clase, pero aparecen en ella. Estos se sitúan sobre la diagonal principal de la matriz.

La matriz de confusión proporciona detección de error y también permite:

- Análisis Descriptivo
- Enfoque general de las asignaciones afirmativas y equivalentes.
- Análisis Analítico

Para la generación de la matriz de confusión se deben tener las siguientes condiciones:

- Clases independientes, mutuamente excluyentes y exhaustivas y en número suficiente.
- Utilizar metodologías de muestreo que exceptúen autocorrelación.
- Para aseverar la presencia de clases extrañas o minoritarias se deben emplear técnicas estratificadas.
- No se deben emplear parcelas de entrenamiento clasificador al llevar a cabo un proceso de clasificación supervisada.

En la Tabla 1 se puede observar el ejemplo de la generación de una matriz de confusión.

Tabla 1.

Ejemplo de Matriz de Confusión

		Predicción	
		Negativo	Positivo
Realidad	Negativo	TN	FP
	Positivo	FN	TP

Nota. Total Negativo (TN), Total Positivo (TP), Falso Positivo (FP), Falso Negativo (FN), tomado de (Pérez González, 2021).

Métricas de Desempeño

Las métricas de desempeño permiten evaluar la calidad que parte de la matriz de confusión con la finalidad de conocer el rendimiento del proceso. Para ello se pueden emplear diversas métricas como: exactitud, precisión, sensibilidad, especificidad, otros (Pérez González, 2021). En la base de la Tabla 1 se indican las diferentes ecuaciones de las métricas de desempeño.

Exactitud

La exactitud (del inglés, *Accuracy*) es la proporción de datos clasificados correctamente en función del total de los eventos. La ecuación se muestra en la ecuación (16).

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (16)$$

Precisión

La precisión indica las predicciones correctas que se realizaron con base al total positivo y los falsos positivos. La ecuación se muestra en la ecuación (17).

$$P = \frac{TP}{TP + FP} \quad (17)$$

Sensibilidad

La sensibilidad indica la cantidad de datos correctos que fueron predichos con base al modelo, se obtiene el total de datos positivos y los falsos negativos. La ecuación se muestra en la ecuación (18).

$$Recall = \frac{TP}{TP + FN} \quad (18)$$

Especificidad

La especificidad es la tasa negativa verdadera. Se calcula con base al total de predicciones negativas y a los falsos negativos. La ecuación se muestra en la ecuación (19).

$$Specificity = \frac{TN}{TN + FP} \quad (19)$$

BER

El BER es la tasa de error balanceada. Se obtiene del promedio de las muestras clasificadas de forma errónea para cada clase. Para la clasificación binaria se define el BER con la ecuación (20) (García et al., 2020).

$$BER = 1 - \frac{1}{2 * 100} \left(\frac{TN}{TP + FP} + \frac{TP}{TP + FN} \right) \quad (20)$$

Espacios Latentes

Los espacios latentes se basan en la proyección de datos en n -dimensiones de entrada de nuevos espacios de l -dimensiones de salida ($n > l$) e intentan mantener gran parte de información posible de las proyecciones. En caso de que la información no se pueda contener, esta se pierde y elimina de esta forma, las características que no poseen información significativa (Diez Tabara, 2023).

Los espacios latentes se pueden obtener de forma visual para poder realizar una comparativa de los modelos, esto, desde el punto de vista de la separación por clases de las diferentes representaciones derivadas del conjunto de datos de estimación. Para la medición de la separación que existe, se puede emplear el algoritmo Silhouette (Puga Reyes, 2020), con el cual se obtiene la medida de agrupamiento de cada modelo a través de la combinación de un único valor de cohesión media de cada uno de los grupos con el mínimo trayecto entre los pares de grupos. Esto se puede observar en la ecuación (21), $a(i)$ es la distancia media del elemento i -ésimo y $b(i)$ es la mínima distancia entre las distancias medias del elemento i -ésimo (Pérez Curiel, 2022).

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \quad (21)$$

t-SNE

La técnica de incrustación de vecinos estocásticos distribuidos (del inglés, *Distributed Stochastic Neighbor Embedding*), introducida por Maaten y Hinton en 2008. Consiste en optimizar y producir visualizaciones considerablemente mejores en la reducción de tendencia al agrupar puntos en el centro del mapa. Esta técnica es empleada en el campo del aprendizaje automático, dado que se fundamenta en la representación de estructuras en diversas escalas en un solo mapa. Es importante trabajar con datos de alta dimensión que se encuentran en diferentes manifold learning (implicaciones múltiples en la decisión), pero con una relación de

baja dimensión. Por ejemplo, las imágenes de objetos con múltiples clases desde varios puntos de vistas. En cuanto a la comparación, se emplean varias técnicas de visualización no paramétricas, incluso el mapeo de Sammon, Isomap y la incrustación lineal local. Estas visualizaciones son significativamente mejores que las producidas por las técnicas en casi todos los conjuntos de datos (Maaten & Hinton, 2008).

t-SNE contiene un enfoque en cuanto a las estructuras complejas y la revelación de las mismas, sin embargo, la interpretación en cuanto a las distancias del espacio, puede ser no trivial, por lo que es implementado principalmente para la visualización y exploración, proporciona una comprensión intuitiva, más que una medida cuantitativa precisa.

PCA

El Análisis de Componentes Principales (del inglés, Principal Component Analysis) es una técnica estadística empleada para la reducción de la dimensionalidad de conjuntos de datos y conserva, al mismo tiempo, la mayor cantidad de información. El PCA tiene como objetivo principal hallar un conjunto de variables no correlacionadas designadas como componentes principales, las cuales deben explicar la máxima variabilidad presente en los datos originales (Abdi & Williams, 2010). Para el cálculo de los componentes principales se utiliza la descomposición de la matriz de covarianza o de correlación de los datos (Jolliffe, 2016).

El cálculo del PCA conlleva técnicas matemáticas como la descomposición en valores singulares (SVD) o la descomposición espectral (Jolliffe, 2016) y permite determinar los componentes principales con sus respectivos valores propios, se indica la cantidad de variabilidad detallada por cada componente (Jolliffe, 2016; Wold et al., 1987).

Para la implementación del método de PCA se emplea un proceso matemático, mismo que utiliza la descomposición de la matriz de covarianza, seguido de la selección y

ordenamiento de los vectores propios asociados, para adquirir una reducción en cuanto a la dimensionalidad. Después se realiza la interpretación de resultados, debido a la importancia relativa de las variables originales y la variabilidad explicada por la componente principal. Con esto se puede obtener información significativa al trabajar con espacios latentes (Jolliffe, 2016).

UMAP

La Aproximación y Proyección de Colector Uniforme para Reducción de Dimensiones (del inglés, Uniform Manifold Approximation and Projection for Dimension Reduction) consiste en un algoritmo para reducción de dimensionalidad y la visualización de datos. Busca incrustaciones de baja dimensión de datos estructurados a través de geometría Riemanniana aplicada y topología algebraica. La UMAP consiste de dos pasos: el primero es el cálculo de la representación gráfica por medio de un conjunto de datos; y el segundo es a través del descenso de gradiente estocástico al optimizar una incrustación de baja dimensión del gráfico (Diaz-Papkovich et al., 2021).

Para llevar a cabo la utilización de UMAP de manera más detallada emplea el uso de técnicas de optimización, con la finalidad de conseguir una proyección poder preservar la topología del espacio original, es necesario la combinación local y global, para conseguir crear una representación coherente y continua. Posterior se inicia la etapa de ajustes e hiperparámetros, como `N_Neighbors` o `MIN_DIST`, lo que afecta la calidad de representación. Depende de los parámetros empleados se podrá obtener resultados significativos (McInnes et al., 2020).

La UMAP puede ser paramétrica o no. En caso de serla, esta aprende una incrustación para disminuir la entropía cruzada muestreada sobre bordes ponderados positivamente o atracción y por medio de un muestreo negativo aleatorio sobre el conjunto de datos o repulsión, lo que permite minimizar los lotes muestreados del conjunto de datos (Sainburg et al., 2021).

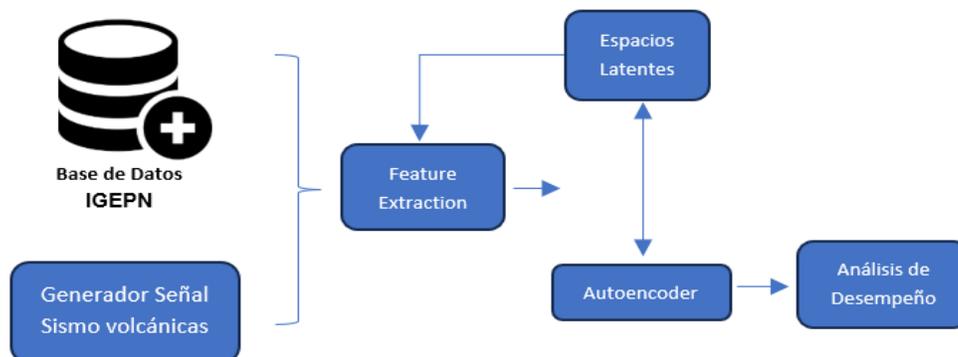
Capítulo III

Materiales y Metodología

La investigación fue realizada con una metodología mixta, descriptiva y experimental. La primera de estas es realizada con base a estudios similares acerca del desarrollo y métodos basados en aprendizaje automático, así como la aplicación de los espacios latentes en cuanto a la evaluación de sistemas de aprendizaje, esto con la finalidad de conocer acerca de las posibles mejoras a implementar con respecto a los parámetros y el desempeño obtenido referente al clasificador de señales sismo-volcánicas. La parte experimental es la segunda etapa de la investigación. Esta se encuentra compuesta por las secciones mostradas en el diagrama de la Figura 9

Figura 9.

Diagrama de bloques acerca de la metodología investigación



Nota. El análisis se realizó de forma independiente con cada una de las bases de datos, es decir, una observación de los datos del IGEPN y otra con los valores obtenidos a partir del generador de señal, el análisis será empleado en función de la frecuencia.

Generador

El generador a implementar es un modelo de Red Neuronal Adversario Generativo Condicional (CGAN, del inglés *Conditional Generative Adversarial Network*) realizado por

(Galarza Cruz & Vega Vergara, 2022) en el *software* MATLAB®, permite generar eventos sismo-volcánicos de tipo VT y LP con una frecuencia de muestreo de 100Hz. Para utilizar el generador es necesario conocer el número de datos a generar por cada uno de los eventos y duplicarlo, ya que el número introducido de señales es el total entre LP y VT

Adicional a esto, es necesario indicar si los datos sintéticos van a contener ruido o no y el lugar en el computador en que se generara el archivo. Una vez generados estos se almacena en el lugar indicado como un archivo.mat, luego, los datos se presentan en una tabla, ahí se podrá observar la etiqueta del tipo de evento, la frecuencia y la procedencia de la señal o datos.

Base de datos

La base de datos utilizada posee señales sismo-volcánicas del volcán Cotopaxi en combinación de datos reales y sintéticos o generados, los reales son proporcionados por el IGEPN, mismas que fueron reunidas durante el 2012 y 2019 en las estaciones VC1 de período corto, con frecuencia de 50 Hz; y también en la estación BREF sismo acústica de banda ancha con una frecuencia de muestreo de 100 Hz.

La base de datos reales está designada como MicSigV1 con extensión. mat y cuenta con la unión de varias señales sísmicas discretas. Dicha base está formada por una matriz de 11 columnas, las cuales son: valor del código de la red ecuatoriana, código de la estación, velocidad de muestreo en Hz, eje del sismómetro, año, mes, tipo de evento, tiempo de duración en segundos, punto de inicio del evento, punto final y datos de las señales. Las mediciones toman en cuenta los 10 segundos previos y los 10 posteriores al evento detectado. Es pertinente mencionar que la base de datos tiene un total de 1187 eventos sísmicos distribuidos de la siguiente manera: 1044 LP, 101 VT, 27 RG, 8 HB y 7 IC (Minango Guatumillo, 2022).

Los datos sintéticos son generados con base a la investigación de Galarza Cruz & Vega Vergara (2022), para poder evaluar e igualar la información de la base de datos proporcionada por IGEPN. En primera estancia realizo pruebas con los datos reales y los del generador, mezclados en una sola base de datos. Al presentar inconsistencias en los resultados se implementó una base de datos reales con un número similar en eventos (VT y LP), para ello se tomó de forma aleatoria 101 eventos de cada clase, es decir, 101 eventos para VT y LP, esto se replica en sintéticos, con la finalidad de evaluar al generador y conocer si este último es la causa de los problemas presentado. Cabe recalcar que los eventos generados contienen ruido, con la finalidad de que los mismos sean lo más similares a los reales.

Extracción de Características

Se encuentra comprendida por la etapa de preprocesamiento, en la cual se adecua a los datos a ser analizados y el procesamiento para la extracción de las características espectrales.

Preprocesamiento

La base de datos MicSigV1 tiene sus señales sismo-volcánicas muestreadas en una frecuencia de 100 Hz. Es necesario llevar a cabo la eliminación de la media de las señales en conjunto de las posibles componentes DC añadidas por los elementos de medición. Al finalizar, se posee un redimensionamiento en cuanto a la cantidad de muestras de las señales con el objetivo de igualar cada uno de los eventos y después proceder a mezclar las señales entre sí.

Se realizo el mismo proceso con los datos sintéticos, con la diferencia de que es necesario los datos en función de la frecuencia para la evaluación de las características espectrales que posee, conocer si el generador de datos sintéticos es funcional y se puede aplicar al combinar con los datos reales para llevar a cabo un mejor desempeño en el entramiento del sistema clasificador de micro terremotos.

Procesamiento

Para la etapa de procesamiento se tienen tres bases de datos una de datos reales, otra con los sintéticos y una base de datos donde se mezclan estos dos, como ya se mencionó cada uno con 101 eventos de VT y LP. Todos estos datos proceden de la extracción de las características espectrales con aquellas que mostraron mayor información y permiten el entrenamiento de los modelos de clasificación.

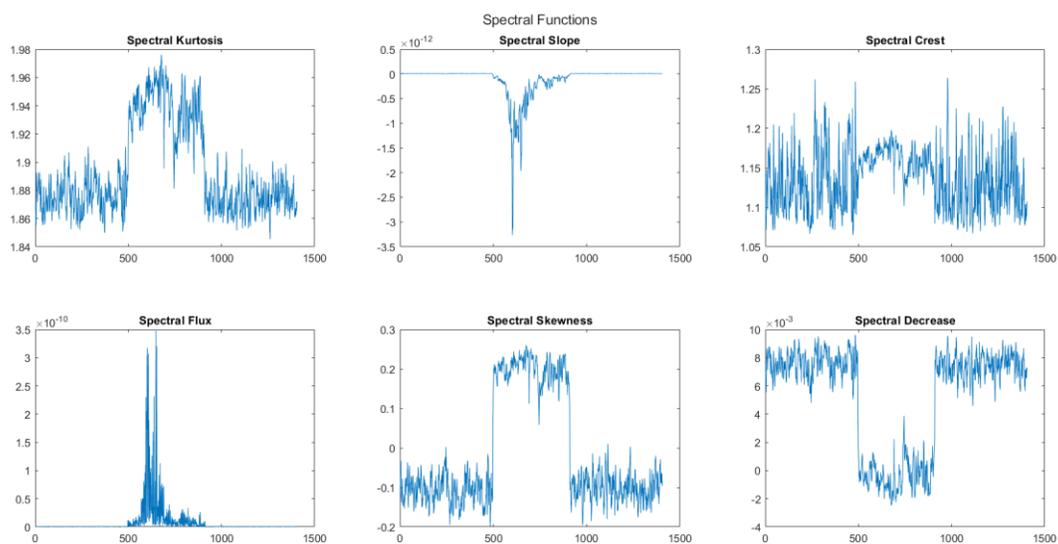
Características Espectrales

Las características espectrales fueron obtenidas (Minango Guatumillo, 2022). Su ventana de análisis es de tipo rectangular, lo que permite tener más detalles en la señal. Ciertos valores y componentes principales con una ventana de 100 muestras con respecto al tamaño y la longitud de solapamiento.

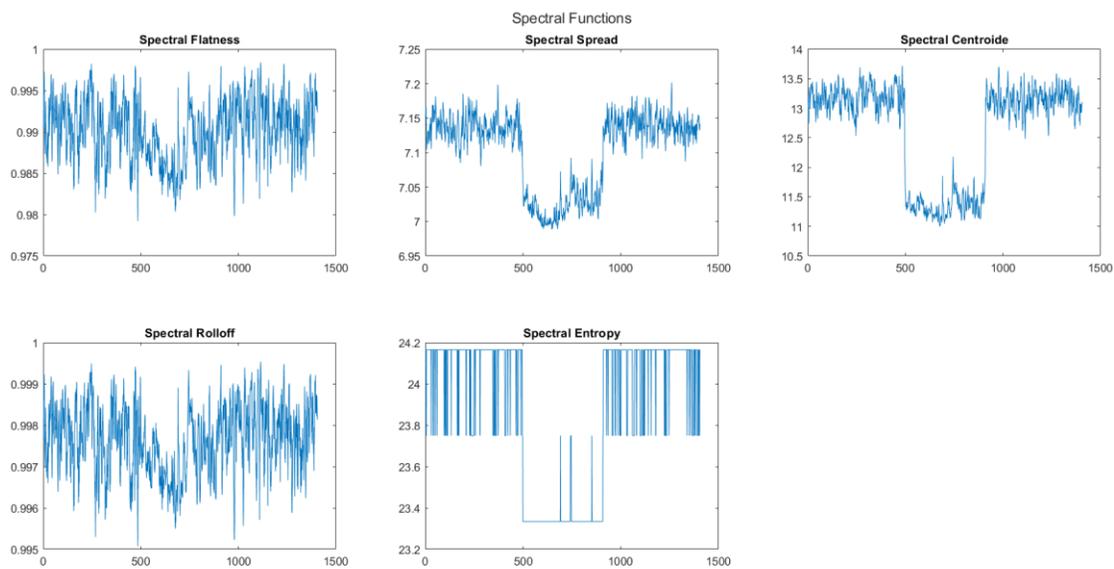
Se extrajeron con funciones lineales y con las escalas Mel, Bark y ERB, para lo cual se utilizó un rango de frecuencia de 0 a 25 Hz, dado a que existen eventos con una concentración mayor a los 10Hz. En este caso, los HB y VT. En la Figura 10 y Figura 11 se pueden observar las 11 características obtenidas.

Figura 10.

Características Espectrales, Curtosis, Pendiente, Cresta, Flujo, Asimetría, Disminución.

**Figura 11.**

Características Espectrales, Planitud, Extensión, Centroide, Rolloff, Entropía.



Entrenamiento de los modelos de clasificación

En el entrenamiento se van a validar ciertos parámetros previos a introducir los datos al *autoencoder* con la finalidad de evitar sesgos y principalmente poder garantizar los resultados. Los parámetros consisten en particionar los datos en dos grupos, uno de prueba y otro de entrenamiento. También se colocan las diferentes especificaciones para llevar a cabo la clasificación.

Validación cruzada de k iteraciones

Con la partición de los datos en dos grupos (entrenamiento y pruebas), se emplea la validación cruzada de k iteraciones, para obtener los datos con sus respectivas etiquetas, mismas que fueron ingresadas de la siguiente manera: 1 para eventos tipos LP y 2 para eventos de tipo VT. La partición realizada es 70% para el entrenamiento del modelo de clasificación y un 30% se utiliza en cuanto a pruebas. Posterior a esto los datos están listos para el ingreso en el modelo de clasificación.

Parámetros del Autoencoder

El *autoencoder* es el encargado de la extracción de las características de una agrupación de datos, estos son clasificados por medio de la capa softmax, la cual consiste en un algoritmo de aprendizaje supervisado con el objetivo de normalizar y exponer el proceso, a la par de poder estimar la probabilidad de las clases en cuanto a la clasificación de datos. Así, se puede llevar a cabo un ajuste fino de los parámetros del *autoencoder*, los cuales son empleados de acuerdo a la investigación de (Minango Guatumillo, 2022).

Este ajuste fino se da en función de la mejora del rendimiento del clasificador y la disminución en cuanto al error. A continuación, en la Tabla 2. se indican los parámetros empleados en (Minango Guatumillo, 2022) de los cuales los cambios realizados son con base a número de neuronas en la capa oculta o *Hidden Size*. El resto de parámetros, tanto para el autoencoder,

como para el modelo de k – NN y el modelo DT, se mantienen con los valores de la investigación anterior.

Tabla 2.

Parámetros del Autoencoder DT.

Parámetros del Autoencoder	Descripción	Predeterminado	Ajuste
<i>Encoder Transfer Function</i>	Función de transferencia para el codificador	Sigmoidal	Sigmoidal
<i>Parámetros del Autoencoder</i>	Descripción	Predeterminado	Ajuste
<i>Decoder Transfer Function</i>	Función de transferencia para el decodificador	Sigmoidal	Lineal saturada
<i>L₂ Weight Regularization</i>	Coeficiente regulador de peso L_2	0.001	0.004
<i>Sparsity Regularization</i>	Control del impacto del regularizador de dispersión	1	1
<i>Sparsity Proportion</i>	Proporción de entrenamiento, para una red neuronal	0.05	0.05
<i>Max Num Splits</i>	Número de decisiones de divisiones		10

Parámetros del	Descripción	Valor
DT		
<i>Crossval</i>	Validación cruzada con respecto al crecimiento del árbol de decisión	on

Nota. Tomado de (Minango Guatumillo, 2022)

Espacios latentes

Los espacios latentes se realizan a partir de la partición de los datos, definidos estos en 70% de entrenamiento y el 30% de prueba de la muestra total de datos, debido a los resultados que se han podido visualizar en investigaciones anteriores. Posteriormente se llevó a cabo tres tipos de gráficas con la finalidad de tener un análisis profundo, cada una proviene de los métodos t – SNE, PCA y UMAP.

En la Figura 12,

Figura **13** y Figura 14, se encuentran las gráficas en tres dimensiones, donde las primeras dos imágenes de cada figura son graficados en función de los datos reales (*a*), mientras que las dos siguientes son en base a los datos del sintéticos (*b*); por la complejidad de apreciación en un plano 3D, también se grafica de forma bidimensional.

Figura 12.

Espacio Latente en tres dimensiones de t -SNE, en training (TR)

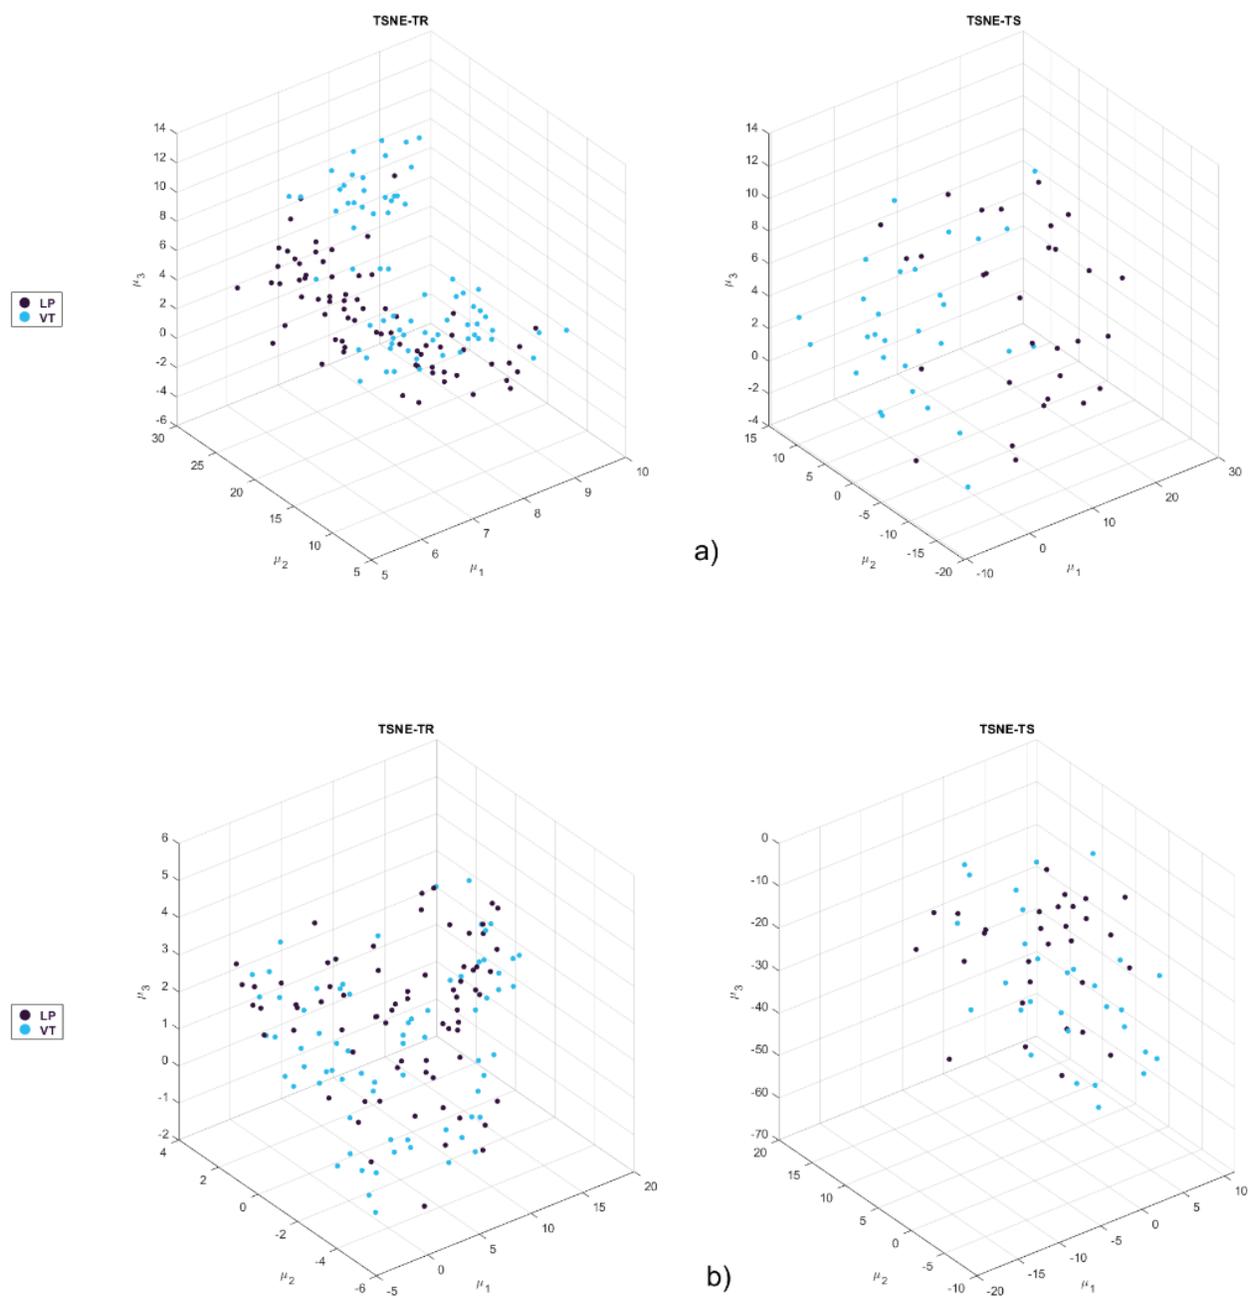


Figura 13.

Espacio Latente en tres dimensiones de PCA, en training (TR) y test (TS)

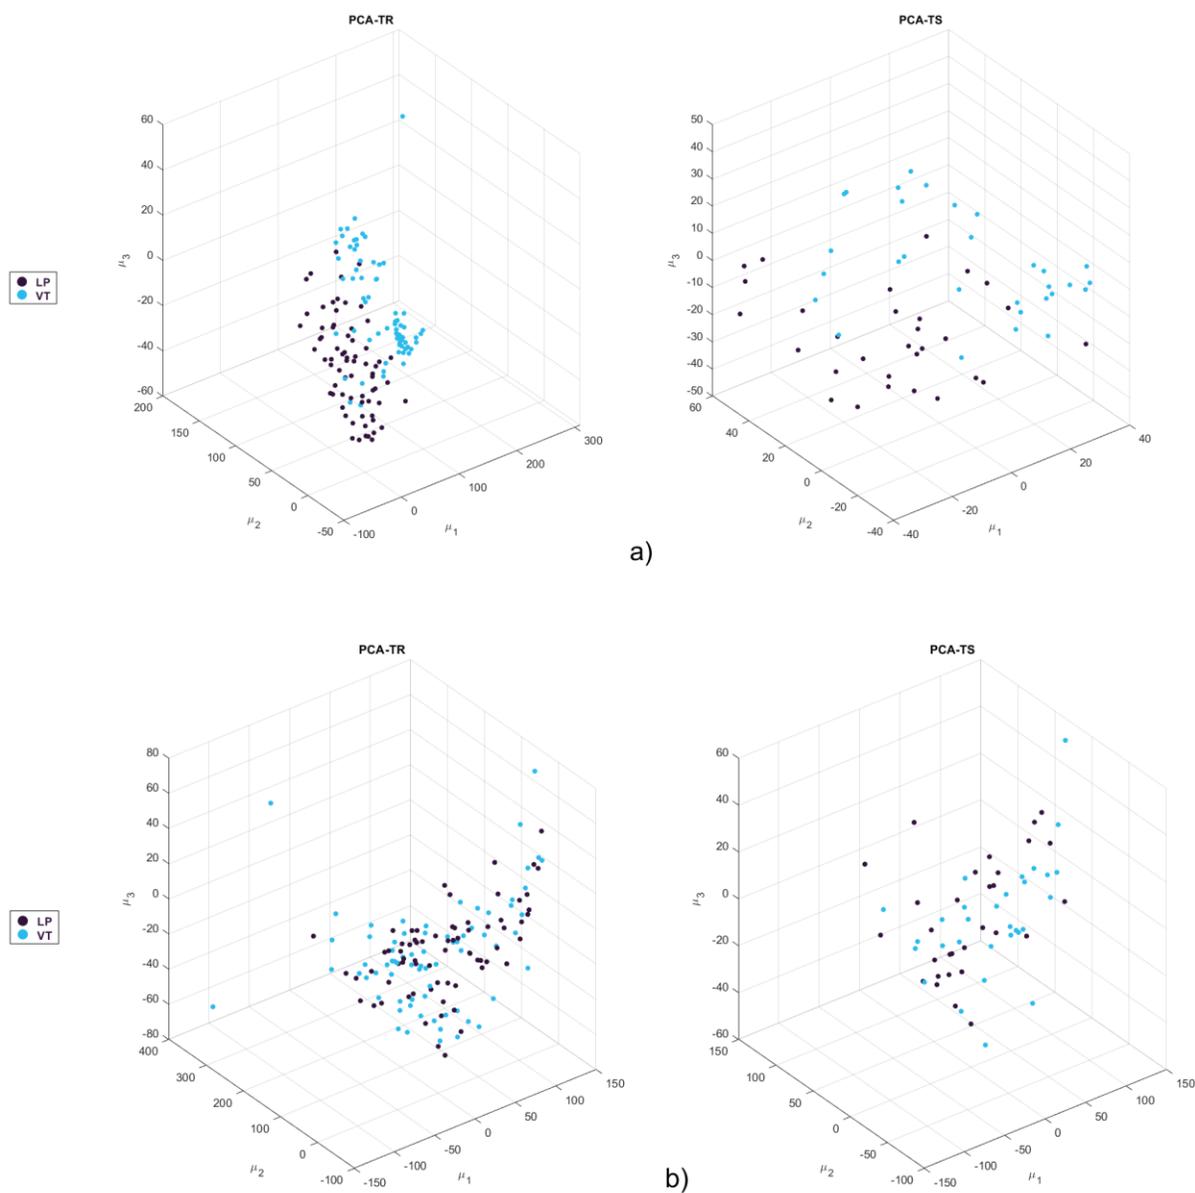
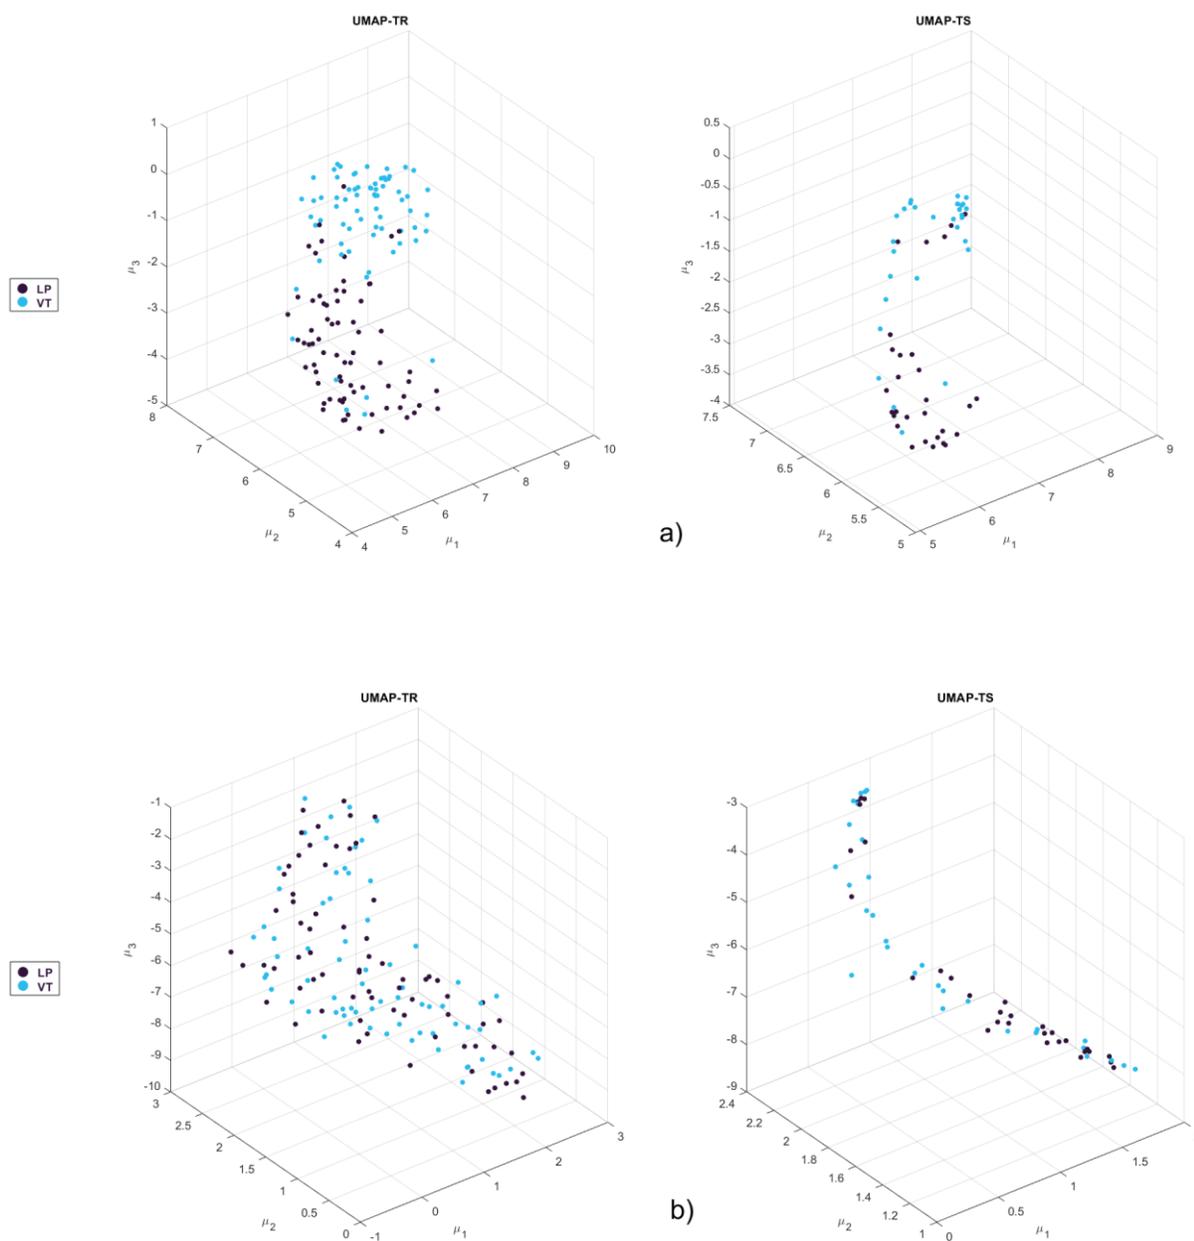


Figura 14.

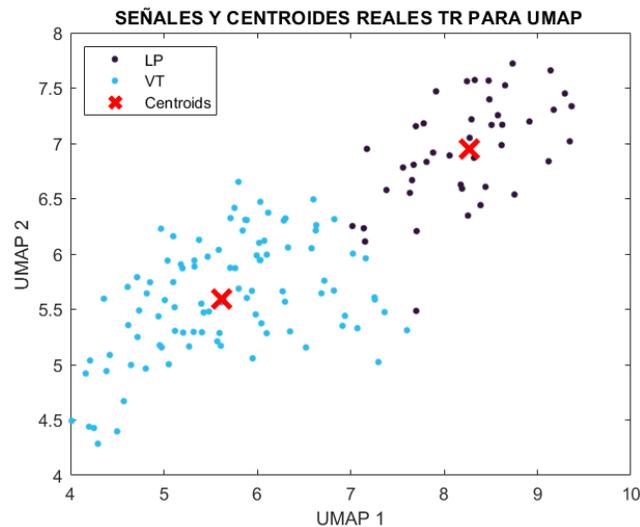
Espacio Latente en tres dimensiones de UMAP, en training (TR) y test (TS)



Para el análisis de los valores de los espacios latentes y que no sea una interpretación subjetiva (Bernal-Oñate et al., 2024), es necesario obtener el centroide de cada una de las clases, este es la distancia media de un cumulo de puntos de los espacios latentes, con la finalidad de conocer y evaluar la concentración de puntos que posee el modelo de clasificación. En la Figura 15, se puede observar el espacio latente de UMAP en dos dimensiones, con sus respectivos centroides para eventos de tipo LP como para VT.

Figura 15.

Espacio latente en dos dimensiones de UMAP con sus centroides



Para realizar la comprobación entre los datos reales y sintéticos, es relevante obtener la distancia euclidiana como se indica en la ecuación (22), con respecto a los centroides de cada uno, de esta manera se puede calcular un valor, el cual determina la medida de concentración con respecto al centroide, indicando la diferencia entre reales y sintéticos.

$$r_{(A,B)} = \sqrt{(X_2 - X_1)^2 + (Y_2 - Y_1)^2 + (Z_2 - Z_1)^2} \quad (22)$$

Capítulo IV

Análisis de Resultados

En el capítulo se indican los resultados y el análisis de los mismos, recolectados en el transcurso de la extracción de características, el análisis del modelo de clasificación y los resultados de desempeño proporcionados por los espacios latentes.

Las características espectrales se mantienen en 11, mismas que se pueden observar en la metodología con la Figura 10 y Figura 11, al igual de los ajustes finos en la Tabla 2., sin embargo, se realiza un cambio en cuanto al número de autoencoders, con el que se lleva en entrenamiento, estos varían en función del número de neuronas empleados para el entrenamiento o test, este cambio se realiza de 10 en 10. Los resultados obtenidos del entrenamiento, son presentados en función de la precisión, exactitud, sensibilidad, especificidad, BER, esto se puede observar en la Tabla 3 y Tabla 4. presentadas a continuación, de los cuales se podrá definir el mejor parámetro para poder trabajar.

Tabla 3.

Precisión, Exactitud, Sensibilidad, Escalabilidad y BER en las diferentes variaciones de Autoencoders en training

Autoencoders Traning	Precisión Traning	Exactitud Traning	Sensibilidad Traning	Especificidad Traning	BER Traning
90	100,00	100,00	100,00	100,00	0,00
80	100,00	100,00	100,00	100,00	0,00
70	100,00	100,00	100,00	100,00	0,00
60	100,00	100,00	100,00	100,00	0,00
50	100,00	100,00	100,00	100,00	0,00
40	99,54	99,62	99,69	99,55	0,00

Autoencoders Traning	Precisión Traning	Exactitud Traning	Sensibilidad Traning	Especificidad Traning	BER Traning
30	100,00	100,00	100,00	100,00	0,00
20	99,08	98,86	98,63	99,10	0,01
10	97,09	96,67	96,21	97,13	0,03

Tabla 4.

Precisión, Exactitud, Sensibilidad, Escalabilidad y BER en las diferentes variaciones de Autoencoders en test

Autoencoders Test	Precisión Test	Exactitud Test	Sensibilidad Test	Especificidad Test	BER Test
90	96,49	93,31	90,65	96,51	0,06
80	96,23	96,28	95,9	96,69	0,04
70	96,49	97,35	97,59	97,45	0,03
60	97,13	96,81	96,26	97,42	0,03
50	96,36	97,17	95,67	98,87	0,03
40	96,68	97,52	96,94	98,15	0,02
30	97,06	93,98	91,29	97,25	0,06
20	97,19	96,11	94,97	97,38	0,04
10	96,81	96,11	94,08	98,47	0,04

Nota: En la tabla se puede observar marcados en otro color los mejores resultados obtenidos para las diferentes métricas mencionadas, los valores con los que se obtiene un alto nivel de entrenamiento son con 60% en precisión, 70% en exactitud, 70% en sensibilidad, 50% en especificidad y finalmente 40% BER. Para la selección del mejor valor en cuanto a

autoencoder, se basa en los mejores resultados obtenidos, por lo que se ocupa 70% en el valor de Autoencoders.

Al realizar la comparación con los resultados de (Minango Guatumillo, 2022) como se muestra en la Tabla 5., con los obtenidos de la base de datos con data augmentation no se observa una mejora en el desempeño siendo, es un factor para visualizar cada uno de los posibles parámetros previos la fase de entrenamiento, con la finalidad de conocer la causa del suceso. Como primer punto se procede a analizar la matriz de confusión, se aprecia en la Figura 16 y Figura 17., donde presentan una notable variación en comparación al trabajar con los datos por separado, esto con lleva a una revisión en cuanto a los códigos e implementos utilizados.

Tabla 5.

Comparación de porcentaje de desempeño previos y posterior a la investigación

Autoencoeder	Antes	Después
Precisión	97.619	96.46
Exactitud	98.413	97.35
Sensibilidad	97.619	97.59
Especificidad	98.810	97.45
VER	0.018	0.03

Nota: Se presume que la alteración a la base de datos combinada, puede darse por las características espectrales utilizadas con el clasificador, debido a que en el trabajo de (Iglesias

Giler & Rosero Arciniega, 2023), al hacer data augmentation se evidencia un mejor desempeño, lo que conlleva al análisis con espacios latentes de los datos del generador en una comparación con los datos reales, con la finalidad de conocer el origen de las inconsistencias presentadas y si las mismas son dadas en función de del generador u otro factor externo.

Figura 16.

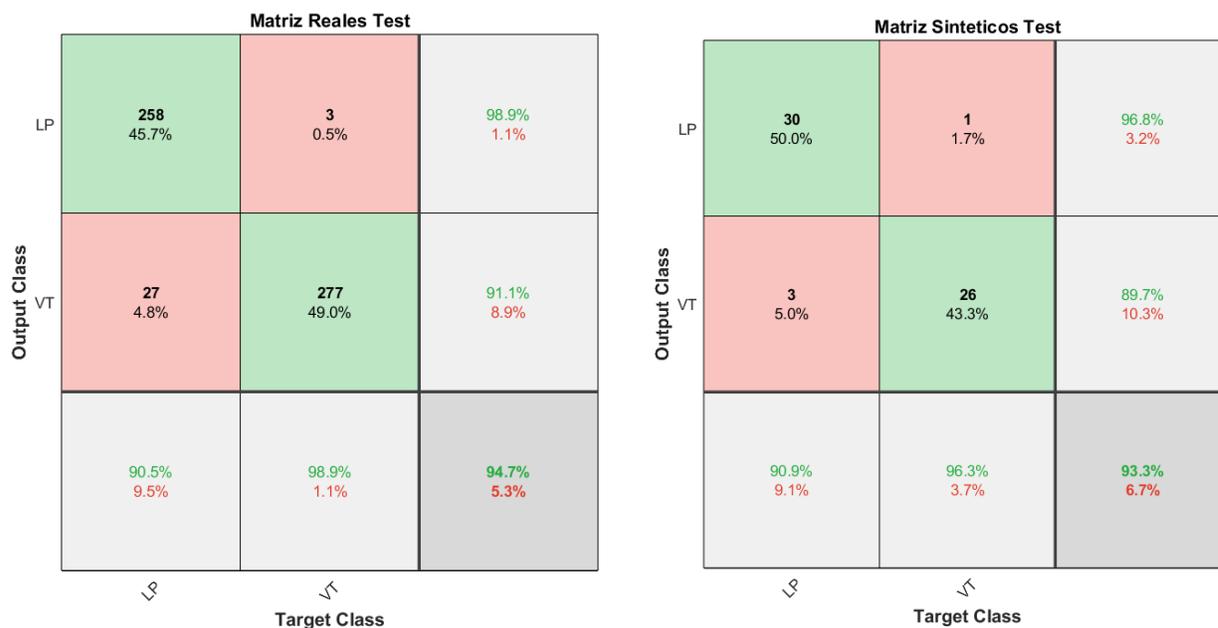
Matriz de Confusión de Datos con Data Augmentation

Matriz Combinada Test

Output Class	LP	<p style="text-align: center;">291 46.5%</p>	<p style="text-align: center;">19 3.0%</p>	<p style="text-align: center;">93.9% 6.1%</p>
	VT	<p style="text-align: center;">9 1.4%</p>	<p style="text-align: center;">307 49.0%</p>	<p style="text-align: center;">97.2% 2.8%</p>
		<p style="text-align: center;">97.0% 3.0%</p>	<p style="text-align: center;">94.2% 5.8%</p>	<p style="text-align: center;">95.5% 4.5%</p>
		L	V	
		Target Class		

Figura 17.

Matriz de Confusión de Datos Reales y Sinteticos



Pruebas de los Espacios Latentes

Los espacios latentes permiten conocer a profundidad al modelo de aprendizaje, ya que con este se puede visualizar un cumulo de puntos parecido a una constelación, misma que representa a los eventos a entrenar, en este caso, se trata de las señales de tipo LP y VT, cada uno está representado por un color, al ser graficados, esto para distinguir si la constelación de cada uno se encuentra dispersa uno con otro o posee una separación, en caso de suceder lo primero se destaca que el modelo no posee un aprendizaje, en el caso de existir esta división de la constelación entre un evento y otro se puede indicar, el caso contrario es decir que el modelo si cumple con su función.

El estudio se llevó a cabo con tres métodos diferentes para obtener a los espacios latentes, (t – SNE, PCA y UMAP), estos permitirán observar el cumplimiento del modelo de

entrenamiento, estos tres tipos se los obtiene de forma tridimensional, pero para una mejor visualización se obtiene 3 gráficos bidimensionales, representados en sus tres planos. Adicionalmente, se utiliza el centroide para conocer la mayor cantidad de señal que poseen los eventos y separación que existe al ser comparado entre real y sintético. Esto se puede visualizar en a las figuras presentadas a continuación, con su centroide se podrá realizar una breve comparación entre los datos reales y sintéticos, en cuanto a training y test.

Tabla 6.

Datos de posición, dispersión y distancia de los centroides training (TR) reales y sintéticos.

CENTROIDE	MODELO	DATOS REALES	DATOS SINTETICOS	DISPERSIÓN	DISTANCIA EUCLIDIANA
		$(\mu_{m1}, \mu_{m2}, \mu_{m3})$	$(\mu_{m1}, \mu_{m2}, \mu_{m3})$		
LP	PCA	(10.30, -3.78, 11.43)	(-2.28, 5.41, -0.31)	19,50	16,94
	TSNE	(7.20, 14.67, 6.78)	(5.76, -1.29, 1.29)	16,94	19,50
	UMAP	(7.13, 8.98, 1.28)	(2.05, 0.70, -3.94)	11,03	11,03
VT	PCA	(-5.97, 14.24, -9.16)	(5.62, -6.21, 1.24)	25,71	21,56
	TSNE	(7.41, 20.5040, 1.64)	(6.80, -1.05, 1.91)	21,56	25,71
	UMAP	(6.25, 9.93, -1.62)	(2.75, 0.96, -3.56)	9,82	9,82

En la Tabla 6 se puede observar las coordenadas rectangulares de los centroides TR reales y sintéticos, misma con la que al comparar se obtiene la dispersión, que existe entre los dos puntos y de igual forma la distancia euclidiana, con la finalidad de conocer la separación que

poseen entre ellos. En cuanto a la distancia media, UMAP posee la menor separación entre datos reales y sintéticos, de esta manera se comprueba su efectividad al evaluar los espacios latentes con este modelo.

Tabla 7.

Datos de posición coordenadas esféricas y distancia de los centroides training (TR) reales y sintéticos.

CENTROIDE	MODELO	DATOS REALES	DATOS SINTETICOS	ANGULO DE
		(θ, ρ, z)	(θ, ρ, z)	DESFACE (θ)
LP	PCA	(339.86°, 10.97, 11.43)	(112.87°, 5.87, -0.31)	227°
	TSNE	(63.86°, 16.34, 6.78)	(347.32°, 5.90, 1.29)	284.46°
	UMAP	(51.56°, 11.46, 1.28)	(18.91°, 2.16, -3.94)	32.65°
VT	PCA	(112.76°, 15.44, -9.16)	(312.14°, 8.38, 1.24)	119.38°
	TSNE	(70.14°, 21.80, 1.64)	(351.25°, 6.88, 1.91)	281.11°
	UMAP	(57.81°, 11.73, -1.62)	(19.33°, 2.91, -3.56)	38.48°

En la Tabla 7, se observa la ubicación de los centroides TR en coordenadas esféricas, además de la distancia euclidiana, permite conocer el ángulo (θ) de desfase. UMAP es el que más destaca de los modelos, con el ángulo de desfase más corto al ser comparado con t-SNE y PCA.

Tabla 8.

Datos de posición, dispersión de los centroides test (TS) reales y sintéticos.

CENTROIDE	MODELO	DATOS REALES	DATOS SINTETICOS	Distancia	
		$(\mu_{m1}, \mu_{m2}, \mu_{m3})$	$(\mu_{m1}, \mu_{m2}, \mu_{m3})$	DISPERSIÓN	Euclidiana TS
LP	PCA	(3.35, -8.24, 10.72)	(22.07, -4.94, 1.24)	21,25	36,95
	TSNE	(0.85, 1.31, 3.62)	(1.60, 3.94, -33.22)	36,95	21,25
	UMAP	(6.92, 6.40, -1.37)	(0.86, 1.74, -5.48)	8,69	8,69
VT	PCA	(-10.21, 10.54, -17.88)	(4.00, -1.70, 5.50)	22,48	33,18
	TSNE	(10.43, -6.41, 4.86)	(0.13, 5.35, -26.66)	35,19	35,19
	UMAP	(6.09, 5.85, -2.65)	(1.09, 1.58, -6.21)	7,48	7,479

Nota: La Tabla 8 indica la posición de los centroides TS reales y sintéticos, la dispersión y distancia euclidiana que existe entre los mismos. Al igual que en las tablas anteriores UMAP destaca con la menor distancia de separación.

Tabla 9.

Datos de posición coordenadas esféricas y distancia de los centroides training (TS) reales y sintéticos.

CENTROIDE	MODELO	DATOS REALES	DATOS SINTETICOS	ANGULO DE
		(θ, ρ, z)	(θ, ρ, z)	DESFACE (θ)
LP	PCA	(292.13°, 8.89, 10.72)	(347.40°, 22.62, 1.24)	55.27°
	TSNE	(56.91°, 1.56, 3.63)	(67.82°, 4.25, -33.22)	10.91
	UMAP	(42.76°, 9.43, -1.37)	(63.78°, 1.94, -5.49)	21.02°
VT	PCA	(134.09°, 14.67, -17.88)	(203,04°, 4.35, 5.50)	68.95°
	TSNE	(328.44°, 12.24, 4.86)	(88.65°, 5.35, -26.66)	239.79°
	UMAP	(43.84°, 8.45, -2.65)	(55.41°, 1.92, -6.21)	11.57°

Nota: La Tabla 9 indica los centroides TS en coordenadas esféricas, de esta forma se puede conocer el ángulo de desfase (θ) que existe entre los datos reales y sintéticos, se puede indicar que UMAP es el modelo con menor desfase.

De la figura 16 a 33 se puede observar los tres modelos t – SNE, PCA y UMAP tanto para TR y TS en el plano 2D, es decir, se presenta los planos XY, XZ y YZ, con la finalidad de obtener una mejor visibilidad de los datos, centroides y el comportamiento que los mismo poseen, dado que el plano en 3D no se puede obtener un análisis cualitativo adecuado.

A continuación, se observa de la Figura 18 a la Figura 23 el plano 2D, una diferencia en cuanto a los datos reales y sintéticos de TR y TS con el modelo t – SNE, dado que se visualiza que los datos para VT y LP se encuentran desfasados. Al revisar la Tabla 7 y Tabla 9 se puede conocer el valor de la rotación y la distancia euclidiana que poseen estos, debido a que la separación que estos poseen es otro punto analizar.

Figura 18.

Señales y Centroides TR Reales y Sintéticas con t – SNE plano 1 - 2

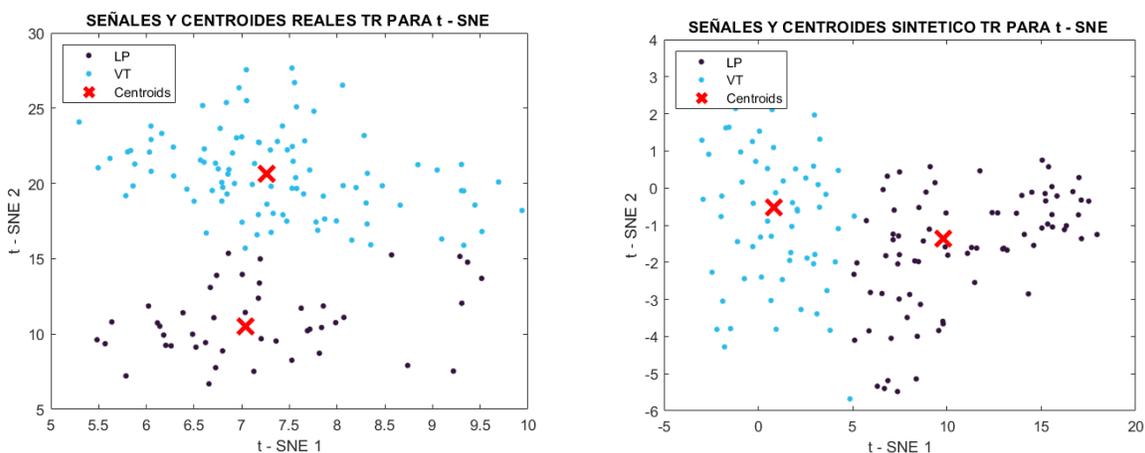


Figura 19.

Señales y Centroides TR Reales y Sintéticas con t – SNE plano 1 - 3

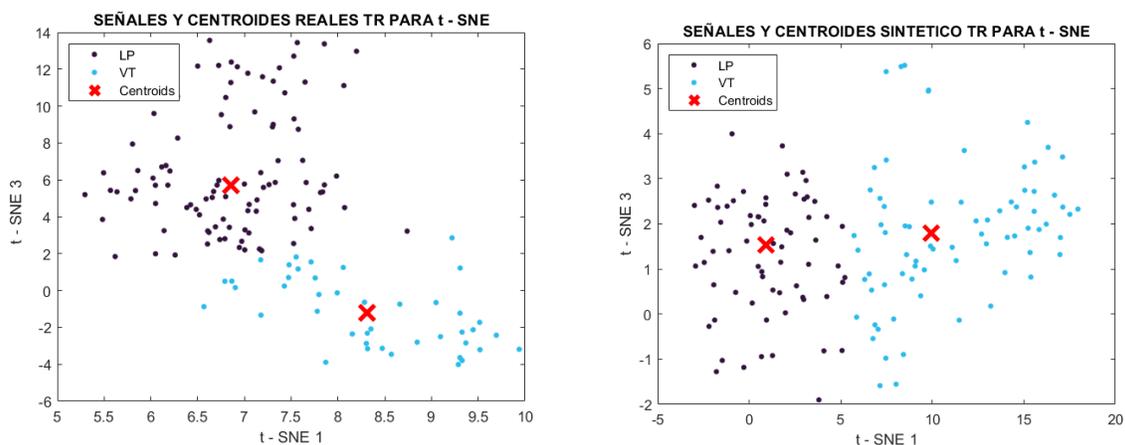


Figura 20.

Señales y Centroides TR Reales y Sintéticas con t-SNE plano 2 - 3

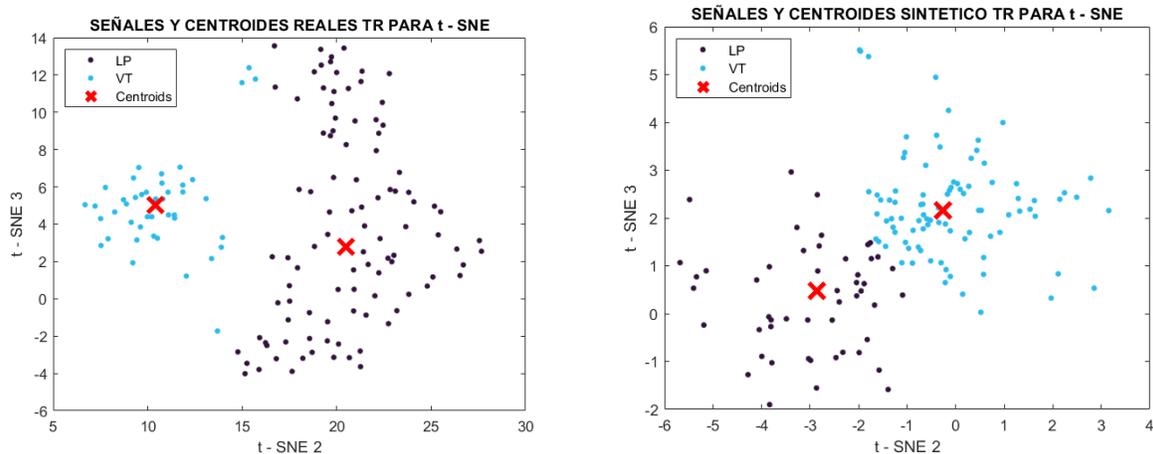


Figura 21.

Señales y Centroides TS Reales y Sintéticas con t-SNE plano 1 - 2

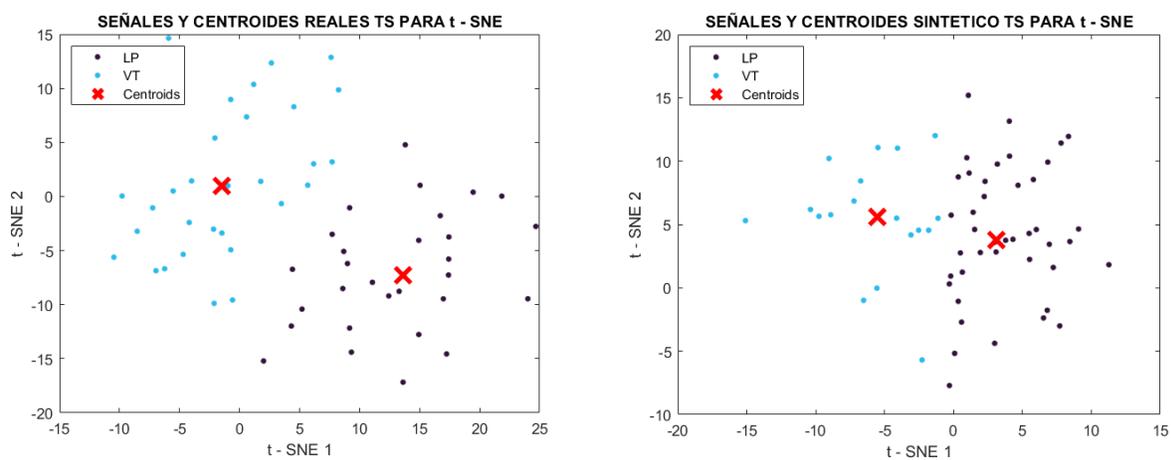
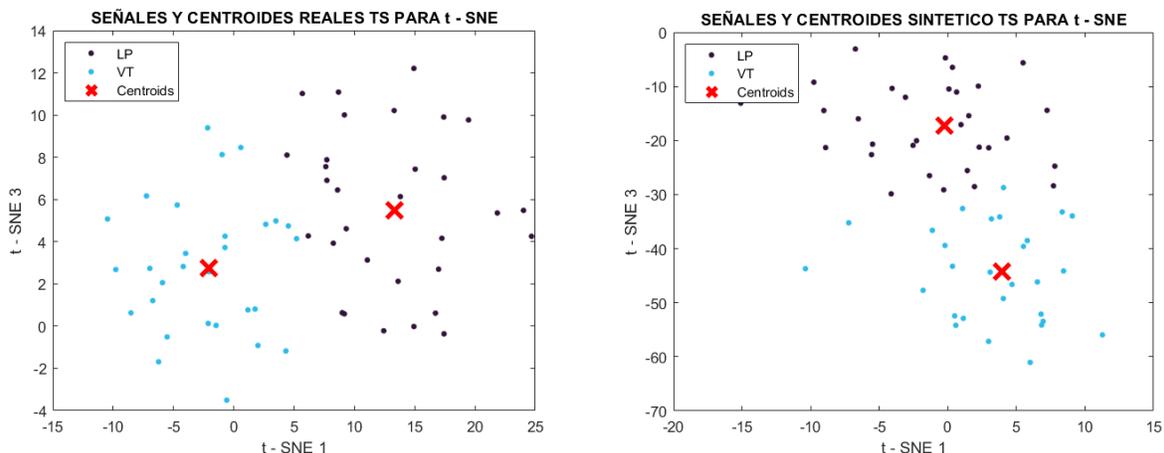
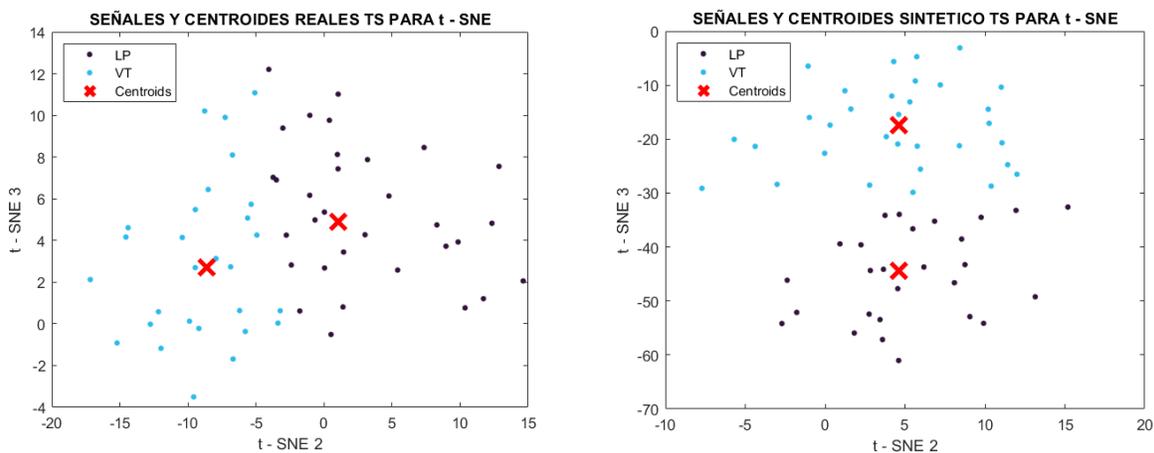


Figura 22.

Señales y Centroides TS Reales y Sintéticas con t-SNE plano 1 - 3

**Figura 23.**

Señales y Centroides TS Reales y Sintéticas con t-SNE plano 2 - 3



De la Figura 24 a la Figura 29 se observa los espacios latentes al aplicar el modelo PCA mismo en el cual se visualiza en las tres primeras imágenes los datos en TR los cuales no cuentan rotación tan variada de los centroides, sin embargo, a pesar de no ser tan perceptible o notoria en las figuras, esta persiste, puede verificarse en la Tabla 7, de igual forma que en

T-SNE se continua con la presencia de una dispersión de los datos. En comparación a los datos en TR con el modelo PCA, los TS si poseen un desfase notorio, además de la ya mencionada dispersión, esto se presentan en los tres planos de TS, es decir, en la Figura 27, Figura 28 y Figura 29. Adicional visualizarse de forma gráfica, se puede constatar el valor de rotación y separación en la Tabla 9, se confirma que estos patrones perseveran

Figura 24.

Señales y Centroides TR Reales y Sintéticas con PCA plano 1 - 2

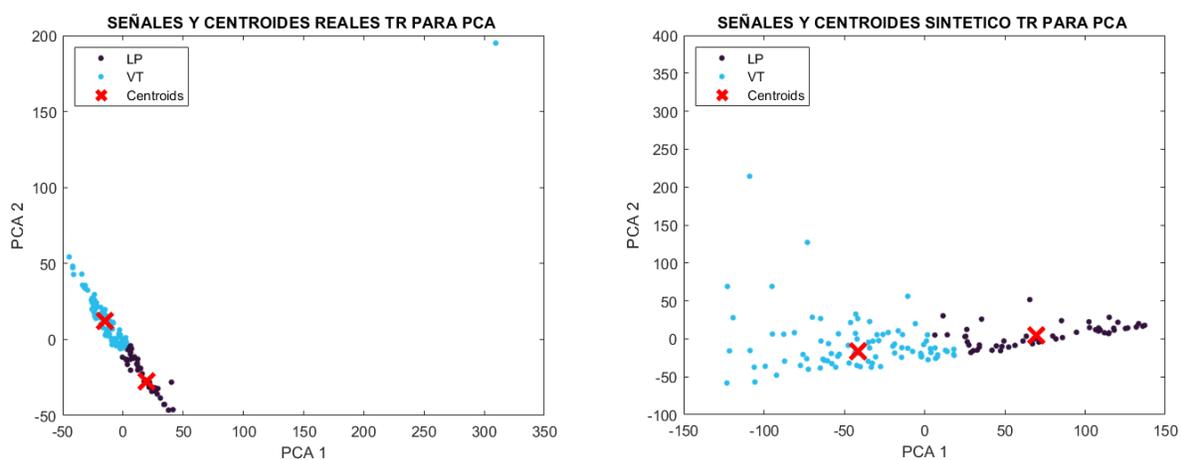


Figura 25.

Señales y Centroides TR Reales y Sintéticas con PCA plano 1 - 3

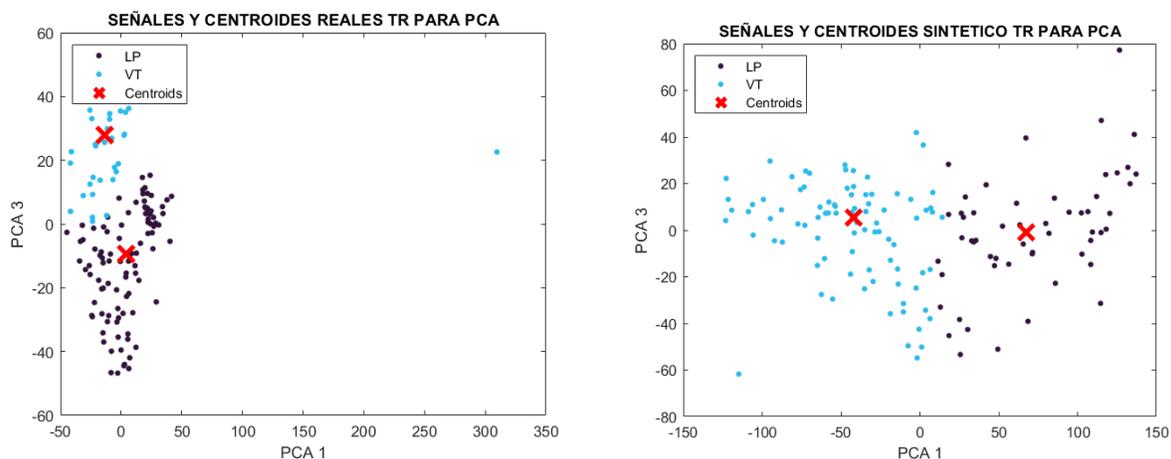


Figura 26.

Señales y Centroides TR Reales y Sintéticas con PCA plano 2 - 3

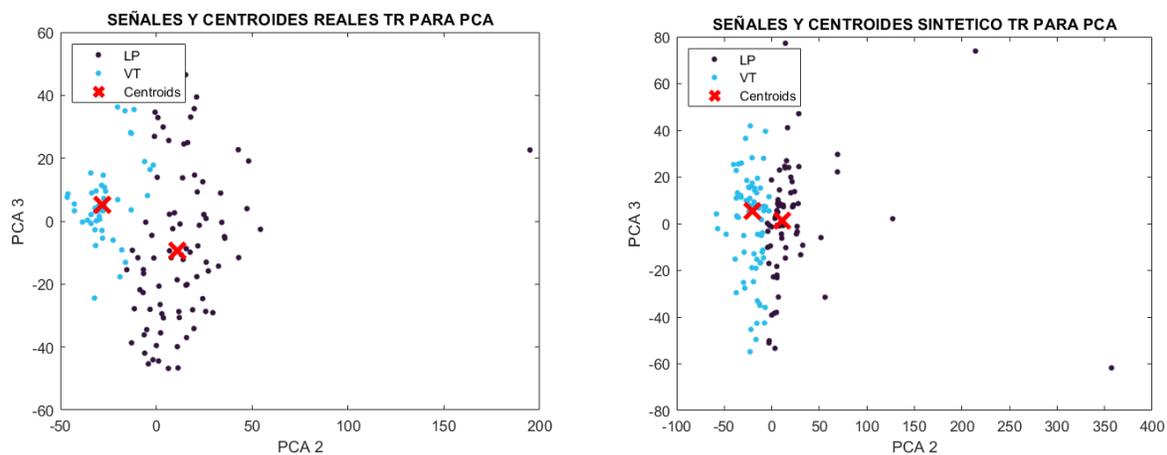


Figura 27.

Señales y Centroides TS Reales y Sintéticas con PCA plano 1 - 2

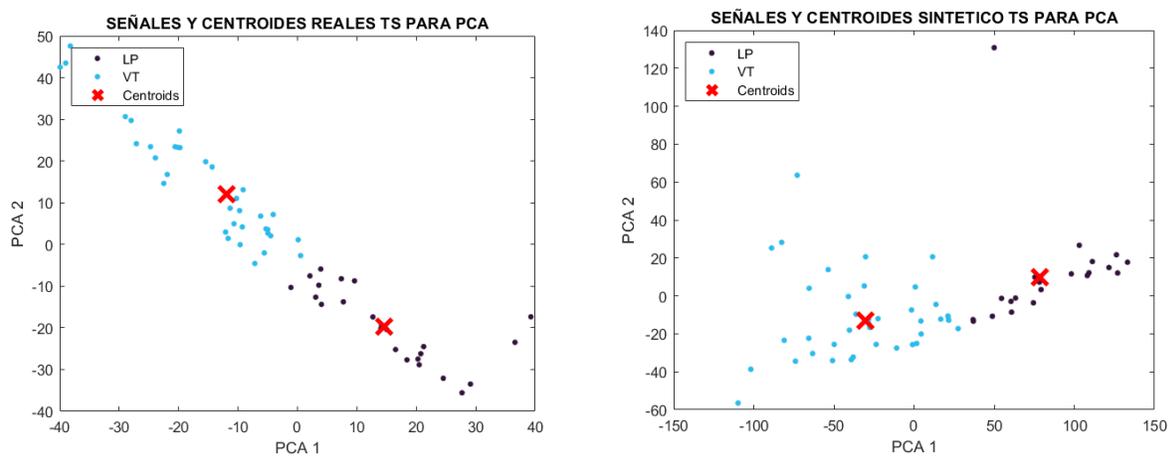


Figura 28.

Señales y Centroides TS Reales y Sintéticas con PCA plano 1 - 3

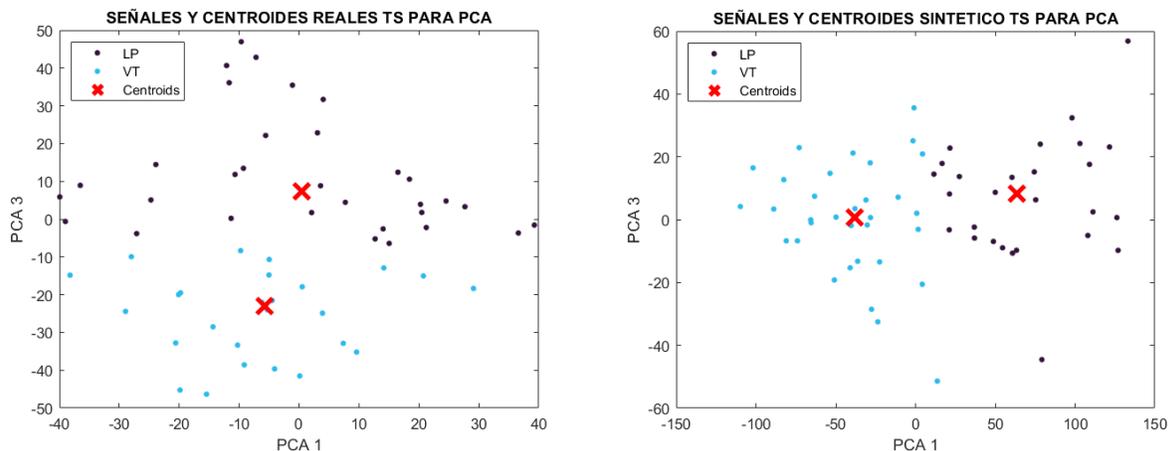
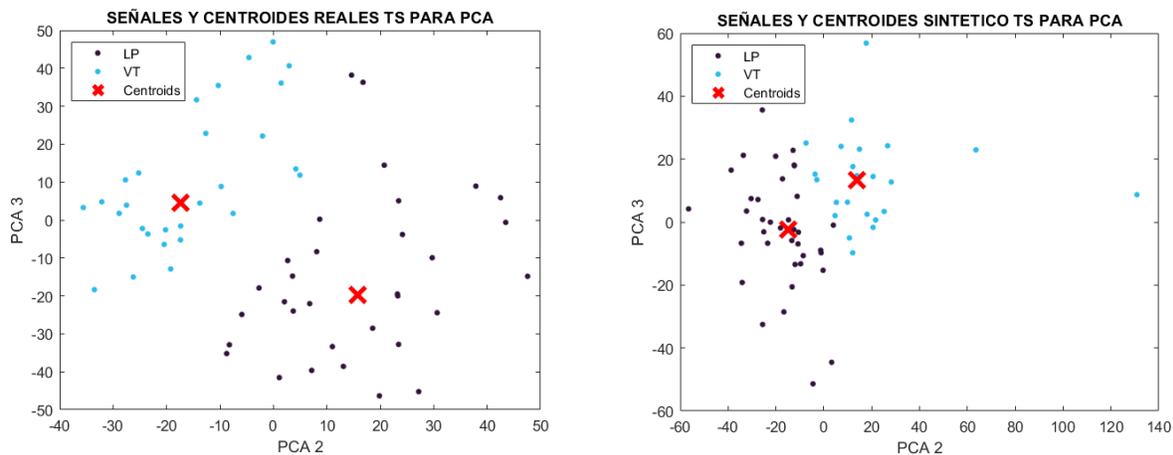


Figura 29.

Señales y Centroides TS Reales y Sintéticas con PCA plano 2 - 3



De la Figura 30 a la Figura 35 se puede observar los diferentes planos en 2D de los datos de TR y TS al ser evaluados con UMAP, estos persisten con la rotación, sin embargo, en comparación al TSNE y PCA, posee una menor distancia y desfase. La variación puede ser visualizada en la Tabla 7 y Tabla 9 al comparar θ entre las posiciones de los centroides, de

igual forma se encuentra la distancia euclidiana, está determina la separación que existe entre los centroides. En cuanto a la concentración de los puntos se puede claramente ver en las figuras que los datos sintéticos de todos los planos de los datos TS se encuentran con una mayor concentración en comparación a los sintéticos, mientras que los TR la diferencia de dispersión que poseen no es tan notoria.

Figura 30.

Señales y Centroides TR Reales y Sintéticas con UMAP plano 1 - 2

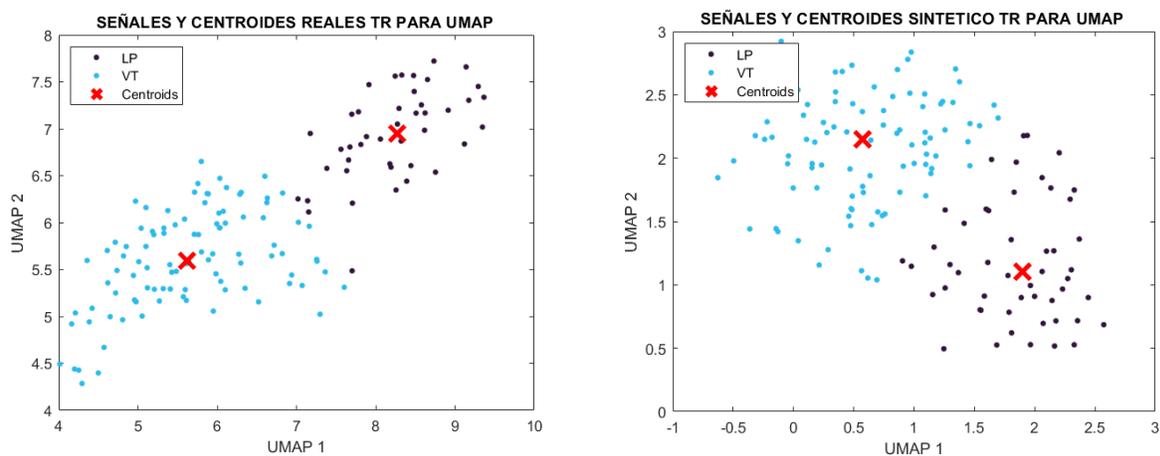


Figura 31.

Señales y Centroides TR Reales y Sintéticas con UMAP plano 1 - 3

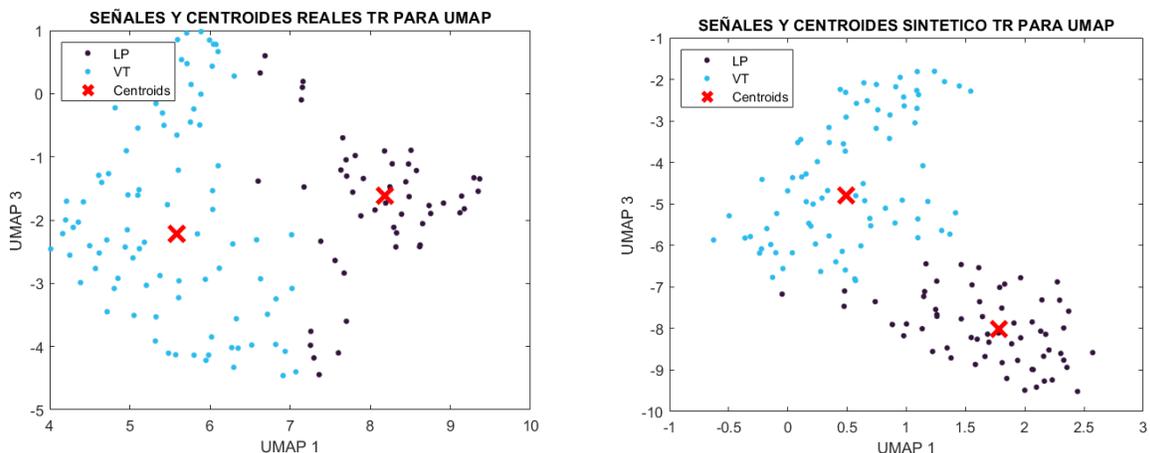


Figura 32.

Señales y Centroides Tr Reales y Sintéticas con UMAP plano 2 - 3

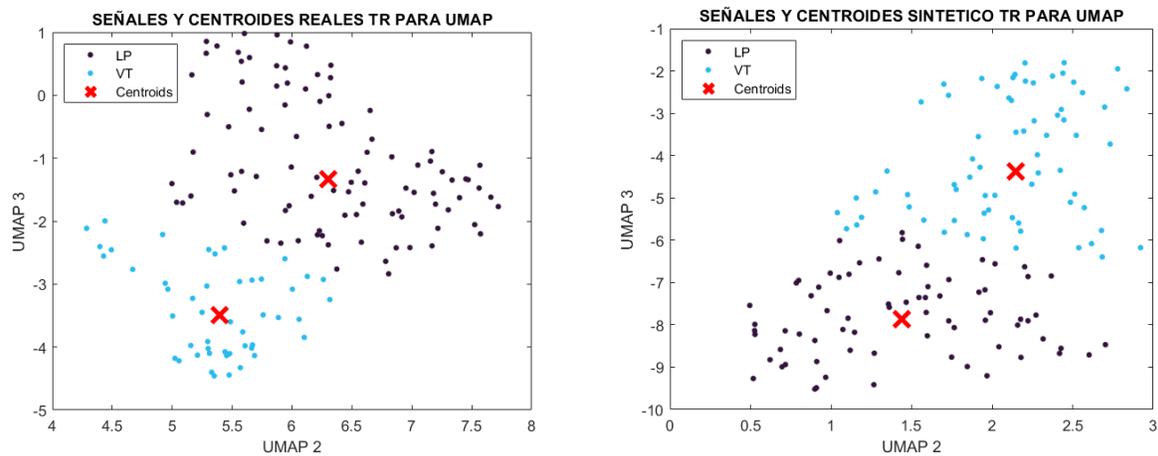


Figura 33.

Señales y Centroides TS Reales y Sintéticas con UMAP plano 1 - 2

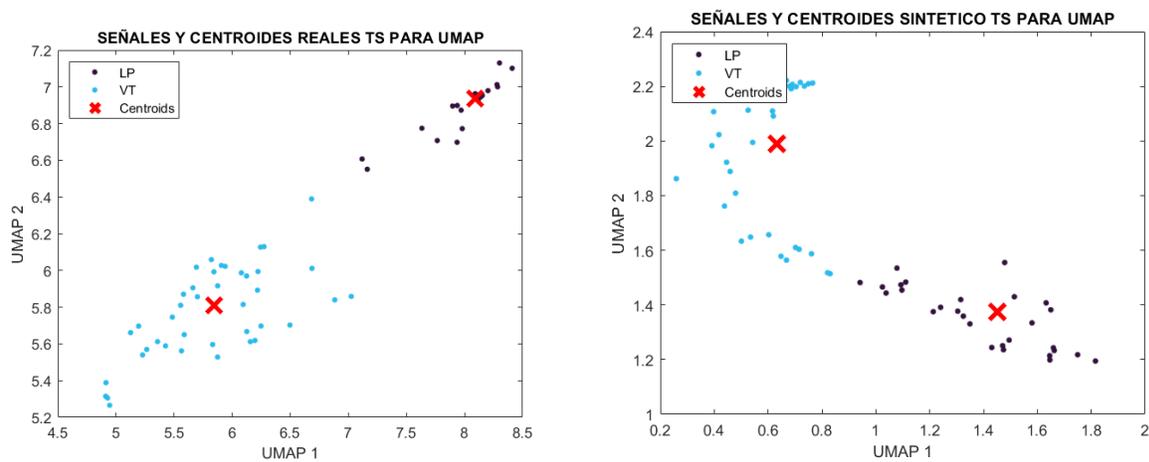


Figura 34.

Señales y Centroides TS Reales y Sintéticas con UMAP plano 1 - 3

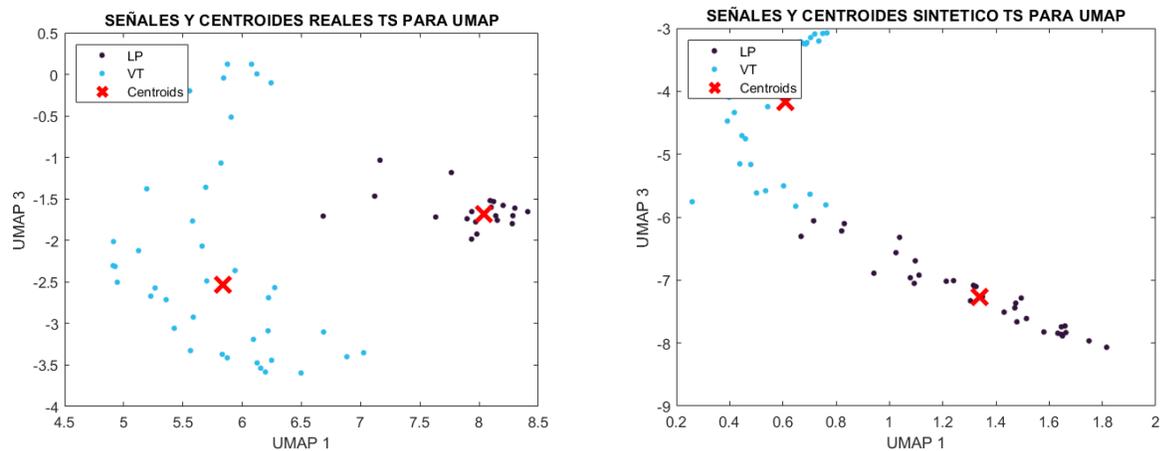
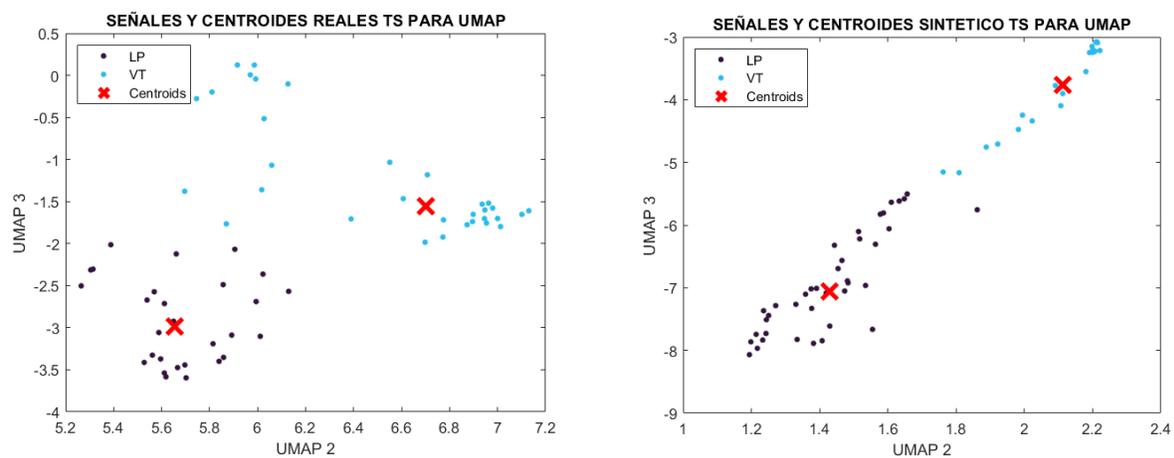


Figura 35.

Señales y Centroides TS Reales y Sintéticas con UMAP plano 2 - 3



Conclusiones y Recomendaciones

Conclusiones

Al analizar los modelos de entrenamiento, propuestos en el trabajo y de acuerdo a los resultados obtenidos, a través de los espacios latentes, se puede observar de forma objetiva y subjetiva que existe separabilidad entre los VT y LP.

En función del porcentaje de acierto de un evento sísmico, se pudo determinar por medio a de la variación de autoencoders para training y test, que al mantener el 70% para cada uno, se obtiene el mejor desempeño al emplear la base de datos con data augmentation en el modelo de entrenamiento.

De acuerdo al trabajo realizado con el generador CGAN al momento de realizar data augmentation, no se logró obtener una mejora en cuanto al desempeño, dado que los porcentajes que reflejaba no superaban al trabajo previo, se presume que las señales sintéticas no contienen ciertas características acústicas, debido a que en el trabajo de (Iglesias Giler & Rosero Arciniega, 2023) si se aprecia una mejora en el desempeño pero al implementar otras características.

Debido a que no se pudo encontrar una mejora al trabajar con data augmentation, no se encontró parámetros para la maximización del porcentaje de acierto, se procede a comparar los datos sintéticos con los reales, en las medidas objetivas, existen desfasajes, diferencias en las distancias euclidianas y en los centroides, esto se corrobora al emplear o utilizar tres métodos (t – SNE, PCA, UMAP).

De los resultados obtenidos de la Tabla 6 a la Tabla 9, se puede concluir que el mejor método al analizar reales como sintéticos fue UMAP, debido al desempeño que presentan en cuanto a la distancia y desface, en comparación a los otros dos métodos.

De las técnicas de las manifold learning; con UMAP se obtuvo un mejor resultado en la parte de test, al evaluar de forma cuantitativa a partir de las coordenadas rectangulares y polares de los centroides, con una separación de 8,69 para LP y 7.48 VT, dispersión de 8.69 para LP y 7.48 en VT y desfasaje de 21.02° en LP y 11.57° en VT.

En los parámetros libres del generador se presentaron distintas anomalías en el análisis gráfico de los centroides, como el desfase o posible ensanchamiento en cuanto a la frecuencia, se presume que esto es provocado, debido a que datos sintéticos no fueron trabajados en función del dominio de la frecuencia.

Recomendaciones

Para llevar a cabo el análisis de los modelos de entrenamiento con espacios latentes, se debe considerar que los datos a emplear se encuentren en el dominio de la frecuencia y con el mismo tamaño, debido a que se pueden presentar diferentes errores en la obtención de las características espectrales, además de influir en la posición del centroide.

En el momento de evaluar el desempeño de los modelos de entrenamiento al trabajar con autoencoders, se debe tomar en cuenta el porcentaje training y test con la finalidad de adecuar los datos al proceso a realizar, de esta forma se asegura el entrenamiento.

Al mejorar el porcentaje de desempeño en cuanto a la optimización de los parámetros libres de los datos sintéticos, se debe tomar en cuenta que el generador fue realizado en el dominio del tiempo, por lo que se debe considerar adaptar este, en función de la frecuencia para evitar posibles desplazamientos del centroide o ensanchamiento de la frecuencia.

Se debe tomar en cuenta la funcionalidad de los diferentes modelos al emplear los espacios latentes, dado que estos son aplicados en función del requerimiento, en caso de solo necesitar un análisis cualitativo puede emplearse t – SNE, por el contrario, si el estudio es cuantitativo se puede emplear UMAP o PCA.

Trabajos Futuros

Realizar una mejora en cuanto a la generación de los datos sintéticos, con el propósito de mejorar su funcionabilidad al emplearlo en el tiempo.

Referencias

- Abdi, H., & Williams, L. J. (2010). Principal component analysis. *Wiley Interdisciplinary Reviews: Computational Statistics*, 2(4), 433-459. doi: 10.1002/wics.101
- Alvarez, M., Henao, R., & Duque, E. (2007). Clasificación de eventos sísmicos empleando procesos gaussianos. *Scientia et Technica*, 1(35), Article 35.
<https://doi.org/10.22517/23447214.5385>
- Andrade, D., Escuela Politécnica Nacional (Quito, Ecuador), & Institut de recherche pour le développement (France) (Eds.). (2005). *Los peligros volcánicos asociados con el Cotopaxi*. Corporación Editora Nacional.
- Aribido, O. J., AlRegib, G., & Alaudah, Y. (2021). Self-supervised delineation of geologic structures using orthogonal latent space projection. *Geophysics*.
<https://doi.org/10.1190/geo2020-0541.1>
- Autoencoders (Autocodificadores)*. (s. f.). Recuperado 16 de junio de 2023, de
<https://la.mathworks.com/discovery/autoencoder.html>
- Bank, D., Koenigstein, N., & Giryas, R. (2021). *Autoencoders* (arXiv:2003.05991). arXiv.
<https://doi.org/10.48550/arXiv.2003.05991>
- Bernal-Oñate, C.-P., Carrera, E. V., Melgarejo-Meseguer, F.-M., Gordillo-Orquera, R., Rojo-Álvarez, J. L., & Lara-Cueva, R. (2024). Volcanic Micro-Earthquake Classification with Spectral Manifolds in Low-Dimensional Latent Spaces. *IEEE Access*, 1-1.
<https://doi.org/10.1109/ACCESS.2024.3354717>
- Bui Quang, P., Gaillard, P., Cano, Y., & Ulzibat, M. (2015). Detection and classification of seismic events with progressive multi-channel correlation and hidden Markov models. *Computers & Geosciences*, 83, 110-119. <https://doi.org/10.1016/j.cageo.2015.07.002>
- Cáceres, B., Ramírez, J., Francou, B., Eissen, J.-P., Taupin, J.-D., & Jordan, E. (s. f.). *DETERMINACIÓN DEL VOLUMEN DEL CASQUETE DE HIELO DEL VOLCÁN COTOPAXI*. Instituto Nacional de Meteorología e Hidrología.

https://d1wqtxts1xzle7.cloudfront.net/92574680/3informe-cotopaxi-2004-libre.pdf?1666005508=&response-content-disposition=inline%3B+filename%3DDeterminacion_del_volumen_del_casquete_d.pdf&Expires=1684873765&Signature=K9hP1-LN341j1nEtBEQ0lsaPNYvjajL5OJq1rSR35Q5X3BAbTsl5RjiNArTp-WXpOdD~QASQ7aZ5TRh5nWv~Tp7rLlhCL2sPk3-DdKrm96-lxT4OD6dZaD2DObUPYn8ThlgUVqcimt-Guon3KNU5jktNy6mb~qQnuOSp2EPdOhZtpSXgTDOPf38jRoFRftXegICfo2Mx~IS3OTUuYTBavRyMPBpz-CoHNv1wUcz9piy5fJYwzZaquTqlZbo1vaf4uatqZsKp8MYV35giFWOwMWGp20uumyOkeLvHJmgix99PhyS0Ze7nSuKZHL4Nmz0aydH8~nYOwndAlrdUbxutPw__&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA

- Camacho Calle, K. S. (2022). *Generación de señales sintéticas de eventos sismo-volcánicos usando el método de Reconstrucción de señales a través de su Fase* [bachelorThesis, Universidad de las Fuerzas Armadas ESPE. Carrera de Ingeniería en Electrónica y Telecomunicaciones]. <http://repositorio.espe.edu.ec/jspui/handle/21000/31682>
- Centeno Quico, R., & Rivera, M. (2020). *Reconocimiento automático de señales sísmicas de origen volcánico para la alerta temprana de erupciones volcánicas del sur del Perú*. <https://repositorio.igp.gob.pe/handle/20.500.12816/4783>
- Diaz-Papkovich, A., Anderson-Trocmé, L., & Gravel, S. (2021). A review of UMAP in population genetics. *Journal of Human Genetics*, 66(1), Article 1. <https://doi.org/10.1038/s10038-020-00851-4>
- Diez Tabara, D. (2023). *Análisis estadístico de indicadores de juventud en espectros RP de estrellas enanas ultrafrías de Gaia*. <http://e-spacio.uned.es/fez/view/bibliuned:master-ETSInformatica-ICD-Ddiez>

Duque, A., González, K., Pérez, N., Benítez, D., Grijalva, F., Lara-Cueva, R., & Ruiz, M. (2020).

Exploring the unsupervised classification of seismic events of Cotopaxi volcano. *Journal of Volcanology and Geothermal Research*, 403, 107009.

<https://doi.org/10.1016/j.jvolgeores.2020.107009>

Duque Pilataxi, B. P., & Tipantuña Tenelema, C. J. (2010). *Estudio, análisis e implementación*

en software de simulación matlab del algoritmo mp3 para compresión de audio a través del uso de técnicas digitales para el procesamiento de señales [bachelorThesis,

QUITO/EPN/2010]. <http://bibdigital.epn.edu.ec/handle/15000/2619>

Evaluación de Técnicas de Extracción de Características Orientado a la Clasificación de Señales Sísmico-volcánicas del Volcán Nevado del Ruiz—ProQuest. (s. f.-a).

Recuperado 28 de agosto de 2022, de

[https://www.proquest.com/openview/89389c5e0d0fd26011712fb07d7dda20/1?pq-](https://www.proquest.com/openview/89389c5e0d0fd26011712fb07d7dda20/1?pq-origsite=gscholar&cbl=1006393)

[origsite=gscholar&cbl=1006393](https://www.proquest.com/openview/89389c5e0d0fd26011712fb07d7dda20/1?pq-origsite=gscholar&cbl=1006393)

Evaluación de Técnicas de Extracción de Características Orientado a la Clasificación de Señales Sísmico-volcánicas del Volcán Nevado del Ruiz—ProQuest. (s. f.-b).

Recuperado 16 de agosto de 2022, de

[https://www.proquest.com/openview/89389c5e0d0fd26011712fb07d7dda20/1?pq-](https://www.proquest.com/openview/89389c5e0d0fd26011712fb07d7dda20/1?pq-origsite=gscholar&cbl=1006393)

[origsite=gscholar&cbl=1006393](https://www.proquest.com/openview/89389c5e0d0fd26011712fb07d7dda20/1?pq-origsite=gscholar&cbl=1006393)

Fuentes, E. J. V. (2019). *Introducción a los métodos Deep Learning basados en Redes Neuronales.*

Galarza Cruz, C. R., & Vega Vergara, J. M. (2022). *Generación de señales sintéticas de eventos sísmo—Volcánicos del volcán Cotopaxi a través de un modelo de red neuronal adverso generativo condicional.* Universidad de las Fuerzas Armadas ESPE.

<https://repositorio.espe.edu.ec/bitstream/21000/31542/1/T-ESPE-052391.pdf>

García, D. R., Enríquez, H. J. V., Hernández, S. H., Velázquez, A. T., & Barbosa, R. C. (2020).

Reconocimiento de Glaucoma usando Imágenes de fondo de la Retina: Glaucoma

- Recognition Using Background Images of the Retina. *Tecnología Educativa Revista CONAIC*, 7(1), Article 1. <https://doi.org/10.32671/terc.v7i1.18>
- Gutierrez, J. M. (s. f.). *Introducción a las Redes Neuronales*.
- Guzmán, L. M. R., & Gallegos, D. R. (s. f.). *ELABORACIÓN DEL PLAN COMUNITARIO DE GESTIÓN DE RIESGOS PARA LA COMUNIDAD "LIBERTAD", DEL CANTÓN MERA, PROVINCIA DE PASTAZA*. 112.
- Iglesias Giler, I. A., & Rosero Arciniega, L. A. (2023). *Implementación de un sistema clasificador de microterremotos del volcán Cotopaxi basado en técnicas de Deep Learning*. Universidad de las Fuerzas Armadas ESPE. <https://repositorio.espe.edu.ec/handle/21000/36707>
- Kortström, J., Uski, M., & Tiira, T. (2016). Automatic classification of seismic events within a regional seismograph network. *Computers & Geosciences*, 87, 22-30. <https://doi.org/10.1016/j.cageo.2015.11.006>
- Lara-Cueva, R., Paillacho, V., & Villalva, M. (2016). Detección de Eventos del Volcán Cotopaxi Empleando Clasificación Supervisada. *Revista Iberoamericana de las Ciencias Computacionales e Informática*, 5, 123-144. <https://doi.org/10.23913/reci.v5i9.52>
- Leon, D., Ordoñez, H., & Bucheli, V. (2020). TagEQ: Sistema de Clasificación de Eventos Sísmicos Basado en Inteligencia Artificial. *RISTI - Revista Iberica de Sistemas e Tecnologías de Informacao*, e27, 359-370.
- Lerch, A. (2012). *Audio content analysis: An introduction*. Wiley.
- López, F., Mora, A., & Magán-Carrión, R. (2023). *Influencia de la selección de hiper-parámetros en el rendimiento de autoencoders para la detección de ataques en red*.
- Maaten, L. van der, & Hinton, G. (2008). Visualizing Data using t-SNE. *Journal of Machine Learning Research* 9, 9, 2579-2605.

- McInnes, L., Healy, J., & Melville, J. (2020). *UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction* (arXiv:1802.03426). arXiv.
<https://doi.org/10.48550/arXiv.1802.03426>
- Medina, B., Sierra, J. E., & Ulloa, A. B. (2018). Técnicas de extracción de características de señales EEG en la imaginación de movimiento para sistemas BCI. *Revista ESPACIOS*, 39(22). <https://www.revistaespacios.com/a18v39n22/18392236.html>
- Minango Guatumillo, M. (2022). *Clasificación de eventos sismo volcánicos usando características psicoacústicas mediante técnicas de aprendizaje automático supervisado y no supervisado*. Repositorio Universidad de las Fuerzas Armadas ESPE.
<https://repositorio.espe.edu.ec/bitstream/21000/31541/1/T-ESPE-052390.pdf>
- Moreno, G. C. (2015). *Reconocimiento de señales sismo-volcánicas mediante canales específicos basados en modelos ocultos de Markov* [Http://purl.org/dc/dcmitype/Text, Universidad de Granada]. <https://dialnet.unirioja.es/servlet/tesis?codigo=56544>
- Munive Benites, D. A. (2016). *Análisis de la molestia causada por la variabilidad temporal y espectral del ruido de tráfico en la ciudad de Quito* [bachelorThesis, Quito: Universidad de las Américas, 2016]. <http://dspace.udla.edu.ec/handle/33000/4912>
- Nacelle, A. (2009). *Redes neuronales artificiales*.
<http://www.nib.fmed.edu.uy/Seminario%202009/Monografias%20seminario%202009/Nacelle-Redes%20NeuronalesImplementacion.pdf>
- Pepino, L., & Bender, L. (2018). *Separación de fuentes musicales mediante redes neuronales convolucionales con múltiples decodificadores*.
- Pérez Curiel, C. (2022). *Análisis del espacio latente en el auto-encoder variacional* [Masters, E.T.S.I de Sistemas Informáticos (UPM)]. <https://oa.upm.es/71832/>
- Pérez González, G. A. (2021). *Detección de transacciones fraudulentas en tarjetas de crédito mediante el uso de modelos de Machine Learning*.
<https://repositorio.uniandes.edu.co/handle/1992/53571>

- Proaño Portilla, M. J. (2022). *Análisis comparativo de grupos de características para la clasificación de señales sísmicas VT y LP del volcán Cotopaxi*.
<http://bibdigital.epn.edu.ec/handle/15000/22695>
- Puga Reyes, E. X. (2020). *Análisis de algoritmos de Clustering basados en particionamiento y basados en Densidad para el procesamiento de trayectorias GPS*.
<http://repositorio.ug.edu.ec/handle/redug/49617>
- Restrepo Arteaga, G. J. P. (2015). Aplicación del aprendizaje profundo (deep learning) al procesamiento de señales digitales. *instname:Universidad Autónoma de Occidente*.
<http://hdl.handle.net/10614/7975>
- Rodríguez Murillo, N. A. (2019). *Análisis de validación cruzada bajo diferentes condiciones de ruido*. <https://rinacional.tecnm.mx/jspui/handle/TecNM/810>
- Roy Martínez, S. (2020, julio). *Sistema en Matlab para la segmentación y clasificación automática de sonidos de ballenas* [Info:eu-repo/semantics/bachelorThesis]. E.T.S.I y Sistemas de Telecomunicación (UPM). <https://oa.upm.es/66972/>
- Sainburg, T., McInnes, L., & Gentner, T. Q. (2021). Parametric UMAP Embeddings for Representation and Semisupervised Learning. *Neural Computation*, 33(11), 2881-2907.
https://doi.org/10.1162/neco_a_01434
- Sánchez Muñoz, J. M. (2016). Análisis de Calidad Cartográfica mediante el estudio de la Matriz de Confusión. *Pensamiento Matemático*, 6(2), 9-26.
- Sefla, O. R. P. (s. f.). *INGENIERO EN ESTADÍSTICA INFORMÁTICA*. 145.
- Sierra Fernández, J. M. (2017). *Técnicas y procedimientos de medida basados en la kurtosis espectral. Una aplicación en el análisis de la calidad de la energía eléctrica* [Http://purl.org/dc/dcmitype/Text, Universidad de Cádiz].
<https://dialnet.unirioja.es/servlet/tesis?codigo=72920>
- Titos, M., Bueno, A., García, L., & 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.

<https://doi.org/10.1109/JSTARS.2018.2803198>

Zapata Yugsi, J. P. (2022). *Generación de señales volcánicas artificiales de tipo LP (long-period) y VT (volcano-tectonic) a partir de una base de datos del volcán Cotopaxi usando la técnica de bootstrapping*. [bachelorThesis, Quito : EPN, 2022.].

<http://bibdigital.epn.edu.ec/handle/15000/23276>