



ESPE

UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

DEPARTAMENTO DE ELÉCTRICA, ELECTRÓNICA Y TELECOMUNICACIONES CARRERA EN TELECOMUNICACIONES

“Creación de algoritmos inteligentes basados en la teoría de Machine Learning tradicional para la detección de los eventos sísmicos en el volcán Llaima”

Autor: Castillo Tipantuña, Edwin Alexander

Director del Proyecto: Ing. Román Alcides Lara Cueva, PhD.

06 de septiembre de 2023



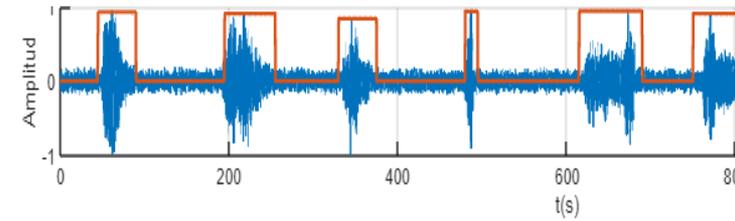
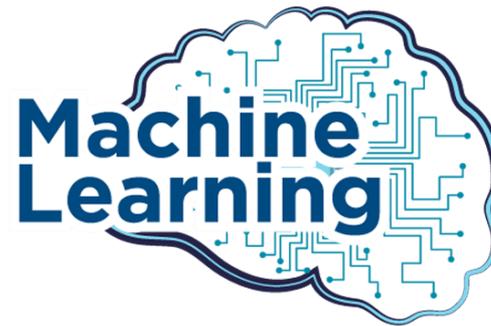
Agenda

- 1.- **Introducción**
- 2.- **Materiales y Métodos**
- 3.- **Pruebas y Resultados**
- 4.- **Conclusiones y Trabajos futuros**



1. Introducción

Motivación e Importancia



1. Introducción

Antecedentes

STA/LTA

99% Exactitud
0.011 BER
Detección

VAD

99% Exactitud
Detección

HMM

94% Exactitud
Detección

Machine Learning

98% Exactitud
0.017 BER
Detección

Deep Learning

Exactitud > 90%
Clasificación

1. Introducción

Objetivos y Actividades

- OBJETIVO

Crear algoritmos inteligentes basados en la teoría de Machine Learning tradicional para la detección de eventos sísmicos en el volcán Llaima

- ACTIVIDADES

Actividad 1. - Identificación de las propiedades y variables del problema a tener en cuenta

Actividad 2. - Reunión de la base de datos representativa, con datos provistos por el Observatorio Volcanológico de los Andes del Sur.

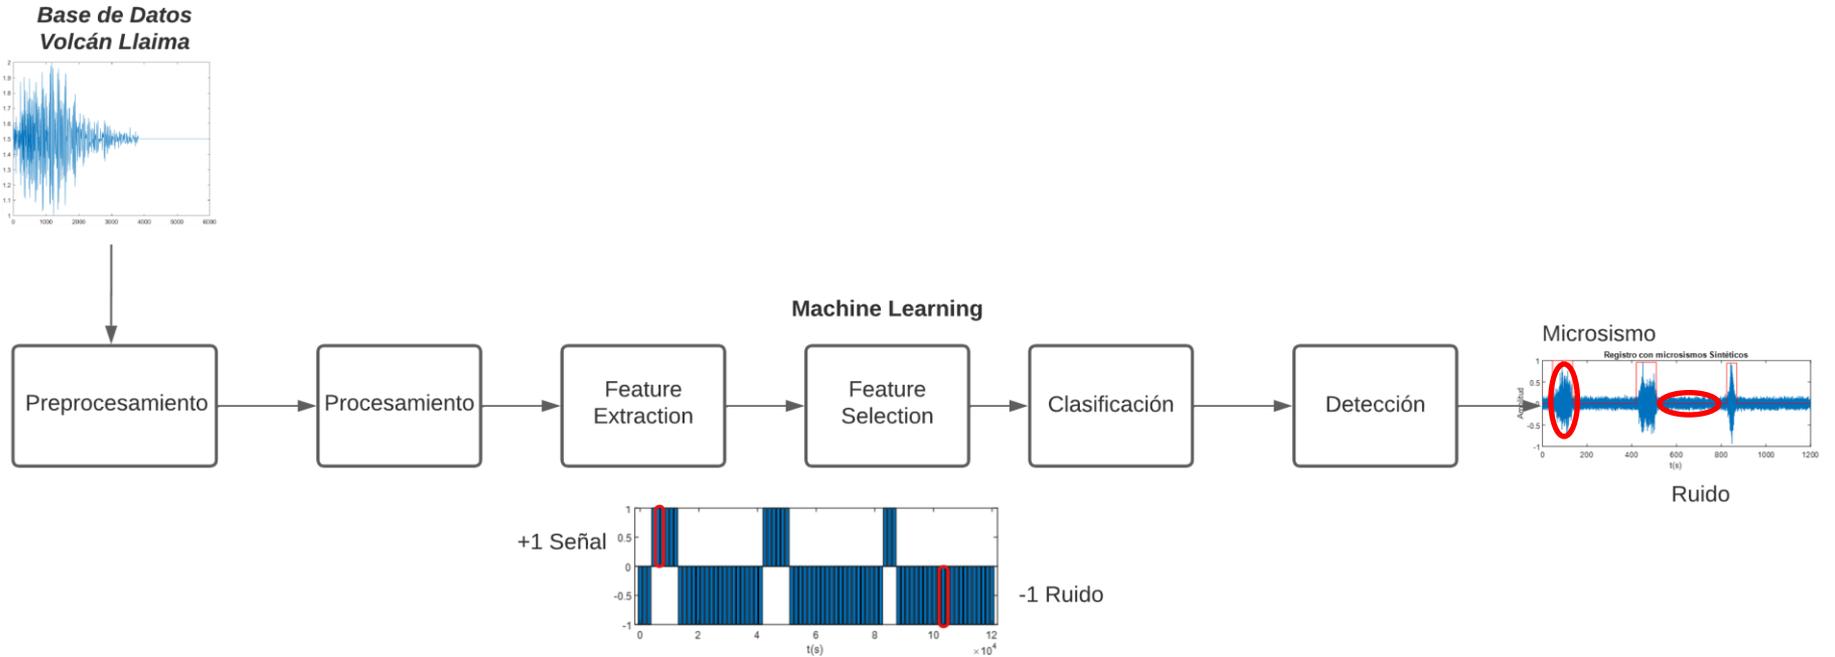
Actividad 3. - Creación de una estructura de datos (temporales, espaciales, otros.) con un soporte común.

Actividad 4. - Identificación de la información a priori a incluir en los algoritmos, y creación de algoritmos de Machine Learning tradicional adaptados al problema.

Actividad 5. - Pruebas y evaluación del desempeño.



2. Materiales y Métodos



2. Materiales y Métodos

Base de datos Volcán Llaima

Las base de datos provistas por el Observatorio Vulcanológico de los Andes Sur (OVDAS) se compone de 3592 señales muestreadas a 100 Hz que se clasifican en:

- Long Period (LP) → 1310 señales
- Tremor (TR) → 490 señales
- Tectonic (TC) → 1488 señales
- Volcano – Tectonic (VT) → 304 señales

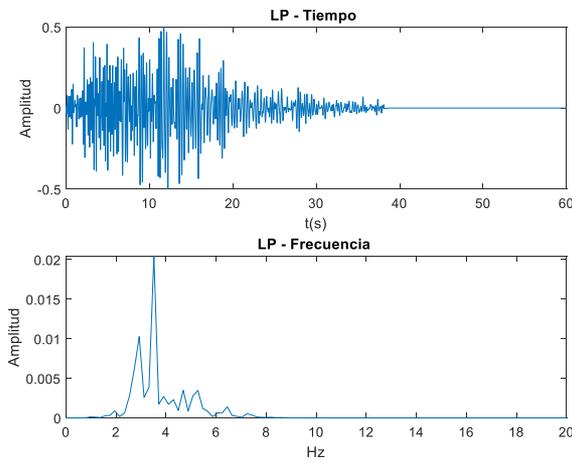


Fig. 1 LP

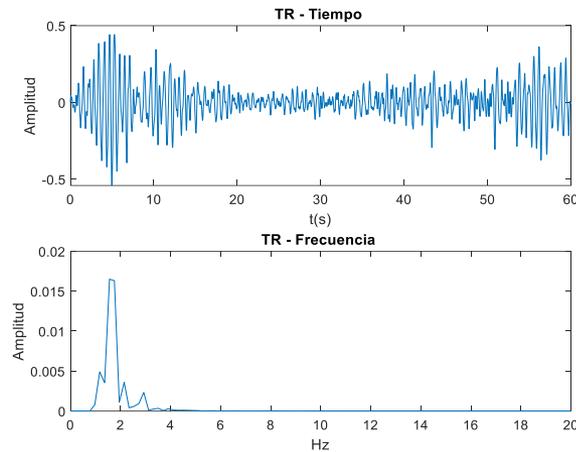


Fig. 2 TR

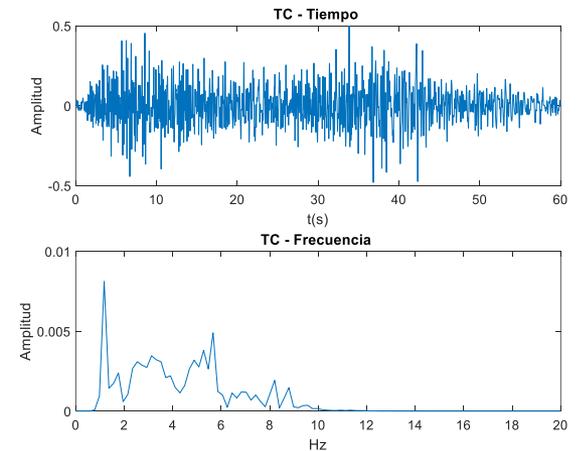


Fig. 3 TC

2. Materiales y Métodos

Base de datos Volcán Llaima

Las base de datos provistas por el Observatorio Vulcanológico de los Andes Sur (OVDAS) se compone de 3592 señales muestreadas a 100 Hz que se clasifican en:

- Long Period (LP) → 1310 señales
- Tremor (TR) → 490 señales
- Tectonic (TC) → 1488 señales
- Volcano – Tectonic (VT) → 304 señales

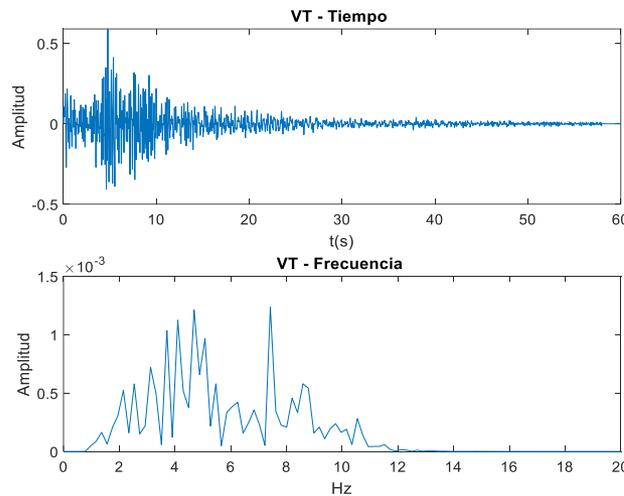


Fig. 4 VT

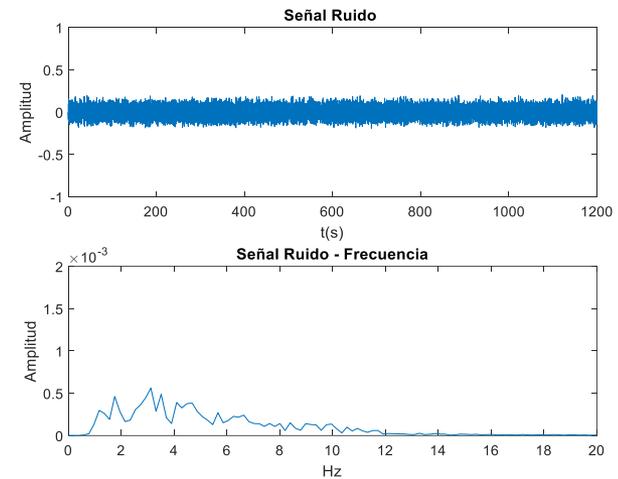


Fig. 5 Señal de Ruido

2. Materiales y Métodos - Preprocesamiento

Filtrado

Se realiza el proceso de filtrado debido a que al realizar el análisis espectral de cada uno de los microsismos se encuentra la presencia de un pico permanente en 0.2 Hz que de acuerdo con Kennett. (2001), está relacionado con los choques del océano con el continente.

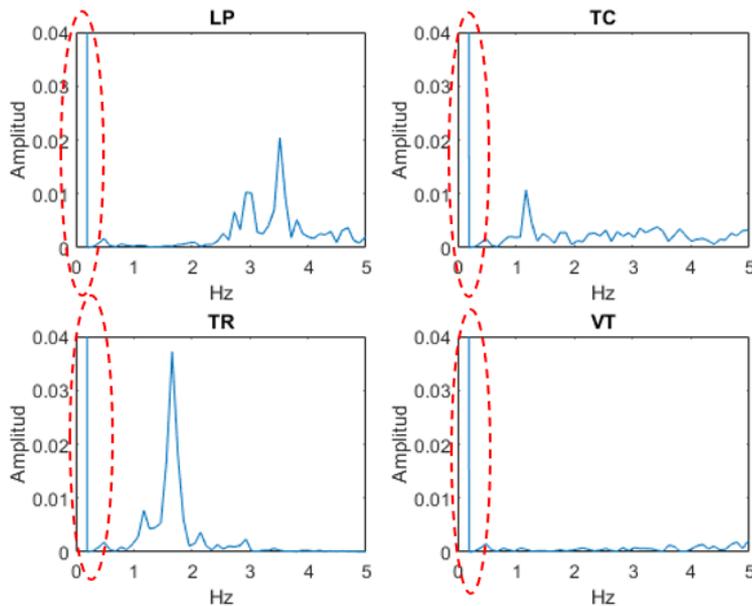


Fig. 6 Pico de 0.2 Hz en evento LP, TC, TR y VT

Normalización base de datos

1. De cada microsismo (S_M), extraer la media (μ_M) y dividir para la desviación estándar (σ_M).

$$zS_M = \frac{S_M - \mu_M}{\sigma_M}$$

2. Dividir la señal estandarizada (zS_M), para su máximo absoluto

$$z_{1M} = \frac{zS_M}{\max|zS_M|}$$

Se obtiene un rango de amplitud entre -1 y 1



2. Materiales y Métodos - Preprocesamiento

Generación de Ruido

Dado que la base de datos contiene únicamente microsismos de 60 segundos se crea una señal de ruido η de 20 minutos con el objetivo de combinar ambas señales y obtener registros de 20 minutos.



Fig. 7 Diagrama de bloques para la generación de señal de ruido

Combinación Microsismo - Ruido

Con el fin de obtener registros de 20 minutos, se lleva a cabo el proceso de combinar ambos tipos de señales previamente obtenidas.

$$Y = z_{1M} + \eta$$

donde Y es el registro de 20 minutos, z_{1M} es el microsismo de 60 [s] normalizado y η la señal de ruido de 20 minutos.



2. Materiales y Métodos - Procesamiento

Segmentación

Los registros se segmentan en ventanas de 15 segundos, esto debido al criterio propuesto por (Lara-Cueva et al., 2016) donde determino que la ventana de 15 segundos es la óptima.

Etiquetado

Se calcula la SNR de cada ventana de 15 segundos respecto a una señal de ruido de la misma longitud.

SNR \geq 3 dB \rightarrow Se etiqueta como +1 \rightarrow Señal
SNR $<$ 3 dB \rightarrow Se etiqueta como -1 \rightarrow Ruido

Balanceo de Datos

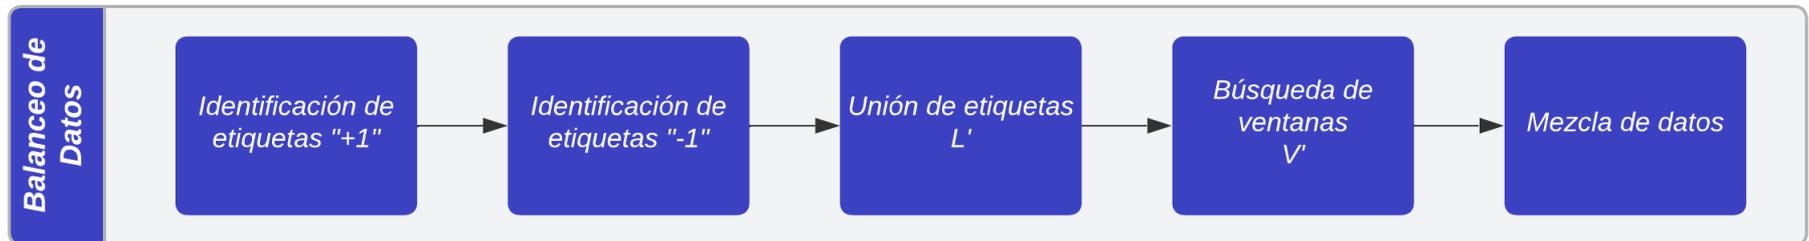


Fig. 8 Diagrama de bloques para balanceo de datos

2. Materiales y Métodos – Feature Extraction

Partición de datos

Se emplea la partición de datos aleatoria de validación cruzada del tipo Hold Out

Partición	Entrenamiento %	Validación %
1	80	20
2	70	30
3	50	50
4	20	80

Dominio	Total
Tiempo	13 características (media, kurtosis, desviación estándar, etc.)
Frecuencia	41 características (media, kurtosis, varianza, entropía, etc.)
Escala	30 características (D1-D6 Máx, pico en el dominio de la freq, A6 Freq de pico máx, etc.)

Procesamiento de señales

Base de datos en el dominio temporal

Corresponde al mismo conjunto de datos entrenamiento y prueba en tiempo

Base de datos en el dominio frecuencial

Se obtiene al aplicar la técnica de la PSD Welch a las ventanas de 15 segundos, lo cual implica pasar del dominio temporal al dominio de la frecuencia

Base de datos con la extracción de las 84 características

Por cada ventana de 15 segundos, se obtienen las 84 características mas relevantes entre tiempo, frecuencia y escala



2. Materiales y Métodos - Entrenamiento

Modelos de ML

Se emplean 3 modelos de ML para cada una de las bases de datos

Decision Tree

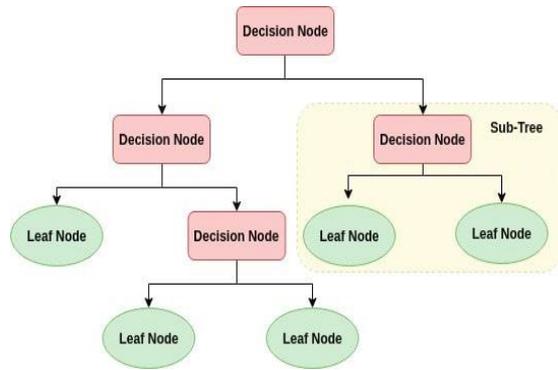


Fig. 9 Decision Tree

El parámetro variable es el tamaño mínimo de las hojas de un árbol (MinLeafSize)

Support Vector Machine

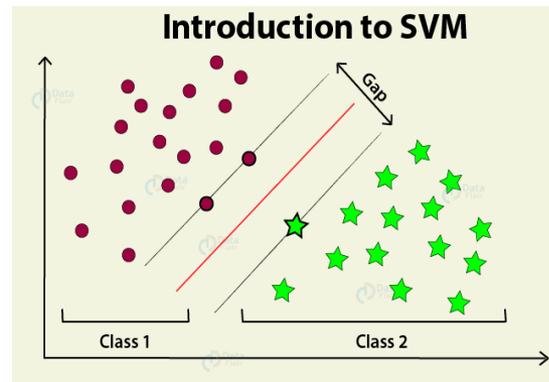


Fig. 10 Support Vector Machine

El parámetro variable es C (BoxConstraint), que controla la penalización de los errores en la clasificación en el entrenamiento.

k Nearest Neighbors

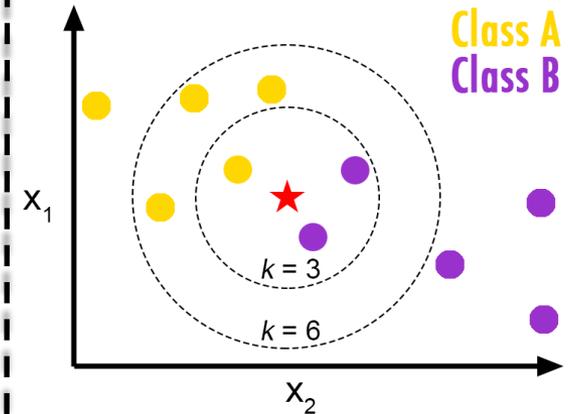


Fig. 11 k Nearest Neighbors

Los parámetros variables son el número de vecinos y la métrica de distancia.

2. Materiales y Métodos - Entrenamiento

Métricas de Desempeño

La matriz de confusión es la herramienta que nos ayuda a tener una visión de que tan preciso es nuestro modelo.

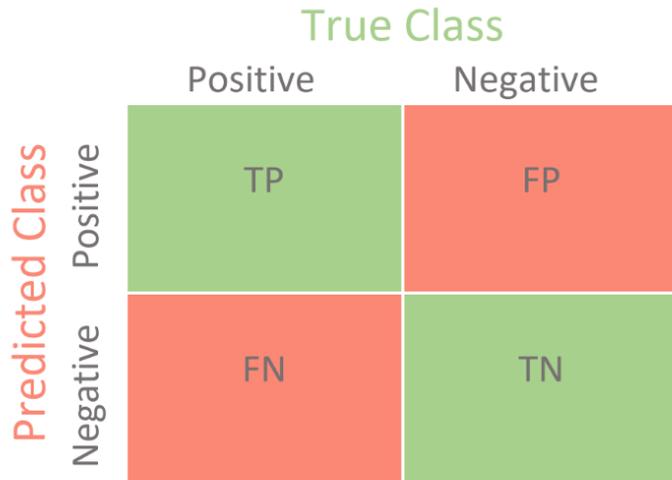


Fig. 12 Matriz de confusión

Clasificación

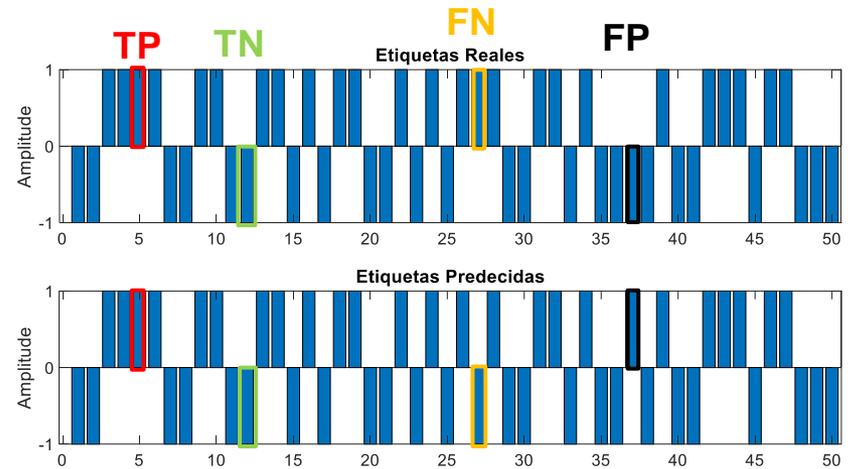


Fig. 13 Clasificación

Detección

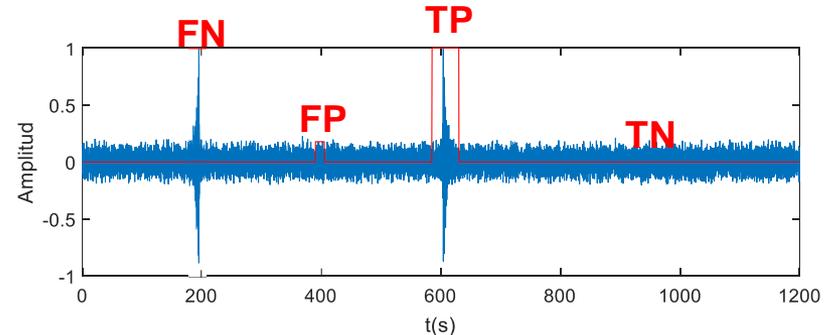


Fig. 14 Detección

2. Materiales y Métodos - Entrenamiento

Métricas de Desempeño

La matriz de confusión es la herramienta que nos ayuda a tener una visión de que tan preciso es nuestro modelo.

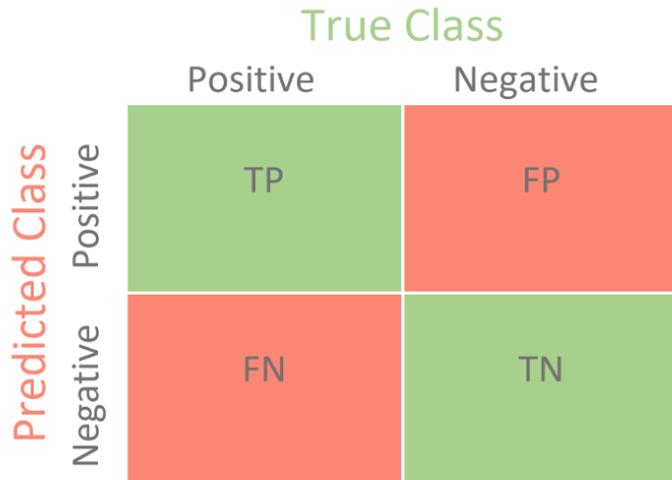


Fig. 12 Matriz de confusión

A partir de ella se pueden calcular las métricas de desempeño que son con las que evaluaremos a nuestro modelo.

Métrica de Desempeño	Fórmula
Exactitud (%)	$A = \frac{TP + TN}{TP + TN + FP + FN} \times 100$
Precisión (%)	$P = \frac{TP}{TP + FP} \times 100$
Sensibilidad (%)	$R = \frac{TP}{TP + FN} \times 100$
Especificidad (%)	$S = \frac{TN}{TN + FP} \times 100$
BER	$BER = 1 - \frac{R + S}{200}$

3. Pruebas y Resultados Preprocesamiento

Filtrado

Se aplica un filtro pasa banda de tipo FIR de orden 256, con $f_{min} = 0.7 \text{ Hz}$ y $f_{sup} = 49,5 \text{ Hz}$, a las 3592 señales sísmicas del volcán Llaima

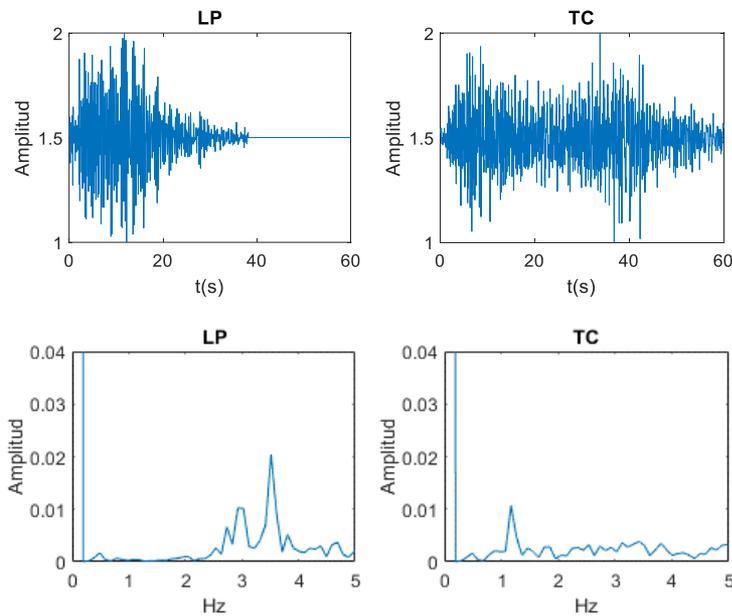


Fig. 15 Microsismos no filtrados

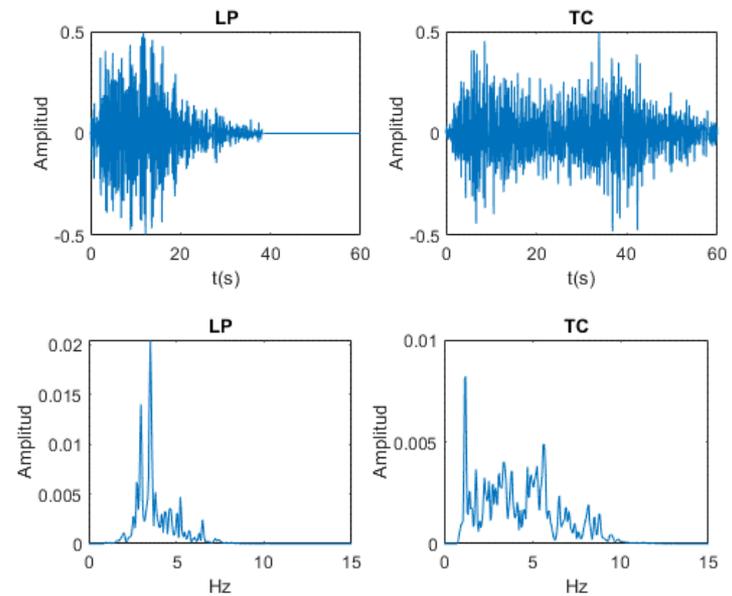


Fig. 16 Microsismos filtrados

3. Pruebas y Resultados Preprocesamiento

Generación de Ruido

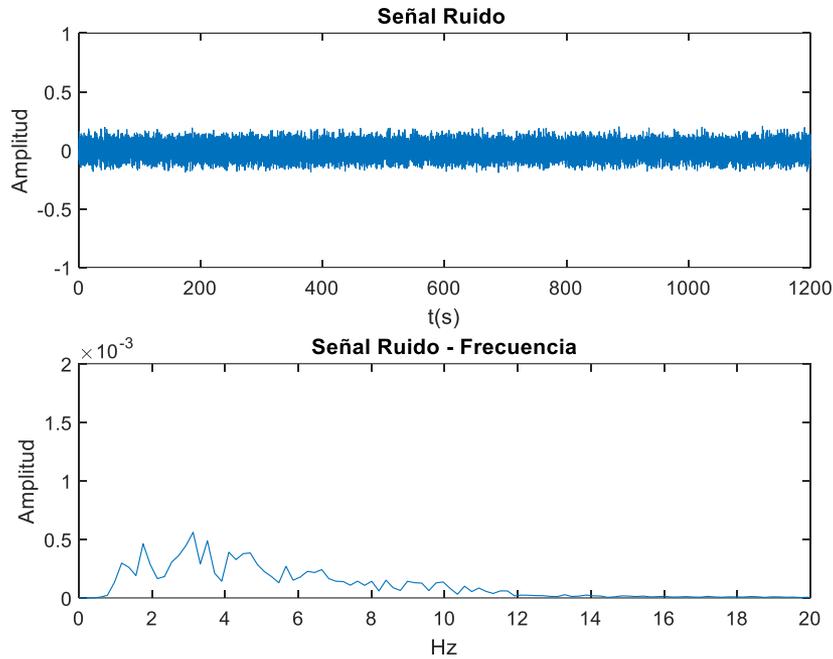


Fig. 17 Señal de ruido generada

Combinación Microsismo - Ruido

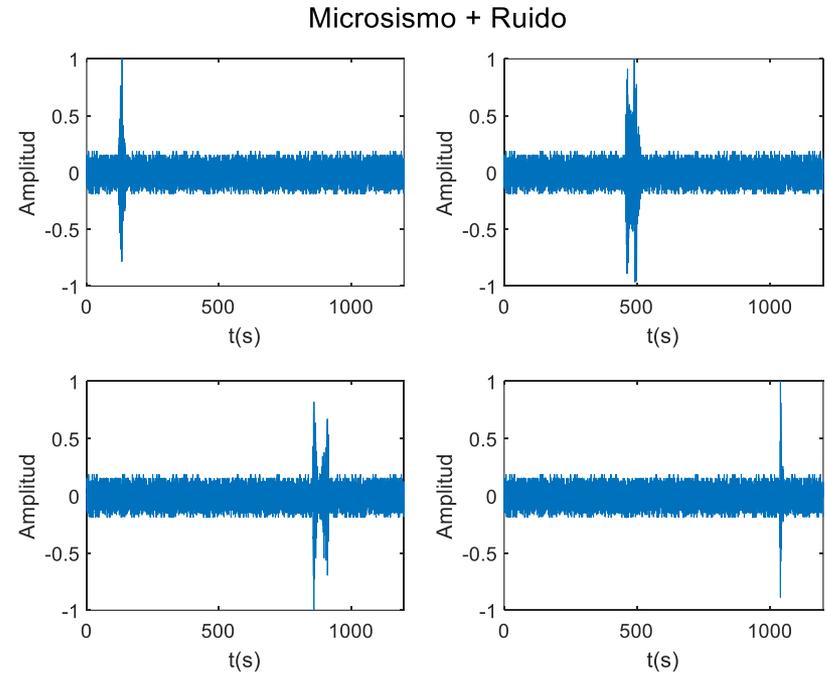


Fig. 18 Combinación microsismo - ruido

3. Pruebas y Resultados Procesamiento

Segmentación y Etiquetado

Se obtiene un total de 4 etiquetas con “+1” que indican que esas ventanas contienen señal y 76 etiquetas con “-1” indicando que esas ventanas contienen Ruido.

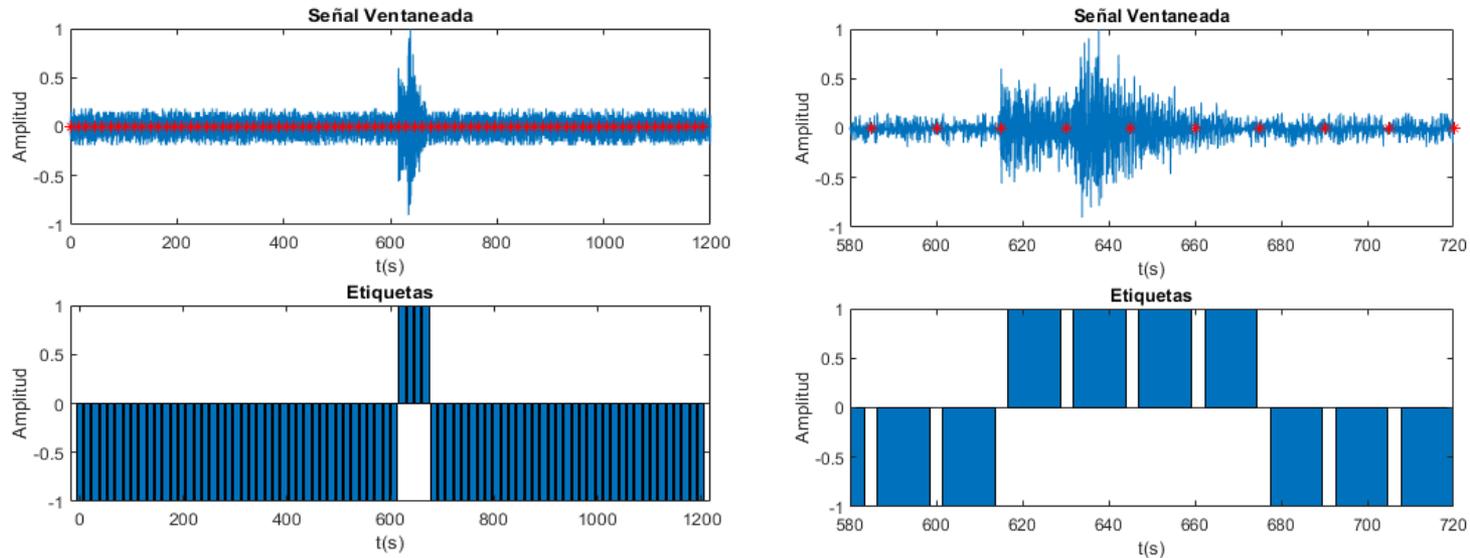


Fig. 19 Etiquetado y segmentado de registro de 20 minutos

Se obtiene un total de:

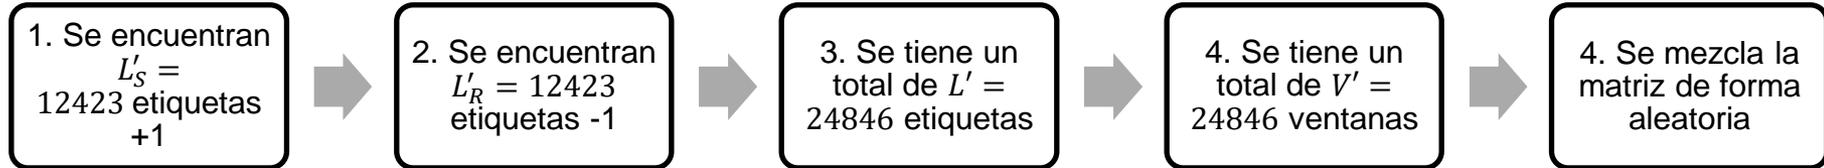
$$V = \{v_1^T, v_2^T, \dots, v_{3592}^T\}^T$$

$$L = \{l_1^T, l_2^T, \dots, l_{3592}^T\}^T$$



3. Pruebas y Resultados Procesamiento

Balanceo de Datos



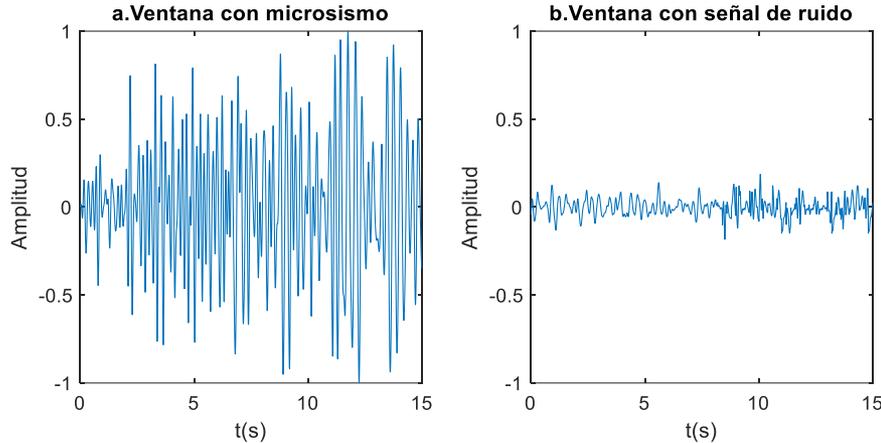
Partición de Datos

Partición	Entrenamiento %	<i>Train</i>	Validación %	<i>Validation</i>	Total
1	80	19877	20	4969	24846
2	70	17393	30	7453	24846
3	50	12423	50	12423	24846
4	20	4970	80	19876	24846

3. Pruebas y Resultados Feature Extraction

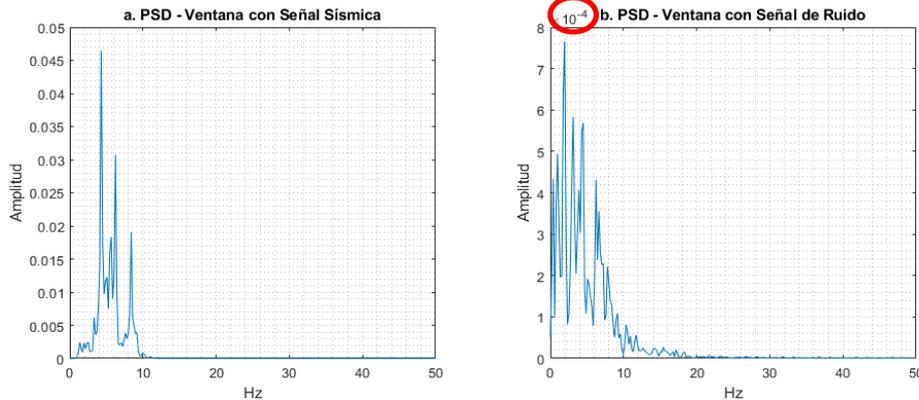
Procesamiento de señal

Base de datos en el dominio temporal:



Base de datos en el dominio frecuencial

Por cada señal se obtendrán 257 puntos



Base de datos con la extracción de las 84 características

Columna 1 – 13 : Características en tiempo

24846x84 table

	1	2	3	4	5	6	7
	t_mean	t_std	t_var	t_entropy	t_kurtosis	t_multiscaleEntropy	t_time2peak
1	-0.0203	0.2806	0.0787	191.3447	3.6875	2.0699	13.9900
2	0.0054	0.2669	0.0712	177.0200	4.2550	2.0419	4.5900
3	-0.0026	0.2166	0.0469	149.0047	4.1321	2.0630	12.3900
4	-9.1188e-04	0.2344	0.0549	161.9117	4.6743	2.0998	14.9700
5	0.0013	0.2079	0.0432	134.0521	6.0442	2.0572	1.1800
6	0.0029	0.2127	0.0453	119.2265	6.8197	1.8418	13.8500

Columna 14 - 54: Características en frecuencia

24846x84 table

	14	15	16	17	18	19	20
	f_peaks_pos_1	f_90_percent_energy	f_entropy	f_mean	f_std	f_var	f_energy
1	2.5391	10.8398	-6.0696e+06	-38.4445	10.1195	102.4039	118.6522
2	3.7109	9.6680	-6.3072e+06	-39.2645	9.7827	95.7010	106.8188
3	5.0781	8.5938	-1.1655e+07	-51.0630	14.4010	207.3888	70.3469
4	1.2695	6.7383	-1.0611e+07	-49.5235	12.1094	146.6382	82.3617
5	3.2227	4.8828	-1.4786e+07	-57.1370	14.9492	223.4781	64.7682
6	2.5391	3.6133	-9.3915e+06	-47.0865	10.8015	116.6724	67.8422

Columna 55 - 84: Características de escala

24846x84 table

	55	56	57	58	59	60
	w_t_meanEnergyAD	w_t_PEC_A6	w_t_PEC_D1	w_t_PEC_D2	w_t_PEC_D3	w_t_PEC_D4
1	22.9733	17.6568	1.8156	4.1667	20.5886	21.0196
2	16.7617	8.6863	1.7590	3.8143	22.1256	36.3671
3	18.3982	25.4962	0.0319	0.4052	23.3216	30.6247
4	35.4120	52.1098	5.7788e-04	0.0688	5.1469	11.0789
5	17.9777	35.1140	8.4860e-05	0.0401	3.7175	21.6558



ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

3. Pruebas y Resultados Procesamiento

Normalización por el método de máximos y mínimos

La característica 16, que corresponde a la entropía en frecuencia, muestra una amplitud considerablemente superior en comparación con las otras 83 características.

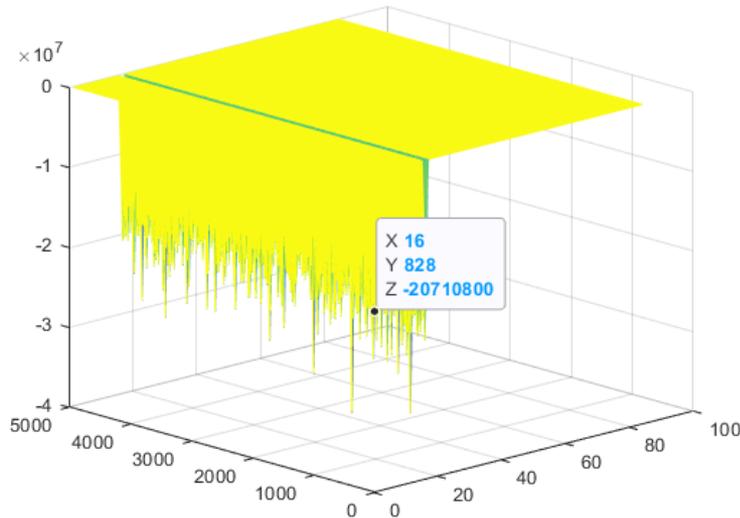


Fig. 20 Característica 16 – Entropía en Frecuencia

Se normaliza la base de datos por característica con el método de mínimos y máximos

$$z_M = \frac{c_M - \min(c_M)}{\max(c_M) - \min(c_M)}$$

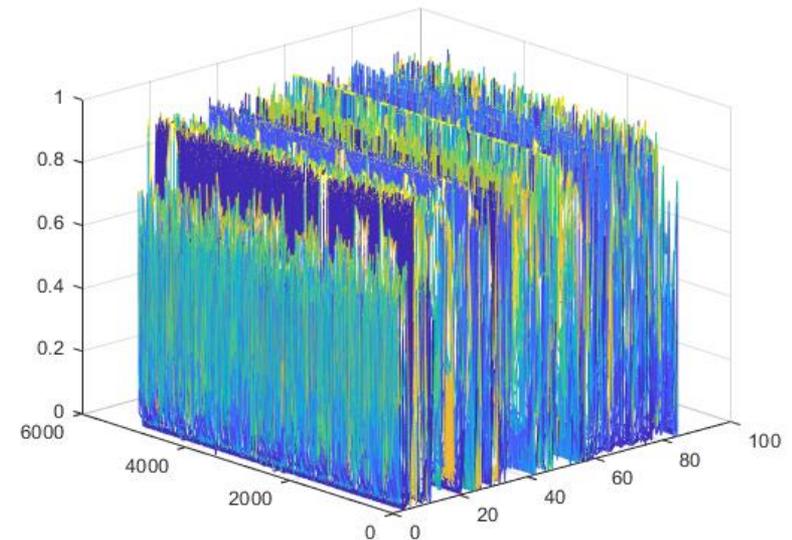


Fig. 21 Normalización de las 84 características

3. Pruebas y Resultados Validación

Partición 80 - 20

Tiempo

Modelo	Configuración	A %	P %	R%	S %	BER
DT	<i>MinleafSize = 4</i> <i>Prune = On</i> <i>SplitCriterion = gdi</i>	99.51	99.51	99.51	99.51	0.0048
SVM	<i>KernelFunction = linear</i> <i>BoxConstraint = 250</i>	98.12	99.58	96.65	99.59	0.0187
k-NN	<i>k = 2</i> <i>Distance = cosine</i>	98.04	99.95	96.13	99.95	0.0195

Frecuencia

Modelo	Configuración	A %	P %	R%	S %	BER
DT	<i>MinleafSize = 4</i> <i>Prune = On</i> <i>SplitCriterion = gdi</i>	98.93	99.51	98.34	99.51	0.0106
SVM	<i>KernelFunction = linear</i> <i>BoxConstraint = 2000</i>	97.34	100	94.68	100	0.0260
k-NN	<i>k = 2</i> <i>Distance = cosine</i>	98.26	98.34	98.18	98.35	0.0173

84 Características

Modelo	Configuración	A %	P %	R%	S %	BER
DT	<i>MinleafSize = 1</i> <i>Prune = On</i> <i>SplitCriterion = gdi</i>	100	100	100	100	0
SVM	<i>KernelFunction = linear</i> <i>BoxConstraint = 15</i>	99.95	99.95	99.95	99.95	0.0040
k-NN	<i>k = 13</i> <i>Distance = euclidean</i>	99.89	99.87	99.91	99.87	0.0010



3. Pruebas y Resultados Validación

Partición 70 - 30

Tiempo

Modelo	Configuración	A %	P %	R%	S %	BER
DT	<i>MinleafSize = 9</i> <i>Prune = On</i> <i>SplitCriterion = gdi</i>	99.43	99.54	99.32	99.54	0.0056
SVM	<i>KernelFunction = linear</i> <i>BoxConstraint = 40</i>	97.79	99.58	96.00	99.59	0.0220
k-NN	<i>k = 700</i> <i>Distance = cosine</i>	89.21	91.57	86.36	92.05	0.1078

Frecuencia

Modelo	Configuración	A %	P %	R%	S %	BER
DT	<i>MinleafSize = 4</i> <i>Prune = On</i> <i>SplitCriterion = gdi</i>	98.69	99.48	97.90	99.49	0.0130
SVM	<i>KernelFunction = linear</i> <i>BoxConstraint = 400</i>	96.52	99.94	93.10	99.94	0.0347
k-NN	<i>k = 3</i> <i>Distance = cosine</i>	98.25	99.64	96.85	99.65	0.0174

84 Características

Modelo	Configuración	A %	P %	R%	S %	BER
DT	<i>MinleafSize = 1</i> <i>Prune = On</i> <i>SplitCriterion = gdi</i>	99.95	99.91	100	99.91	0.0004
SVM	<i>KernelFunction = linear</i> <i>BoxConstraint = 50</i>	99.91	99.91	99.91	99.91	0.0080
k-NN	<i>k = 3</i> <i>Distance = euclidean</i>	99.87	99.81	99.94	99.81	0.0012

3. Pruebas y Resultados Validación

Partición 50 - 50

Tiempo

Modelo	Configuración	A %	P %	R%	S %	BER
DT	<i>MinleafSize = 6</i> <i>Prune = On</i> <i>SplitCriterion = gdi</i>	99.33	99.56	99.09	99.56	0.0066
SVM	<i>KernelFunction = linear</i> <i>BoxConstraint = 20</i>	97.27	99.64	94.89	99.66	0.0272
k-NN	<i>k = 200</i> <i>Distance = cosine</i>	93.05	96.00	89.84	96.26	0.0694

Frecuencia

Modelo	Configuración	A %	P %	R%	S %	BER
DT	<i>MinleafSize = 7</i> <i>Prune = On</i> <i>SplitCriterion = gdi</i>	98.29	99.63	96.94	99.64	0.0170
SVM	<i>KernelFunction = linear</i> <i>BoxConstraint = 500</i>	96.22	99.98	92.46	99.98	0.0377
k-NN	<i>k = 1</i> <i>Distance = cosine</i>	98.17	99.61	96.71	99.62	0.0182

84 Características

Modelo	Configuración	A %	P %	R%	S %	BER
DT	<i>MinleafSize = 1</i> <i>Prune = On</i> <i>SplitCriterion = gdi</i>	99.09	100	98.18	100	0.0090
SVM	<i>KernelFunction = linear</i> <i>BoxConstraint = 140</i>	99.91	99.98	99.85	99.98	0.0008
k-NN	<i>k = 3</i> <i>Distance = euclidean</i>	99.83	99.74	99.93	99.74	0.0016

3. Pruebas y Resultados Validación

Partición 20 - 80

Tiempo

Modelo	Configuración	A %	P %	R%	S %	BER
DT	<i>MinleafSize = 3</i> <i>Prune = On</i> <i>SplitCriterion = gdi</i>	99.14	99.55	98.73	99.55	0.0085
SVM	<i>KernelFunction = linear</i> <i>BoxConstraint = 1.5</i>	99.57	99.16	100	99.15	0.0042
<i>k-NN</i>	<i>k = 1</i> <i>Distance = cosine</i>	96.56	99.79	93.31	99.80	0.0343

Frecuencia

Modelo	Configuración	A %	P %	R%	S %	BER
DT	<i>MinleafSize = 1</i> <i>Prune = On</i> <i>SplitCriterion = gdi</i>	98.38	99.33	97.41	99.34	0.0171
SVM	<i>KernelFunction = linear</i> <i>BoxConstraint = 400</i>	95.41	99.97	90.85	99.97	0.0458
<i>k-NN</i>	<i>k = 1</i> <i>Distance = euclidean</i>	97.87	99.52	96.20	99.53	0.02128

84 Características

Modelo	Configuración	A %	P %	R%	S %	BER
DT	<i>MinleafSize = 1</i> <i>Prune = On</i> <i>SplitCriterion = gdi</i>	99.97	99.95	100	99.95	0.0002
SVM	<i>KernelFunction = linear</i> <i>BoxConstraint = 4</i>	99.82	99.74	99.90	99.74	0.0017
<i>k-NN</i>	<i>k = 5</i> <i>Distance = cosine</i>	99.75	99.59	99.90	99.59	0.0024

3. Pruebas y Resultados - Test

Test mejor modelo

El modelo DT en la partición 80 – 20 con la base de datos con las 84 características normalizadas con el método de mínimos y máximos obtuvo en todas las métricas de rendimiento el 100%, alcanzando así un BER de 0 en los datos de Validación

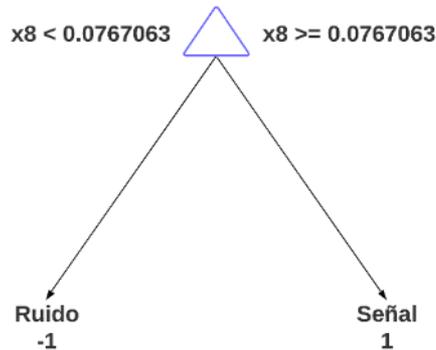


Fig. 22 *Árbol de decisión generado*

La característica que toma es la número 8 que corresponde al valor RMS en tiempo.

Se comprueba mediante el diagrama de cajas de la característica 8

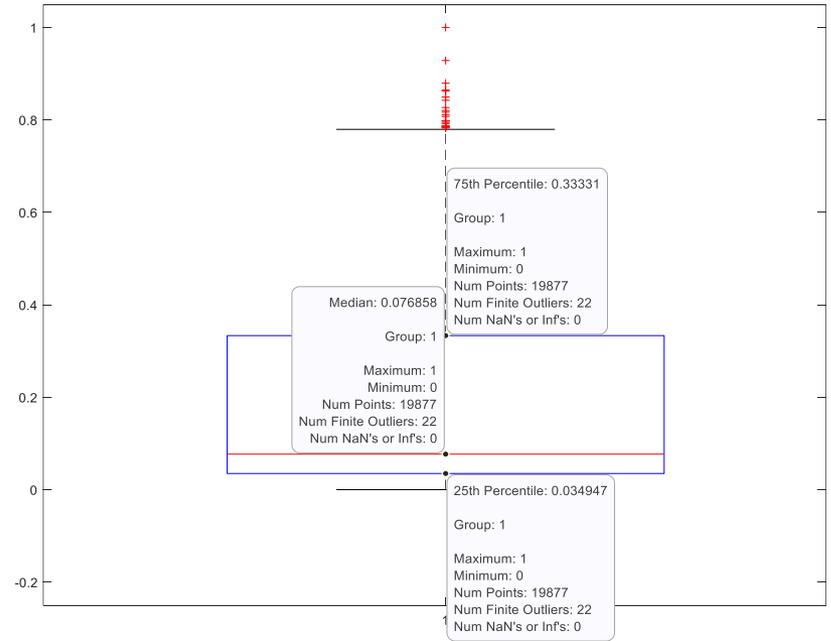


Fig. 23 *Diagrama de cajas*

3. Pruebas y Resultados - Test

Test mejor modelo

El modelo DT en la partición 80 – 20 con la base de datos con las 84 características normalizadas con el método de mínimos y máximos obtuvo en todas las métricas de rendimiento el 100%, alcanzando así un BER de 0 en los datos de Validación

Se prueba el modelo con un conjunto de 158 registros de 20 minutos de duración cada uno. Estos registros abarcan un total de 806 microsismos aleatorios entre LP, VT, TC, TR. La elección de este número de microsismos se debe a que representa el 20% del total de microsismos de la base de datos.

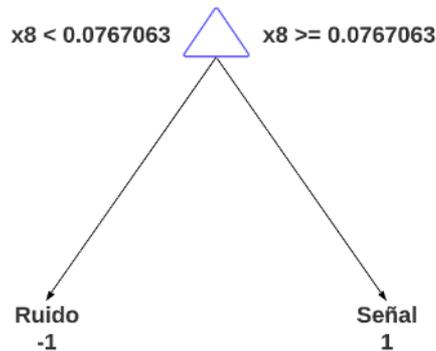


Fig. 22 Árbol de decisión generado

Clasificación

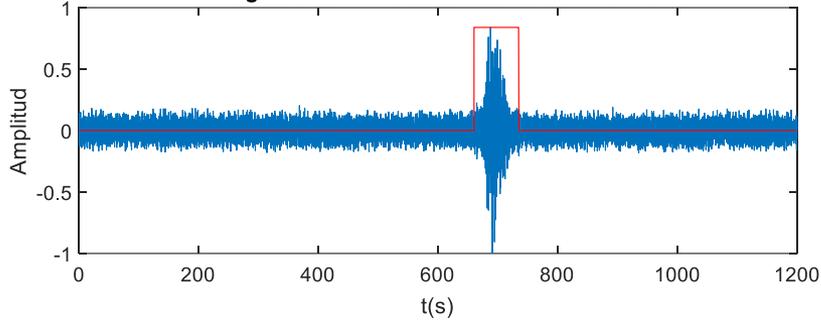
A %	P %	R %	S %	BER
97.41	92.73	93.97	98.23	0.038

La característica que toma es la número 8 que corresponde al valor RMS en tiempo.

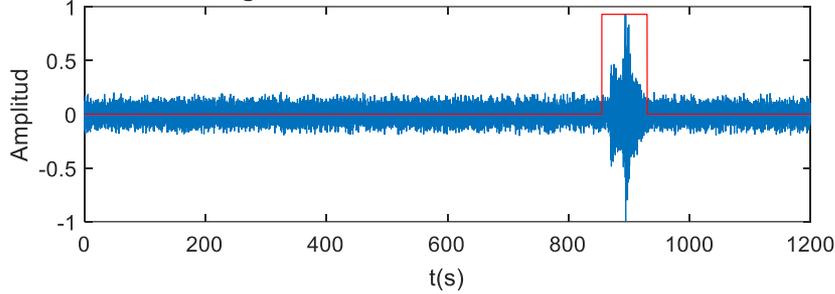
3. Pruebas y Resultados

Detección con 1 microsismo

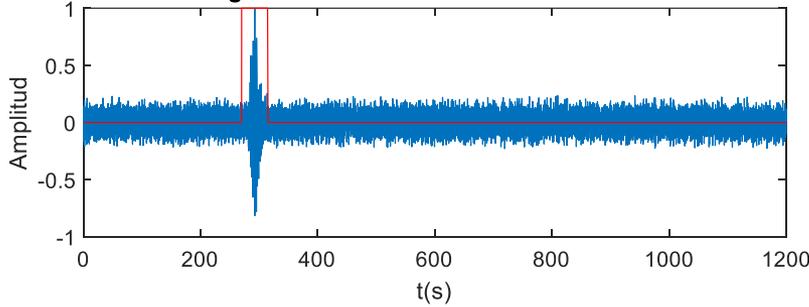
Registro con microsismos volcan Llaima



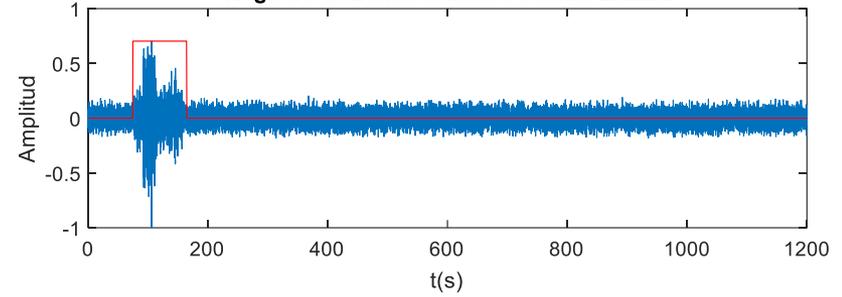
Registro con microsismos volcan Llaima



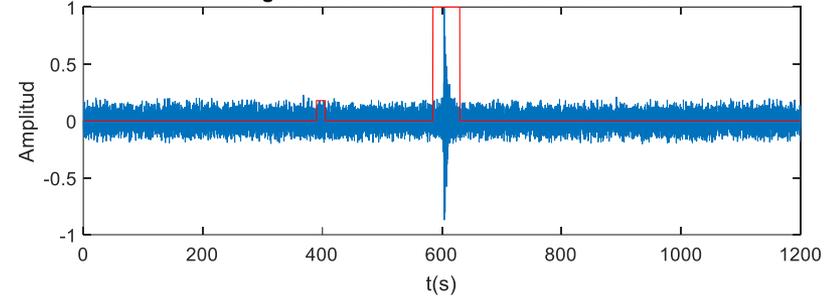
Registro con microsismos volcan Llaima



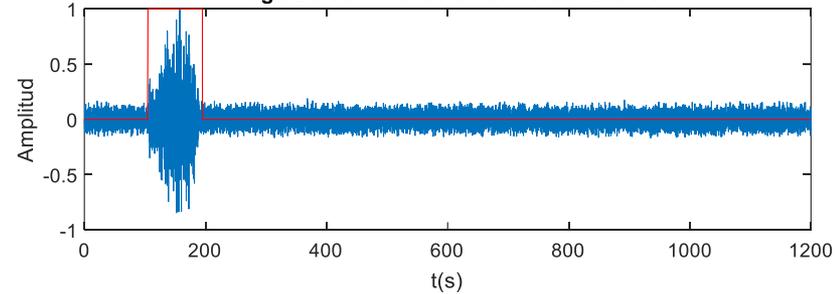
Registro con microsismos volcan Llaima



Registro con microsismos volcan Llaima

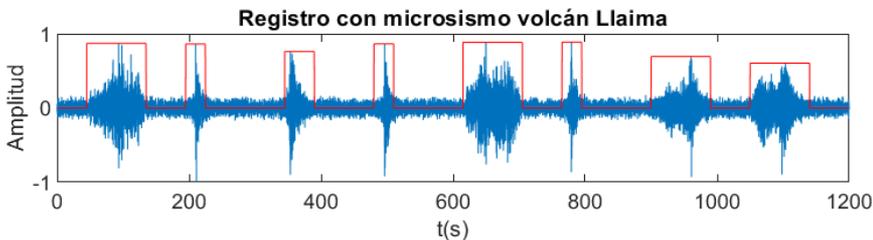
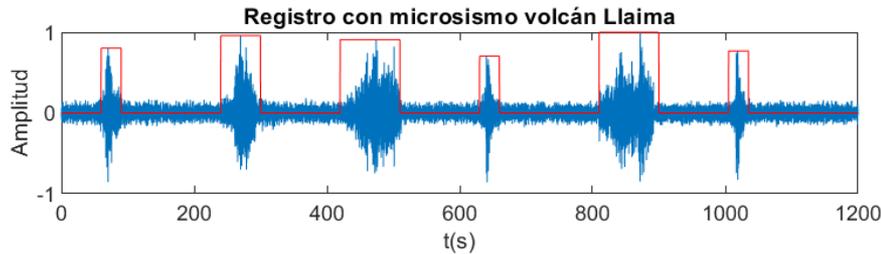
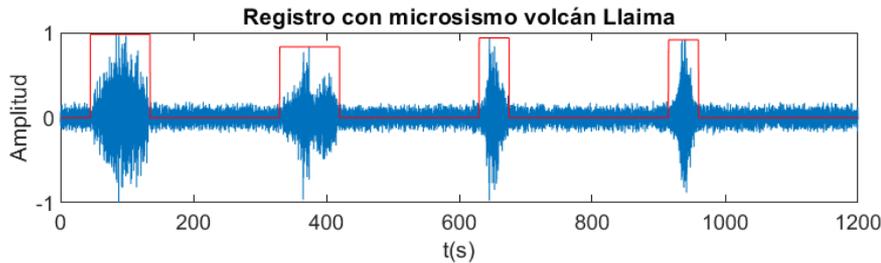
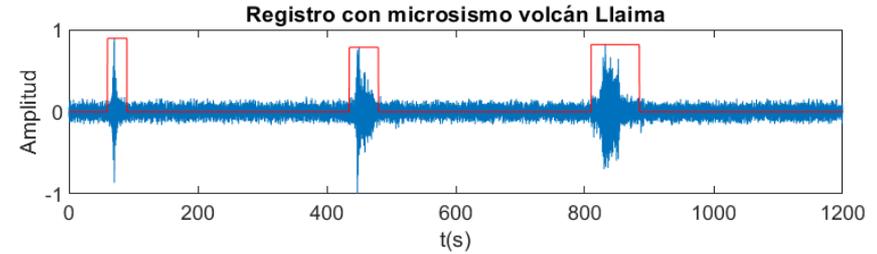
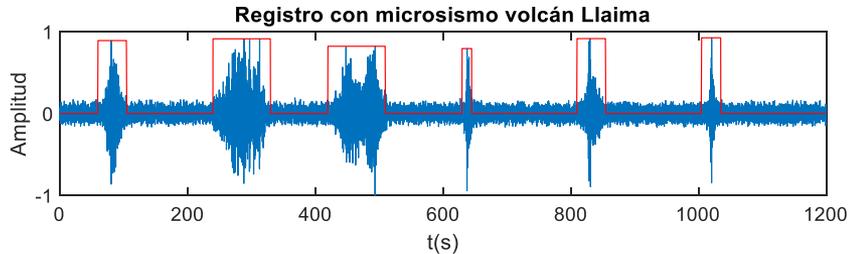


Registro con microsismos volcan Llaima

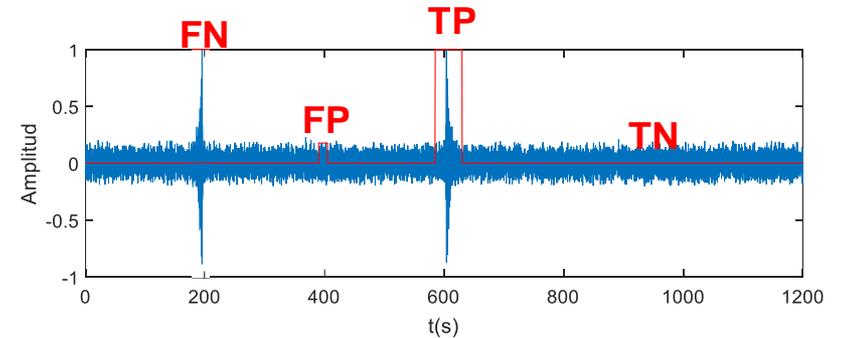


3. Pruebas y Resultados - Test

Detección con múltiples microsismos aleatorios

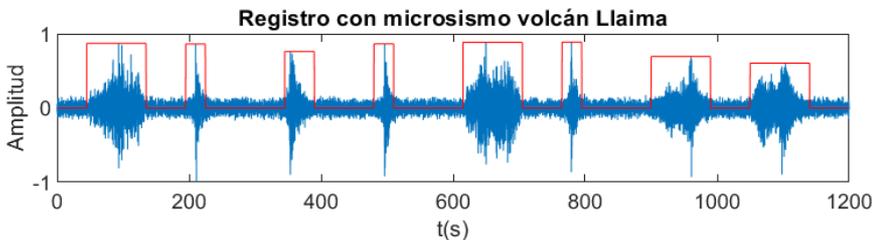
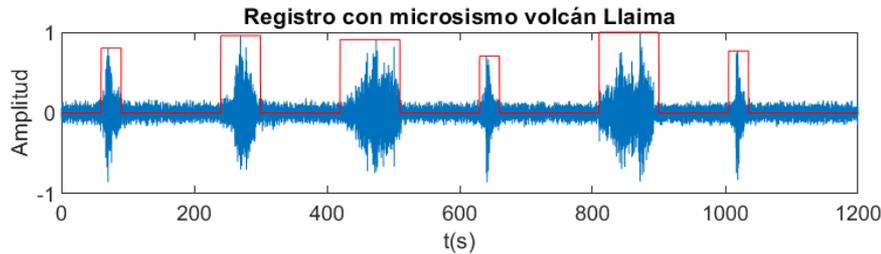
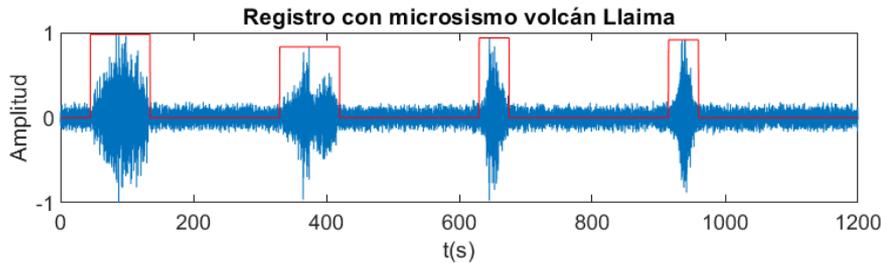
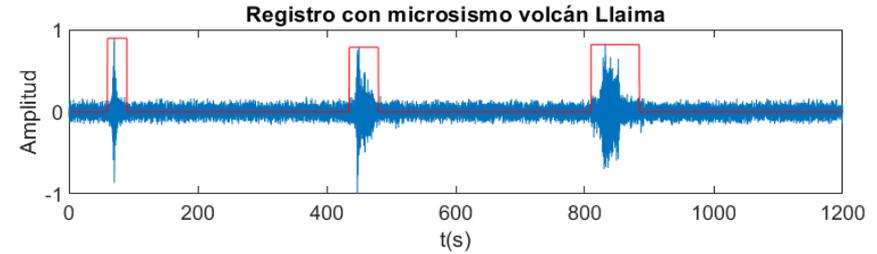
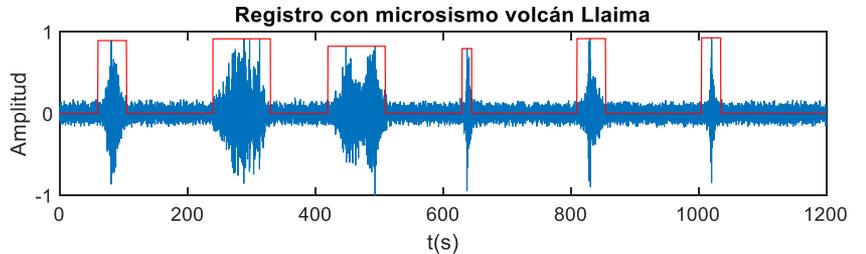


Análisis de señales



3. Pruebas y Resultados - Test

Detección con múltiples microsismos aleatorios



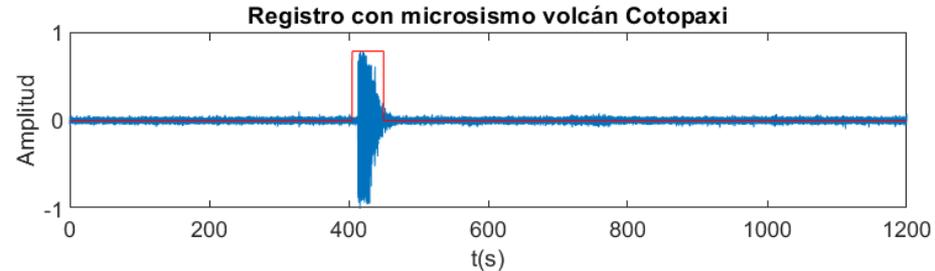
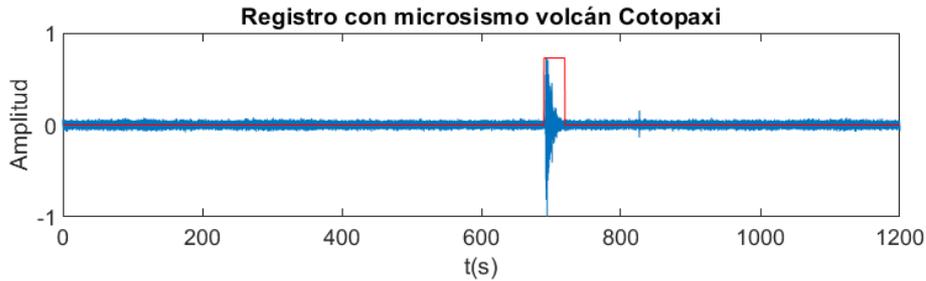
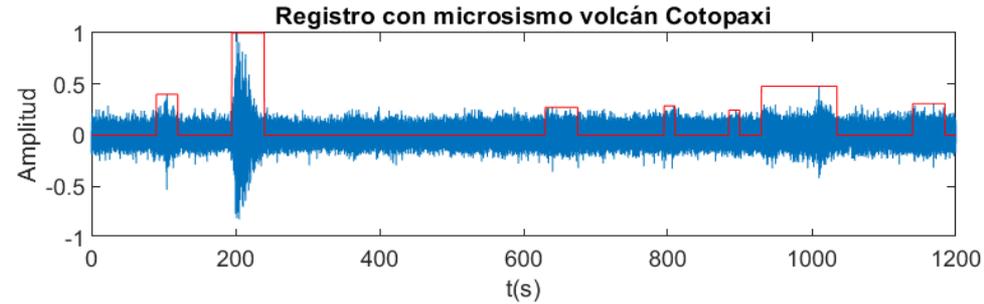
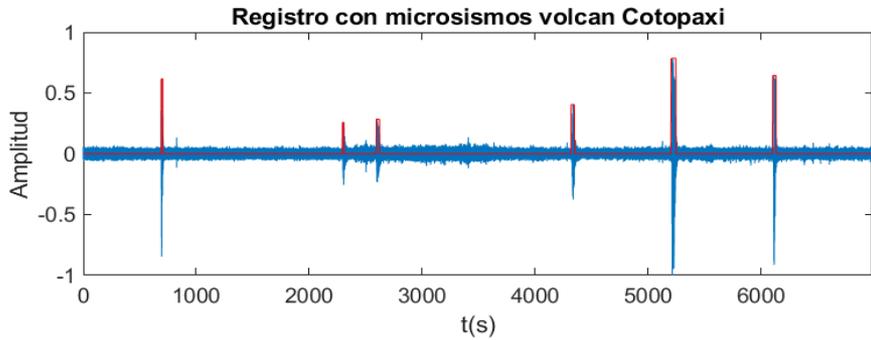
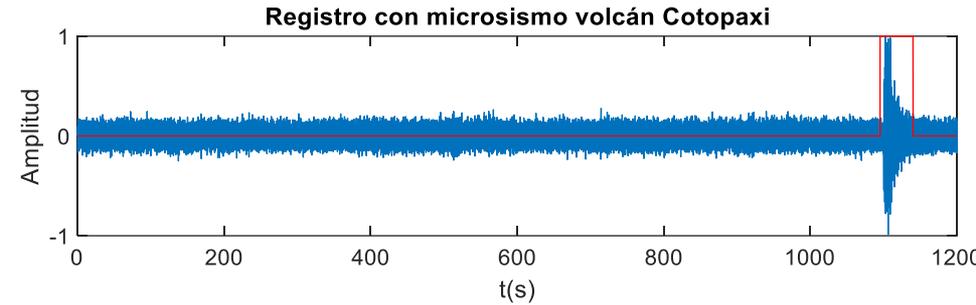
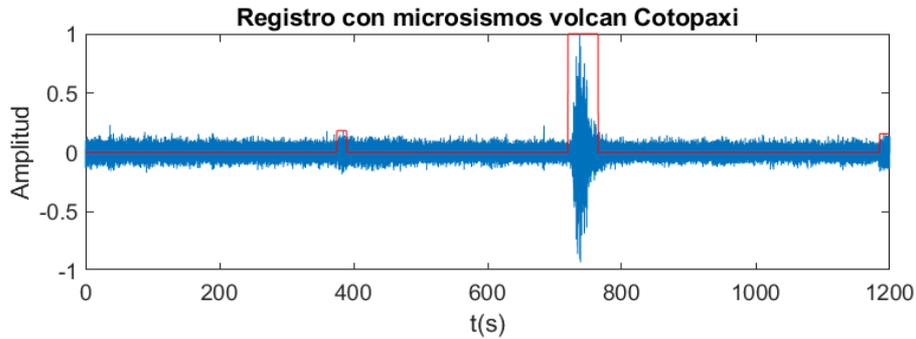
Detección

A %	P %	R%	S %	BER
99.66	99.26	99.26	99.37	0.006



3. Pruebas y Resultados - Test

Detección con microsismos volcán Cotopaxi



4. Conclusiones

- Se ha logrado crear un algoritmo basado en la teoría de ML tradicional para detectar eventos sísmicos del volcán Llaima. Este modelo no solo se ha ajustado a las exigencias de rendimiento establecidas por instituciones encargadas de la vigilancia volcánica, sino que ha superado dichos requisitos al alcanzar un BER inferior a 0.01.
- La normalización de la base de datos de las 84 características fue una etapa importante previo al entrenamiento de los modelos de ML, esto permite evitar que el modelo se concentre solo en características específicas debido a sus valores en amplitud significativamente altos o bajos, lo que impide que exista un sobre entrenamiento y los resultados obtenidos sean generalizables a nuevos datos
- En la fase de clasificación el modelo obtuvo en A (%) 97.41 y BER 0.038, sin embargo, en la etapa de detección el modelo alcanza en A (%) 99.66 y BER un 0.006 respectivamente, donde a través del BER se indica que el modelo no puede detectar 6 de cada 1000 microsismos.



4. Conclusiones

- Se eligió 3dB como valor mínimo de SNR para etiquetar los registros segmentados, debido a que este valor permitía una distinción adecuada entre ventanas de ruido y microsismo. Para valores inferiores a 3dB ventanas de ruido eran etiquetadas como señal.
- Es posible detectar hasta 8 microsismos como máximo en un registro de 20 minutos, al exceder esta cantidad, el algoritmo detecta 2 microsismos como si fuera 1, hasta el punto en que todo el registro se identifica como una única señal debido a la proximidad entre los microsismos.
- Debido a que el modelo se ha entrenado únicamente con microsismos del volcán Llaima, esto lo convierte en un modelo exclusivo para este volcán, por este motivo se evidencian deficiencias al intentar detectar microsismos provenientes de otros volcanes, como el Cotopaxi. Aunque en ocasiones logra detectar correctamente algunos registros que se componen de 1 o varios microsismos, en otros casos confunde el ruido como si fuera una señal válida.



4. Trabajos Futuros

- Nuestro grupo de investigación plantea investigar como el ruido afecta a nuestro detector cuando la SNR es distinta de 3dB.
- Se propone modificar parámetros adicionales a cada uno de los modelos propuestos como “Maxnumsplit” en DT, nuevas funciones del kernel en SVM o nuevas distancias en k -NN como minkowski, Manhattan entre otros, con el objetivo de investigar la posibilidad de lograr mejoras en los resultados obtenidos en la generalización del modelo a nuevos microsismos provenientes de otros volcanes.
- El presente trabajo de titulación emplea las 84 características para entrenar los modelos de ML, por lo cual se propone realizar un estudio que incorpore técnicas de reducción de características, como la Eliminación Recursiva de Características (RFE, por sus siglas en inglés Recursive Feature Elimination), con el fin de mejorar las métricas en clasificación de los modelos de ML.



GRACIAS



ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA



ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

DEPARTAMENTO DE ELÉCTRICA, ELECTRÓNICA Y TELECOMUNICACIONES CARRERA EN TELECOMUNICACIONES

“Creación de algoritmos inteligentes basados en la teoría de Machine Learning tradicional para la detección de los eventos sísmicos en el volcán Llaima”

Autor: Castillo Tipantuña, Edwin Alexander

Director del Proyecto: Ing. Román Alcides Lara Cueva, PhD.

06 de septiembre de 2023

