



# ESPE

UNIVERSIDAD DE LAS FUERZAS ARMADAS  
INNOVACIÓN PARA LA EXCELENCIA

Sistema de Reconocimiento Automático de Micro sismos Volcánicos basado en Redes  
Neuronales Convolucionales

Lara Mina, Marco Fernando

Vicerrectorado de Investigación, Innovación y Transferencia de Tecnología  
Centro de Posgrados

Maestría de Investigación en Electrónica

Trabajo de titulación, previo a la obtención del título de Magíster en Investigación Electrónica,  
mención Telecomunicaciones

Msc. León Vásquez, Rubén Darío

29 de septiembre de 2021

## Reporte Urkund



### Document Information

---

<b>Analyzed document</b>	TesisLara_Urkund.docx (D111414639)
<b>Submitted</b>	8/18/2021 11:31:00 AM
<b>Submitted by</b>	León Vásquez Rubén Darío
<b>Submitter email</b>	rdleon@espe.edu.ec
<b>Similarity</b>	0%
<b>Analysis address</b>	rdleon.espe@analysis.orkund.com

### Sources included in the report

---

<b>SA</b>	<b>Universidad de las Fuerzas Armadas ESPE / Trabajo_Titulacion_Aguinaga_Diana_VF.docx</b>	 <b>1</b>
	Document Trabajo_Titulacion_Aguinaga_Diana_VF.docx (D44056162)	
	Submitted by: dsaguinaga@espe.edu.ec Receiver: ralara.espe@analysis.orkund.com	
<b>SA</b>	<b>Universidad de las Fuerzas Armadas ESPE / Trabajo_Titulacion_Rosero_Jacome_Karen.pdf</b>	 <b>1</b>
	Document Trabajo_Titulacion_Rosero_Jacome_Karen.pdf (D61393392)	
	Submitted by: jclarco@espe.edu.ec Receiver: jclarco.espe@analysis.orkund.com	

---

Msc. Rubén Darío León Vásquez.

Director

C.C.: 1801654284



# ESPE

UNIVERSIDAD DE LAS FUERZAS ARMADAS  
INNOVACIÓN PARA LA EXCELENCIA

VICERRECTORADO DE INVESTIGACIÓN, INNOVACIÓN Y TRANSFERENCIA DE  
TECNOLOGÍA  
CENTRO DE POSGRADOS

## CERTIFICACIÓN

Certifico que el trabajo de titulación, **Sistema de Reconocimiento Automático de Microsismos Volcánicos basado en Redes Neuronales Convolucionales** fue realizado por el señor **Lara Mina, Marco Fernando** el mismo que ha sido revisado y analizado en su totalidad, por la herramienta de verificación de similitud de contenido; por lo tanto, cumple con los requisitos legales, teóricos, científicos, técnicos y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, razón por la cual, me permito acreditar y autorizar para que lo sustente públicamente.

Sangolquí, 29 de septiembre de 2021

Firma:

---

Msc. Rubén Darío León Vásquez.

Director

C.C.: 1801654284



**ESPE**  
UNIVERSIDAD DE LAS FUERZAS ARMADAS  
INNOVACIÓN PARA LA EXCELENCIA

**VICERRECTORADO DE INVESTIGACIÓN, INNOVACIÓN Y TRANSFERENCIA DE  
TECNOLOGÍA  
CENTRO DE POSGRADOS**

**RESPONSABILIDAD DE AUTORÍA**

Yo **Lara Mina, Marco Fernando**, con cédula de ciudadanía n° **1715140115**, declaro que el contenido, ideas y criterios del trabajo de titulación: **Sistema de Reconocimiento Automático de Micro sismos Volcánicos basado en Redes Neuronales Convolucionales** 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, 29 de septiembre de 2021

Firma:

Marco Fernando Lara Mina

C.C.: 1715140115



VICERRECTORADO DE INVESTIGACIÓN, INNOVACIÓN Y TRANSFERENCIA DE  
TECNOLOGÍA  
CENTRO DE POSGRADOS

AUTORIZACIÓN DE PUBLICACIÓN

Yo **Lara Mina, Marco Fernando**, con cédula de ciudadanía n° 1715140115, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: Título: **Sistema de Reconocimiento Automático de Micro sismos Volcánicos basado en Redes Neuronales Convolucionales** en el Repositorio Institucional, cuyo contenido, ideas y criterios son de mi responsabilidad.

Sangolquí, 29 de septiembre de 2021

Firma:



Marco Fernando Lara Mina

C.C.: 1715140115

## ÍNDICE GENERAL

Resumen . . . . .	11
Abstract . . . . .	12
Introducción . . . . .	13
Antecedentes . . . . .	13
Objetivos . . . . .	14
Metodología . . . . .	15
Fundamento Teórico . . . . .	16
Microsismos volcánicos . . . . .	16
Representación Tiempo-Frecuencia . . . . .	20
Redes Neuronales Convoluciones . . . . .	21
Estado del Arte . . . . .	24
Propuesta . . . . .	25
Preprocesamiento . . . . .	28
Deconvolución Homomórfica . . . . .	28
Estimación SNR . . . . .	33
Análisis en Frecuencia . . . . .	36
Filtro Digital . . . . .	39
Detección . . . . .	40
Modificación STA/LTA . . . . .	40
Evaluación . . . . .	45
Detección con CNN . . . . .	46
Transferencia de Aprendizaje . . . . .	46
Espectrograma . . . . .	47
Evaluación . . . . .	50
Clasificación . . . . .	56
Análisis en Frecuencia . . . . .	56

Generación de Espectrogramas . . . . .	61
Evaluación . . . . .	64
Evaluación Múltiples Etiquetas . . . . .	67
Software . . . . .	70
Funciones. . . . .	70
Interfaz . . . . .	71
Conclusiones . . . . .	74
Recomendaciones . . . . .	76
Referencias . . . . .	77

## ÍNDICE DE TABLAS

2.1	Clasificación de Microsismos volcánicos . . . . .	19
4.1	Métrica de detección STA/LTA de $g(r[n]) = RMS E(\hat{s}[n])$ . . . . .	46
4.2	Métrica de detección C2N . . . . .	53
5.1	Análisis en frecuencia por tipos de microsismo Volcán Cotopaxi . . . . .	59
5.2	Análisis en frecuencia por tipos de microsismo Volcán Llaima . . . . .	60
5.3	Análisis en frecuencia por tipos de microsismo . . . . .	61
5.4	Métrica de clasificación C2N . . . . .	67

## ÍNDICE DE FIGURAS

1.1 Posición Volcán Cotopaxi en Ecuador . . . . .	13
2.1 Señal de evento LP . . . . .	17
2.2 Señal de evento VT . . . . .	17
2.3 Señal de evento Híbrido . . . . .	18
2.4 Señal de evento Icequake . . . . .	19
2.5 Espectrograma de evento sísmico . . . . .	21
2.6 Estructura básica CNN . . . . .	22
2.7 Ejemplo de Convolución . . . . .	23
2.8 Diagrama de Bloques Sistema de Reconocimiento . . . . .	26
3.1 Diagrama de Bloques Deconvolución Homomórfica . . . . .	31
3.2 Resultado del procesamiento homomórfico aplicado a un registro. (Ejemplo 1). . . . .	32
3.3 Resultado del procesamiento homomórfico aplicado a un registro. (Ejemplo 2). . . . .	33
3.4 Comparación SNR . . . . .	35
3.5 Análisis de Frecuencia LP . . . . .	38
3.6 Análisis de Frecuencia VT . . . . .	38
3.7 Análisis de Frecuencia Tremor . . . . .	39
4.1 Funciones $g(x)$ clásicas . . . . .	41
4.2 Función $g(x)$ propuesta . . . . .	42
4.3 RMSE señal sísmica . . . . .	43
4.4 RMSE señal sísmica estimada . . . . .	43
4.5 Ejemplo de detección con RMSE y señal estimada . . . . .	44
4.6 Espectrograma ventana No Evento . . . . .	48

4.7	Espectrograma ventana Evento . . . . .	49
4.8	Espectrograma ventana No Evento (Deconvolución) . . . . .	49
4.9	Espectrograma ventana Evento (Deconvolución) . . . . .	50
4.10	Capas GoogLeNet . . . . .	51
4.11	Capas GoogLeNet Modificado . . . . .	51
4.12	Matriz de confusión 1 . . . . .	52
4.13	Matriz de confusión 2 . . . . .	52
4.14	Histograma duración microsismos volcánicos . . . . .	54
5.1	Componentes principales en frecuencia (Cotopaxi) . . . . .	58
5.2	Componentes principales en frecuencia (Llaima) . . . . .	59
5.3	Análisis ventanas Blackman - Flat Top . . . . .	62
5.4	Periodograma microsismo LP . . . . .	62
5.5	Periodograma microsismo VT . . . . .	63
5.6	Espectrograma microsismo LP . . . . .	63
5.7	Espectrograma microsismo VT . . . . .	64
5.8	Entrenamiento SqueezeNet . . . . .	65
5.9	Matriz de confusión balanceado . . . . .	66
5.10	Matriz de confusión No balanceado . . . . .	66
5.11	Matriz de confusión No balanceado (Prueba Balanceada) . . . . .	66
5.12	Matriz de confusión No balanceado Volcán Llaima . . . . .	68
6.1	Pantalla principal Software <i>Ariq Kuyuy</i> . . . . .	71
6.2	Pantalla de Verificación <i>Ariq Kuyuy</i> . . . . .	72
6.3	Pantalla de Operación <i>Ariq Kuyuy</i> . . . . .	72
6.4	Pantalla de Registro <i>Ariq Kuyuy</i> . . . . .	73

## RESUMEN

En este trabajo se propone el desarrollo de un sistema de reconocimiento automático de señales sísmicas que consta de tres etapas: pre procesamiento, detección y clasificación.

En la etapa de pre procesamiento se propone considerar el trayecto o canal de propagación como un sistema lineal e invariante con el tiempo para estimar la señal sísmica producida en el punto de origen del sismo, reduciendo las perturbaciones provocadas por el canal.

En la etapa de detección se propone dos técnicas: una modificación del algoritmo STA/LTA (detector MarGra) y también se propone un segundo detector basado en redes neuronales convolucionales (detector C2N), los dos sistemas cumplen con las métricas establecidas por el Instituto Geofísico de la Escuela Politécnica Nacional (IGEPN).

En la tercera etapa, se propone la clasificación de eventos utilizando redes neuronales convolucionales. Para entrenar la redes neuronales se propone el uso de espectrogramas, y para superar el problema de un conjunto de datos limitados, se utiliza la técnica de transferencia de aprendizaje; para generar los espectrogramas se realiza un análisis de las bandas de frecuencia de cada tipo evento sísmico para resaltar las bandas de frecuencia que diferencia a los distintos tipos de eventos con funciones de ventana distintas.

Finalmente, se evalúa el sistema propuesto con distintas bases de datos previamente analizadas por expertos, consiguiendo una mejora en la relación señal a ruido de 10dB, una probabilidad de detección de 99 % para los dos detectores propuestos, y una exactitud en clasificación de 97.5 % entre eventos de largo periodo y eventos volcánico tectónicos.

### **Palabras Claves:**

- DECONVOLUCIÓN HOMOMÓRFICA**
- REDES NEURONALES CONVOLUCIONALES**
- MICROSISMOS VOLCÁNICOS**

## ABSTRACT

In this work, the automatic recognition system design of seismic signal is proposed, this system have three stages: pre processing, detection and classification.

In the pre processing stage, it is proposed to consider the path or channel of propagation of the microearthquake as a convolutional channel to recover the seismic signal produced at the source or point of origin of the microearthquake, reducing the disturbances caused by the channel or path that the signal travels. seismic, improving the signal to noise ratio.

In the detection stage, two techniques are proposed: a modification of the STA / LTA algorithm (MarGra detector) and a second detector based on convolutional neural networks (C2N detector) is also proposed, the two systems satisfy the metrics established by the *Instituto Geofísico de la Escuela Politécnica Nacional (IGEPN)*.

In the classification stage, the classification of events using convolutional neural networks is proposed, to train the neural networks, spectrograms are used, and to overcome the problem of a limited data set, the transfer learning technique is implemented; To generate the spectrograms, an analysis of the frequency bands of each type of seismic event is carried out to highlight the frequency bands that differentiate the different types of events with different window functions.

Finally, the proposed system is evaluated with different databases previously analyzed by experts, achieving an improvement in the signal to noise ratio of 10dB in pre processing stage, a detection probability of 99 % for the two proposed detectors, and a classification accuracy of 97.5 % between long period events and volcano tectonic events.

### **Keywords:**

- HOMOMORPHIC DECONVOLUTION**
- CONVOLUTIONAL NEURAL NETWORKS**
- MICROEARTHQUAKES**

## Introducción

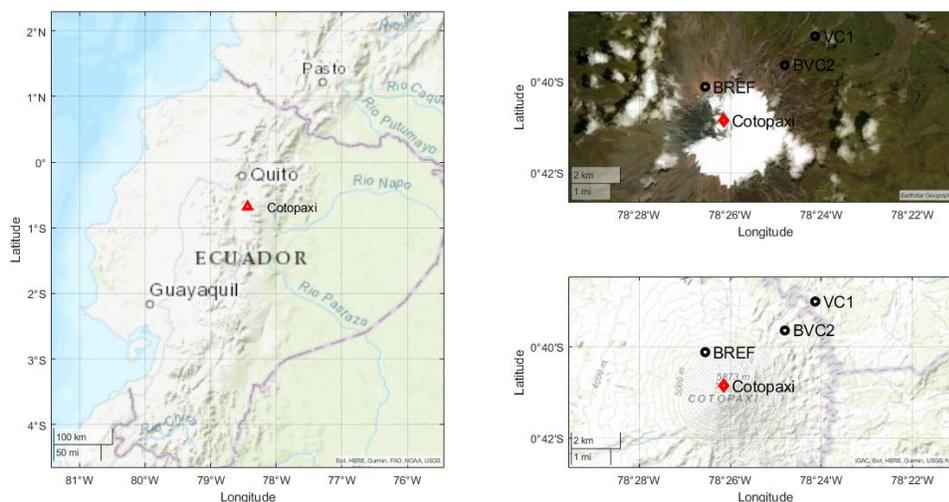
### Antecedentes

El Ecuador es un país caracterizado por la presencia de la cordillera de los Andes, la cual, atraviesa la sierra del país, lo que hace del Ecuador, un país con un alto riesgo volcánico; en los últimos 500 años, 9 de sus volcanes han tenido un proceso eruptivo [1], de los cuales 4 han ocurrido desde 1999 [2] y se considera que existen alrededor de 30 volcanes [1] activos.

La cordillera de los Andes puede dividirse en cordillera oriental y occidental, y en medio se encuentra el valle interandino [2], lo que, incrementa los potenciales daños en caso de erupción. Uno de los volcanes activos que presentan mayor riesgo, es el Volcán Cotopaxi, ubicado en la cordillera oriental, localizado en Latacunga, el cual podría afectar a 300000 personas a causa de sus lahares [3], el último proceso eruptivo del Volcán Cotopaxi se registró en 1877 [4]; la Fig. 1.1 muestra la ubicación del Volcán Cotopaxi.

**Figura 1.1**

*Posición Volcán Cotopaxi en Ecuador y posición de sensores sísmicos*



Es por esto que, monitorizar la actividad volcánica es una tarea de gran interés en el

mundo, actualmente un tercio de los volcanes del mundo se encuentran en monitorización constante [5]. El Volcán Cotopaxi se encuentra bajo monitorización desde el año 1976 [6], se registra la actividad sísmica, niveles de dióxido de sulfuro ( $SO_2$ ), registro de emisión de gases, anomalías térmicas, entre otros [7].

La actividad sismo volcánica ha sido ampliamente estudiada, y ha permitido conocer la relación de los volcanes con su entorno [5]. Existen algunos estudios que muestran que existe un incremento de la actividad sísmica antes de un proceso eruptivo [8], por lo que, los sistemas de reconocimiento automáticos de eventos sismo volcánicos tienen gran importancia para incrementar el conocimiento de los volcanes y para acelerar la toma de decisiones de los organismos responsables ante eventuales erupciones. Es importante mencionar que los sistemas volcánicos son complejos, por lo cual, el procesamiento de señales sísmicas, solo es parte de los muchos sistemas utilizados para tratar de entender la actividad volcánica.

## **Objetivos**

### **Objetivo General**

- Desarrollar un sistema de reconocimiento de microsismos de baja energía basado en redes neuronales convolucionales.

### **Objetivos Específicos**

- Estimar la señal de la fuente sísmica, para reducir el ruido presente en las señales adquiridas por el sensor sísmico.
- Utilizar representación en tiempo-frecuencia de señales sísmicas que resalten la presencia de eventos sísmicos, y entrenar las redes neuronales convolucionales con estas representaciones.
- Implementar el concepto de transferencia de aprendizaje para entrenar las redes neuronales convolucionales con un conjunto de datos limitado, permitiendo superar el problema de conjunto de datos reducidos.

- Evaluar el desempeño del sistema propuesto midiendo su exactitud, precisión, sensibilidad, especificidad y tasa de evento balanceada y comparar los nuevos resultados con anteriores propuestas.

## **Metodología**

En el presente trabajo se plantea desarrollar un sistema de reconocimiento de microsismos basado en redes neuronales convolucionales, en una primera instancia se realizará un breve estudio del conjunto de datos a utilizar, el cual consta de 1187 registros sísmicos del Volcán Cotopaxi [9], en una segunda instancia se propone mejorar la relación señal a ruido a través de la estimación de la señal sísmica en su punto de origen, considerando la ruta de propagación como un canal convolucional, finalmente, se propone utilizar la representación tiempo-frecuencia de las señales sísmicas para transferir conocimiento a redes convolucionales de alta complejidad para el reconocimiento de las señales.

En el siguiente capítulo se dará una descripción de los elementos teóricos más importantes discutidos en este trabajo: una descripción de los principales eventos sismo volcánicos, principio del espectrograma y una descripción de las redes neuronales convoluciones.

## Fundamento Teórico

### Microsismos volcánicos

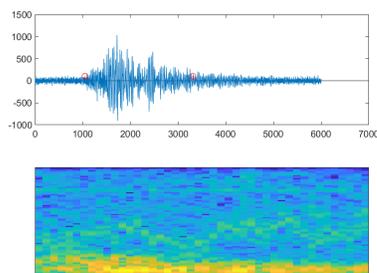
Los sismos pueden dar valiosa información de los procesos internos de los volcanes y de la interacción de los volcanes con su entorno, tradicionalmente se pueden clasificar los microsismos como: LP (del inglés, *Long Period*), VT (del inglés, *Volcano Tectonic*), Híbridos, Tremores, Explosiones y *Icequake* o rupturas de hielo.

### Long Period

Los eventos LP se producen por procesos de presurización, como la formación de burbujas de magma y su posterior colapso o movimientos de magma a través de conductos [5], a pesar de que cada volcán presenta características únicas, el rango de frecuencia más común para eventos LP es  $1 - 2Hz$  [10], existen registros entre  $1 - 5Hz$  [5] y tienen una duración típica entre 5 segundos y 40 segundos [10]. Una variación de los eventos LP, presentando una mayor duración, ocasionados por deslizamientos [10], se conocen como LP de larga duración. En la Fig. 2.1, se presenta un ejemplo de un evento LP, en la sección superior la señal en tiempo y en la sección inferior de la imagen su representación en tiempo-frecuencia, la señal se encuentra muestreada a  $100Hz$ , el evento de la Fig. 2.1, tiene una duración de 22,5 segundos (2250 muestras), mientras que, en el espectrograma se nota que no se tienen componentes en altas frecuencias.

Existen varios trabajos, que presentan la existencia de un fuerte incremento en el número de eventos LP antes de una erupción [11], [12], esto permitiría tener sistemas de alerta temprana más efectivos y permitir a las entidades gubernamentales encargadas tomar decisiones en un menor tiempo.

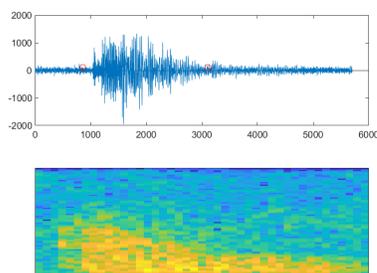
**Figura 2.1**  
Ejemplo señal evento LP



## Volcano Tectonic

Los eventos VT también son conocidos como eventos de alta frecuencia, presentan frecuencias entre 5 y 15Hz [5], los eventos VT son ocasionados principalmente por fallas de cizallamiento (tensión de corte) o por colapsos en estructuras internas [5], [13]. Existen algunos indicios de que los eventos VT son precursores de erupciones, aunque no se ha encontrado relaciones fuertes de esta premisa [14], es por esto, que para validar las hipótesis de procesos pre eruptivos se requiere monitorización y sistemas de reconocimiento automático, para extraer la mayor cantidad de información posible de los registros sísmicos pasados, actuales y futuros. Un ejemplo de señal de evento VT es presentado en la Fig. 2.2, la señal de ejemplo tiene una duración de 22 segundos (2100 muestras, inicio muestra 900, fin muestra 3100); en cuanto al espectrograma se puede notar que tiene componentes en alta frecuencia y que durante el tiempo reducen su valor máximo de frecuencia.

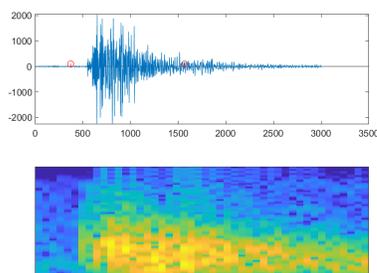
**Figura 2.2**  
Ejemplo señal evento VT



## Híbridos

Ocurren cuando se dan eventos conjuntos LP y VT, o por el colapso de cavidades de fluidos (magma) [5]. En la Fig. 2.3, se presenta una muestra de señal de un evento híbrido, este evento tiene una duración de 12 segundos (1200 muestras).

**Figura 2.3**  
*Ejemplo señal evento Híbrido*



## Tremores

Son eventos de larga duración, son eventos LP ocurriendo de forma continua o en otro caso son eventos VT sucesivos [5].

## Explosiones

Microsismos que acompañan a las erupciones, como resultado de la energía liberada viaja por la tierra y aire [5]. Presentan componentes en frecuencia entre 1y 5Hz, se diferencian de los LP por la presencia de un señal de choque de aire en el registro sísmico [15].

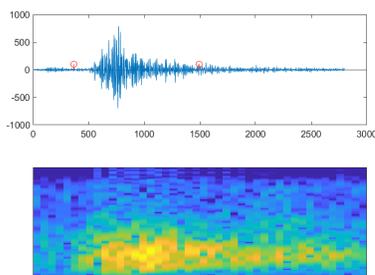
## Regional

Son eventos sísmicos, que tiene su origen fuera de las edificaciones volcánicas, puede ser originados en placas tectónicas [16].

## Icequake

Micros sismos generados en zonas superficiales a causa de fracturas de hielo [17], presentan contenido espectral similar a eventos LP, aunque se diferencian por tener componentes hasta los  $10\text{Hz}$  [17]. Un ejemplo de registro Icequake del Volcán Cotopaxi se presenta en la Fig. 2.4, esta señal de ejemplo tiene una duración de 12,5 segundos.

**Figura 2.4**  
*Ejemplo señal evento Icequake*



En la Tabla 2.1, se presenta un resumen de la clasificación de los principales eventos sísmicos.

**Tabla 2.1**  
*Clasificación de Microsismos volcánicos*

Evento Sísmico	Frecuencia	Duración	Origen
VT	$5 - 15\text{Hz}$	corta	Deslizamientos y rupturas
LP	$1 - 5\text{Hz}$	corta	Presurización fluidos
Tremor	$2 - 3\text{Hz}$	larga	Eventos LP o VT concatenados
Híbrido	$2 - 15\text{Hz}$	corta	Eventos conjuntos
Explosiones	$1 - 5\text{Hz}$	corta	Durante erupción
Icequake	$1 - 10\text{Hz}$	corta	Causados por rupturas de glaciales

El presente trabajo, se basa en señales adquiridas en el Volcán Cotopaxi ubicado a  $60\text{km}$  de la ciudad de Quito, Ecuador en las coordenadas (latitud  $0^{\circ}41'05''\text{S}$  y longitud  $78^{\circ}25'54,8''\text{W}$ ), la principal base de datos utilizada contiene un registro de 1187 eventos [9], de tres estaciones (VC1 - Short Period seismological station, BVC2 - Broadband seis-

mological station 2 y BREF- Broadband reference seismological station) [18], la ubicación de estas tres estaciones se presenta en la Fig. 1.1. Los eventos registrados se encuentran etiquetados y clasificados, los eventos registrados presentan la siguiente distribución: LP (1044), VT (101), Regionales (27), Híbridos (8) y Icequake (7) [9].

### Representación Tiempo-Frecuencia

Un señal registrada en el tiempo puede ser representada por sus características en frecuencia, a través de la transformada de Fourier o un proceso de estimación espectral.

A partir de lo antes mencionado, podemos tener una representación bidimensional, representando la señal en tiempo y su característica en frecuencia, para esto, se procesa la señal en ventanas de tiempo  $x_c(t_i)$ , y se calcula  $X_C(t_i, \Omega)$ , para un rango limitado de valores de  $(t_i, \Omega)$  [19], para sistemas discretos la transformación  $x_c[n] \rightarrow X_c[k]$ , se realiza con la Transforma Discreta de Fourier (DFT, del inglés *Discrete Fourier Transform*), a través del algoritmo Transformada Rápida de Fourier (FFT, del inglés *Fast Fourier Transform*) dado en la Ec. (2.1) [20].

$$X_c[k] = \sum_{n=0}^{N-1} x[n] \exp(-j2\pi kn/N) \quad (2.1)$$

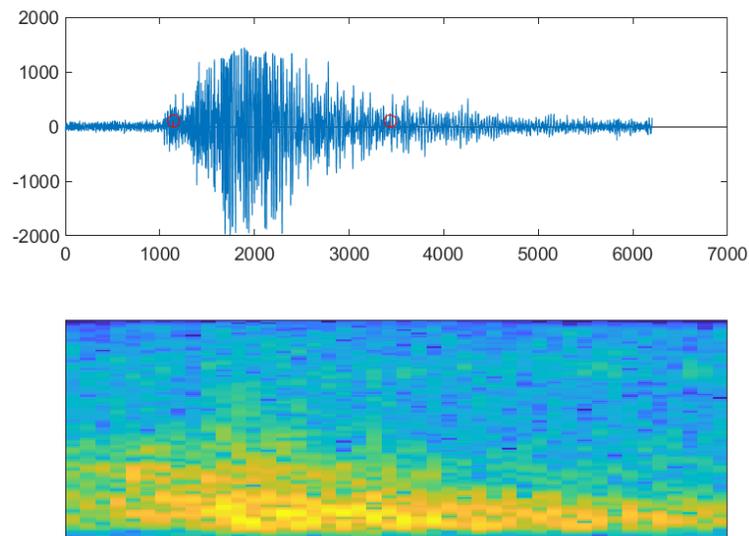
donde,  $N$  es el número total de muestras.

De cada ventana  $x_c$  se obtiene el logaritmo de la magnitud dada por la Ec. (2.2) [19].

$$|X_c[k]| = \log \left( \sqrt{\Re(X_c[k])^2 + \Im(X_c[k])^2} \right) \quad (2.2)$$

Los vectores del logaritmo de la magnitud de cada ventana se organizan en un arreglo bidimensional, dando origen a la representación denominada espectrograma [21]. En la Fig. 2.5, se presenta un ejemplo de espectrograma de un evento sísmico, en la imagen superior se presenta la representación en tiempo, y en la imagen inferior se representa en tiempo-frecuencia, donde el eje X, representa el tiempo y el eje Y representa frecuencia.

**Figura 2.5**  
Espectrograma de evento sísmico



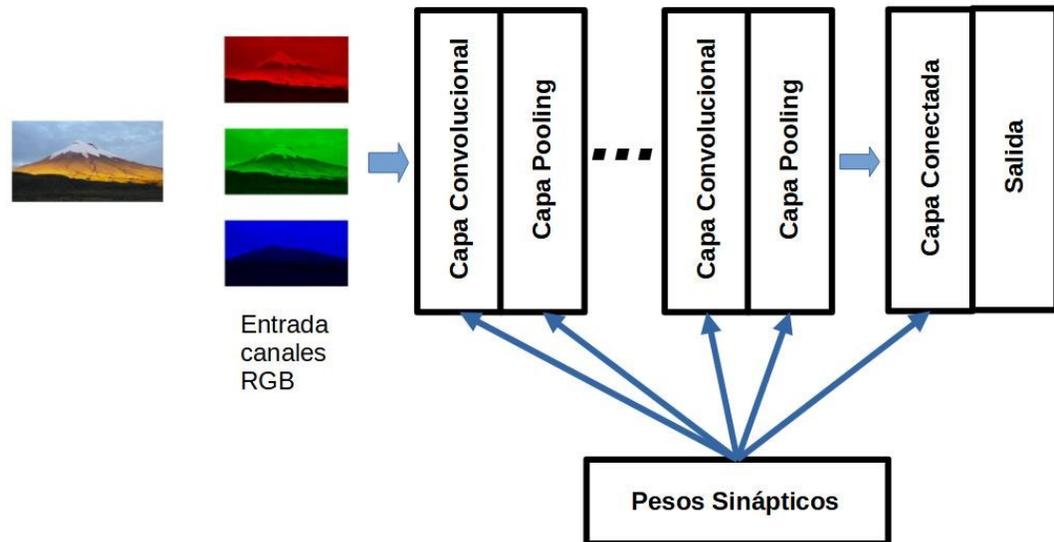
## Redes Neuronales Convoluciones

Las redes neuronales convolucionales (CNN, del inglés *Convolutional Neural Network*) pertenecen al grupo de redes neuronales profundas, las mismas que hacen referencia a redes neuronales con un gran número de capas ocultas [22]. El propósito de incrementar el número de capas ocultas, es tener una combinación no lineal de las entradas a la red, para así obtener las características que permitan reconocer patrones [23].

Las CNN tienen 3 matrices como entradas (existen excepciones con solo una matriz de entrada), utilizadas para representar las matrices de colores de imágenes RGB [24], utiliza la característica de combinar la entrada para extraer información, combinando distintos píxeles para realizar tareas de reconocimiento de imágenes. Otra de las ventajas de las CNN, es que, se puede obtener las características utilizadas para la discriminación de las imágenes a través de los pesos de las capas ocultas [22].

Una CNN tiene tres tipos de capas típicamente: capa convolucional, capa *pooling*, capas totalmente conectadas [25], la estructura básica se presenta en la Fig. 2.6.

**Figura 2.6**  
Estructura básica CNN



### Capa Convolucional

En imágenes la extracción de características es una tarea compleja, pero la convolución nos permite buscar esas características mediante "filtros" (matrices con coeficientes) y de acuerdo a estos coeficientes podemos determinar características como bordes horizontales, bordes verticales, texturas, entre otros.

En la Fig. 2.7, se presenta un ejemplo de convolución utilizando 3 filtros (Bordes, *Sharpen* y *Blur* [22]), donde se observa como de acuerdo al filtro de la convolución se puede extraer cierta información de la imagen; en la primera imagen como salida de la convolución se observa un fondo negro y en blanco el perfil de la imagen, en el segundo escenario con el filtro sharpen se resalta la imagen y difumina el fondo, y finalmente, el filtro blur difumina toda la imagen. Cuando se trabaja con CNN los coeficientes de los filtros se obtienen a través de entrenamiento.

**Figura 2.7**  
Ejemplo de Convolución



La convolución se define mediante la Ec (2.3) [22].

$$c[m, n] = x[m, n] \otimes w[t, j] = \sum_n \sum_m x[m, n] w[t - m, j - n] \quad (2.3)$$

donde,  $\otimes$  representa la convolución,  $x$  la imagen en la entrada y  $w$  el filtro. Luego de la convolución pueden presentarse una capa de activación ReLU.

### Capa Pooling

Con esta capa se pretende reducir gradualmente la dimensión de la entrada, y por consecuencia, el número de parámetros en filtros de capas siguientes [26]. Las funciones más comunes son la función media y máxima [24].

### Capa Totalmente Conectada

Cada salida de la capa anterior se conecta a todas las entradas de la siguiente capa [22], al final de la CNN se utilizan redes neuronales totalmente conectadas, para establecer la probabilidad de cada categoría para la clasificación, a través de los neuronas de la capa totalmente conectada.

Para encontrar los pesos sinápticos de todas las capas de la CNN se utiliza el

descenso de gradiente estocástico [24], minimizando el error entre las categorías reales y las predichas por la red, cuyo resultado se ilustra en la Ec. (2.4)

$$(\omega^i)^{t+1} = (\omega^i)^t - \eta \frac{\partial z}{\partial (\omega^i)^t} \quad (2.4)$$

donde,  $z$  es la pérdida, permitiendo guiar el aprendizaje a través de las etiquetas de entrada.

### **Estado del Arte**

Como parte del desarrollo de este trabajo, se realizó la compilación de información de trabajos relacionados, en esta búsqueda los principales trabajos son:

En [27] se presenta un sistema de detección y clasificación utilizando redes neuronales recurrentes, este trabajo implementa 5 etiquetas en el proceso de clasificación LP (765), VT (75), TRE (77), HB (54) y SIL (No evento - 1222), adicionalmente utilizan una ventana de análisis de 4 segundos con un solapamiento de 3.5 segundos, presentando la mayor exactitud en las diferentes pruebas de 94 %.

Por otra parte, en [28] se plantea el uso de transfer learning con la CNN LeNet, para la clasificación de eventos sísmicos, en este trabajo los autores utilizaron espectrogramas (FFT 512) en escala de grises con una resolución de 32x32, la base de datos empleada por los investigadores cuenta con 9332 eventos distribuidos en VT, LP, Tremores, Colapsos, Explosiones, Regionales, Ruido. Como parte del preprocesamiento en este trabajo utilizan un filtro limitador de espectros con frecuencia de corte de 25Hz y una frecuencia de muestreo de 50Hz, a la salida porcentual de la red LeNet se prueba distintos clasificadores de machine learning, concatenando dos técnicas para la clasificación de eventos, en la cual se consigue un 94 % de exactitud en señales del Volcán de Fuego.

En otro de los trabajos consultados [29], se clasifica eventos sísmicos a partir de espectrogramas utilizando la CNN clásica LeCun formulada en 1998, los espectrogramas para mejorar o resaltar las características de los sismos pasan por un proceso de suavizado, en el cual, se obtiene una media móvil de las ventanas. Las señales pertenecen al Volcán Llaima presentando una exactitud del 95 %. En [30], usan un filtro pasa bajos de

25Hz como etapa de preprocesamiento, la información que ingresa a la red son los vectores correspondientes a los 3 ejes de los sensores (entrada  $600 \times 3$ ), en este trabajo se compara el desempeño del detector con el clásico STA/LTA. En [31], se plantea el uso de la red U-Net, y aplicar transferencia de aprendizaje para detectar la llegada de la señal P y S en registros sísmicos.

En [32], se presenta un detector de microsismos basado en redes neuronales convolucionales, con redes pre entrenadas y segmentos de 15 segundos sin solapamiento, con una probabilidad de detección por ventana de 96 %. En [18], se propone un algoritmo de detección basado en técnicas de detección de voz activa, en esta propuesta los autores presentan una exactitud del 98 %.

### **Propuesta**

En base a los conceptos teóricos explicados en los puntos anteriores se plantea desarrollar un sistema de reconocimiento automático de microsismos, con la capacidad de reconocer eventos LP y VT, el sistema cuenta con tres etapas, preprocesamiento, detección y clasificación.

En el preprocesamiento se plantea considerar un canal convolucional, para estimar la señal sísmica producida en la fuente del sismo, con lo cual, se mejora la relación señal a ruido (SNR, del inglés *Signal to Noise Ratio*), lo que, permite la detección de eventos sísmicos de baja energía.

En la etapa de detección se plantean dos detectores, el primer detector utiliza CNN entrenadas con etiquetas de (*evento-no evento*), para determinar la existencia de un evento sísmico en una ventana de tiempo; el segundo detector evaluado es una variación del algoritmo STA/LTA, utilizando la energía cuadrática media de la señal como función  $g(x)$ .

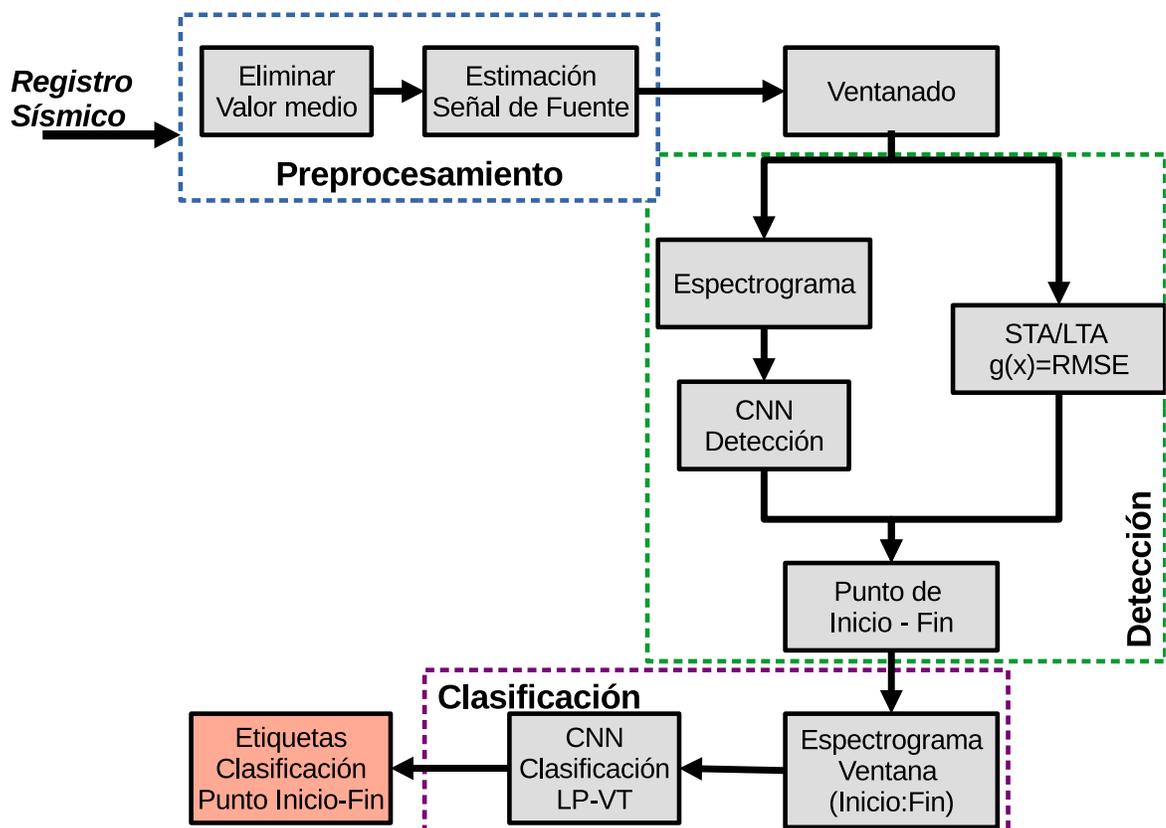
Finalmente, se plantea generar espectrogramas que resalten las diferencias entre los eventos sismo volcánicos, y utilizar redes neuronales convolucionales pre entrenadas, para utilizar conjuntos de datos limitados se utiliza transferencia de aprendizaje para entrenar las CNN.

En la Fig. 2.8, se presenta el diagrama de bloques de la propuesta, donde se observa, que el sistema propuesto está dividido en tres bloques principales, como ya se menciona anteriormente:

- Bloque de preprocesamiento, se encarga de eliminar el valor medio y de estimar la señal producida en la fuente del mismo.
- Bloque de detección, se evalúa dos propuestas una modificación del detector STA/LTA y detección basada en CNN.
- Bloque de clasificación, se utiliza la información de punto de inicio y fin dada por el detector y se clasifica los eventos sísmicos.

La información generada por los tres bloques, podría ser utilizada en sistemas de alerta temprana.

**Figura 2.8**  
*Diagrama de Bloques Sistema de Reconocimiento*



En el siguiente capítulo, se describen los detalles de los procesos utilizados en la etapa de pre procesamiento, formada por: extracción de valor medio, filtro digital y deconvolución homomórfica, con la finalidad de mejorar la relación señal a ruido sin afectar las componentes espectrales de los micro sísmicos, con esto se espera mejorar el desempeño de la etapa de detección y clasificación.

## Preprocesamiento

En la etapa de preprocesamiento, se plantean dos procesos, el primer proceso es eliminar el valor medio de la señal, considerando que el sistema opera en un esquema de quasi tiempo-real, se puede estimar la media y removerla de la señal, la estimativa del valor medio se presenta en la Ec. (3.1).

$$m_x = \frac{1}{n} \sum_{i=1}^n x[i] \quad (3.1)$$

donde, el valor de  $m_x$  se remueve de la señal  $x_s$ , que es la señal registrada por los sismógrafos, y se obtiene la señal  $x_p$ , con valor medio 0, como se presenta en la Ec. (3.2):

$$x_p = x_s - m_x \quad (3.2)$$

Luego de este proceso, se propone el uso de la deconvolución homomórfica para mejorar la SNR, de los eventos microsismos, con lo que, se espera que la detección sea un proceso con un desempeño superior.

### Deconvolución Homomórfica

Se plantea la deconvolución homomórfica, con el objetivo de estimar la señal  $\widehat{s}[n]$ , que es la señal estimada de la señal producida en la fuente sísmica [33]. Para esto se considera, el modelo de canal presentado en la Ec. (3.3), donde  $r[n]$  es la señal registrada por el sismógrafo y  $h_T[n]$ , es la respuesta al impulso del sistema Lineal Invariante en el Tiempo (LTI del inglés, *Linear Time-Invariant*) [34], este sistema LTI representa el trayecto que recorre la onda sísmica desde su origen hasta el sismógrafo.

$$r[n] = s[n] \otimes h_T[n] \quad (3.3)$$

donde,  $\otimes$  representa convolución.

La señal  $s[n]$ , es la señal producida en la fuente del sismo, y por medio de la deconvolución homomórfica se plantea recuperar  $\widehat{s}[n]$ , una estimación de dicha señal, como se presenta en la Ec. (3.4).

$$\widehat{s}[n] = deconv(r[n]) \quad (3.4)$$

De forma general se utiliza la propiedad de la convolución de ser una multiplicación en frecuencia y el uso de logaritmos para pasar esa multiplicación a una suma, el proceso completo se detalla a continuación:

Como se dice en el párrafo anterior, el primer paso para estimar  $\widehat{s}[n]$ , es calcular la DFT, de la señal  $r[n]$  de longitud  $N$ , para definir la notación se utiliza  $DFT_N[r[n]]$ , la Ec. (3.5) presenta la DFT de  $r[n]$ .

$$R[k] = DFT_N[r[n]] = \sum_{n=0}^{N-1} r[n] W_N^{kn} \quad (3.5)$$

donde,  $W_N = \exp[-j(2\pi/N)]$  y  $0 \leq k \leq N - 1$ . Se considera que el registro  $r[n]$  tiene una longitud de  $(m + 1)N - 1$ , para procesar el registro, se segmenta en ventanas donde  $m$  es la  $m$ -ésima ventana y  $N$  es el número de muestras de cada ventana, considerando esto se genera la matriz  $R[k, m]$  con la DFT de cada ventana como se presenta en la Ec. (3.6):

$$R[k, m] = \sum_{n=mN}^{(m+1)N-1} r[n] W_N^{k(n-mN)} \quad (3.6)$$

donde,  $R[k, m]$  es la matriz de DFT de cada ventana  $m$ , con una dimensión de  $m$  columnas y cada fila contiene la  $DFT_N[r[n]]$  de cada ventana.  $m$  esta dado por  $m = integer(M/N)$  y  $M$  es el número total de muestras del registros  $r[n]$ .

La secuencia original  $r[n]$  de cada ventana  $m$  se puede recuperar con la Transformada Inversa de Fourier (IDFT del inglés, *Inverse Discrete Fourier Transform*) de la matriz  $R[k, m]$  Ec. (3.7):

$$r[n, m] = \frac{1}{N} \sum_{k=0}^{N-1} R[k, m] W_N^{-kn} \quad (3.7)$$

para recuperar la secuencia  $r[n]$  original es necesario un proceso de ordenamiento de la

nueva matriz  $r[n, m]$ .

Continuando con el proceso de deconvolución homomórfica, se requiere calcular el logaritmo natural de la matriz  $R[k, m]$  (3.6) esto se presenta en la Ec. (3.8) y la IDFT de la Ec. (3.8), esto se describe en la Ec. (3.9).

$$L[k, m] = \ln(R[k, m]) \quad (3.8)$$

$$\underline{l}[n, m] = \frac{1}{N} \sum_{k=0}^{N-1} L[k, m] W_N^{-kn} \quad (3.9)$$

Ahora, cada columna de  $\underline{l}[n, m]$  se debe multiplicar con la señal  $\ell[m]$  [35], donde  $\ell$  es  $\ell[m] = 2u[m] - \delta_k[m]$ , y  $u[m]$  es la función escalón unitario [36] y  $\delta_K[m]$  es la función delta de Kronecker [37].

$$A = [\ell_1^T[j], \ell_2^T[j], \dots, \ell_m^T[j]] \quad (3.10)$$

donde,  $j = 1, 2, \dots, n$

$$\underline{l}' = \underline{l} \times A \quad (3.11)$$

La DFT de cada columna de la matriz  $\underline{l}'$ , se obtiene la matriz  $L'[k, m]$  Ec. (3.12), a la cual, se le aplica la función de la Ec. (3.13) como operación contraria al logaritmo natural aplicado en Ec. (3.8), con este proceso se obtiene la matriz  $\widehat{S}[k, m]$ , que es la representación en frecuencia de la matriz  $\widehat{s}[n, m]$ .

$$L'[k, m] = \sum_{n=0}^{N-1} \underline{l}'[n, m] W_N^{kn} \quad (3.12)$$

$$\widehat{S}[k, m] = \exp(L'[k, m]) \quad (3.13)$$

Finalmente, se obtiene la señal  $\widehat{s}[n]$ , la cual ya es la señal estimada de la fuente sísmica, aplicando la IDFT a la matriz  $\widehat{S}[k, m]$  Ec. (3.14) y reorganizando la matriz de dimensiones  $(k, m)$  a un vector de dimensión  $km$  esto se presenta en la Ec. (3.15), donde el

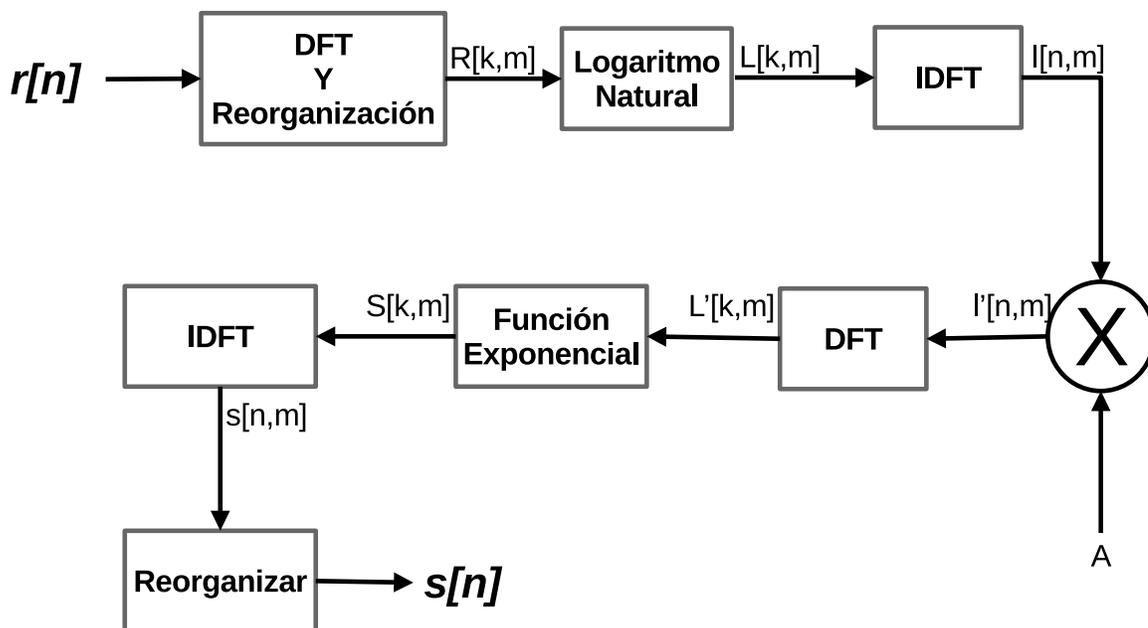
vector de cada ventana  $\widehat{s}[n, 1]$  hasta  $\widehat{s}[n, m]$ , se concatenan para formar la señal estimada  $\widehat{s}[p]$ .

$$\widehat{s}[n, m] = \frac{1}{N} \sum_{k=0}^{N-1} \widehat{S}[k, m] W_N^{-kn} \quad (3.14)$$

$$\widehat{s}[p] = [\widehat{s}[n, 1]^T, \widehat{s}[n, 2]^T, \dots, \widehat{s}[n, m]^T] \quad (3.15)$$

**Figura 3.1**

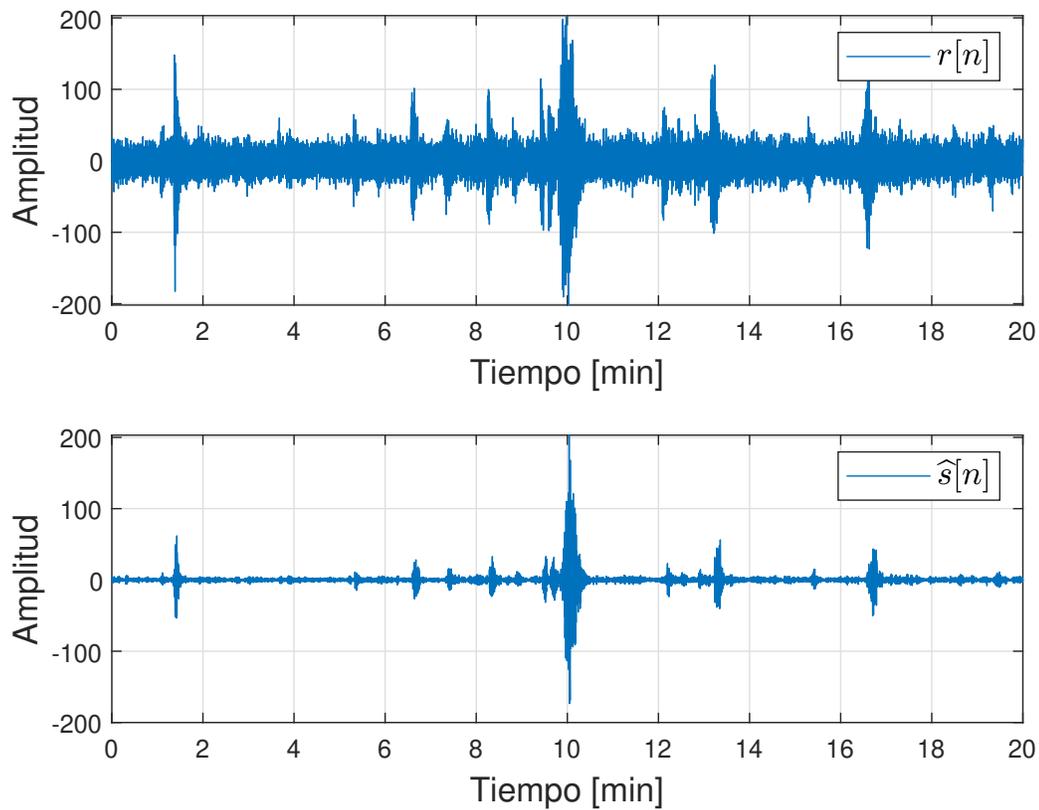
*Diagrama de Bloques del proceso de Deconvolución Homomórfica*



En la Fig. 3.1, se presenta el resumen del proceso de deconvolución homomórfica el mismo que esta detallado en los párrafos anteriores.

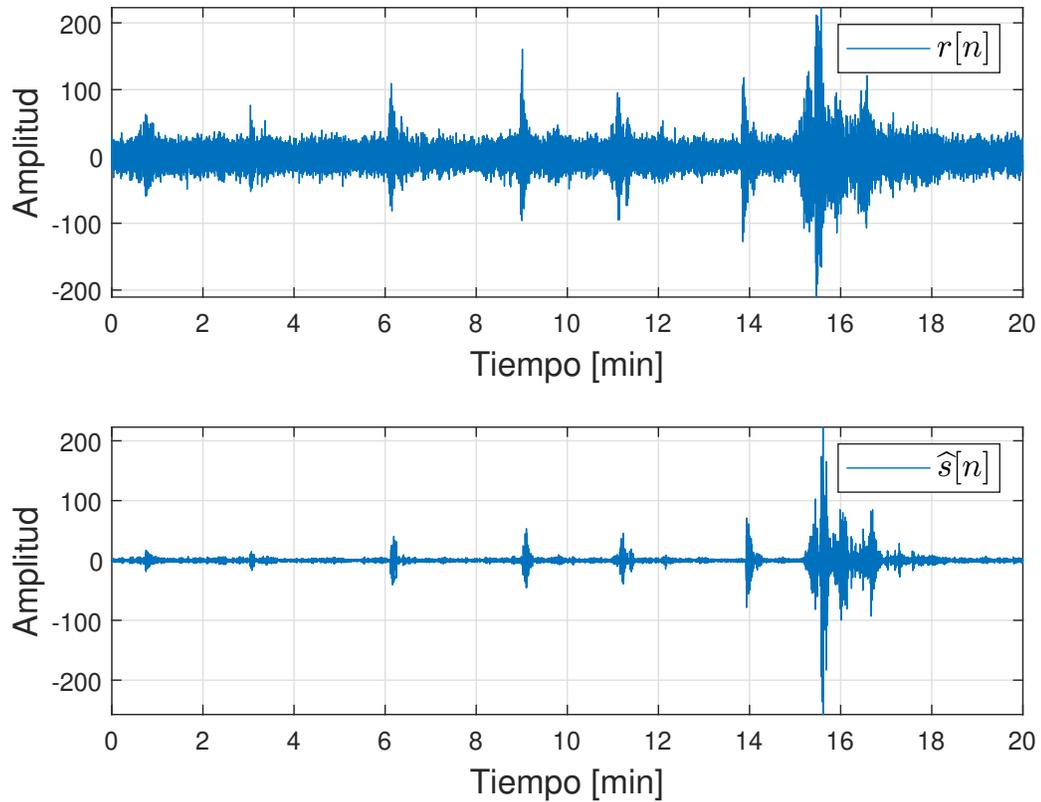
**Figura 3.2**

Resultado del procesamiento homomórfico aplicado a un registro (Ejemplo 1). Figura superior registro original  $r[n]$ , figura inferior salida del procesador homomórfico  $\hat{s}[n]$



**Figura 3.3**

Resultado del procesamiento homomórfico aplicado a un registro (Ejemplo 2). Figura superior registro original  $r[n]$ , figura inferior salida del procesador homomórfico  $\hat{s}[n]$



En las Fig. 3.2 y Fig. 3.3, se presentan registros sísmicos de  $20min$ , en los cuales se compara la señal  $r[n]$  con la señal  $\hat{s}[n]$ , donde se aprecia que el nivel de ruido se reduce, lo cual confirma las hipótesis planteadas. Al reducir el nivel de ruido de fondo se mejora el desempeño de los detectores y se puede encontrar microsismos de baja energía, la Fig. 3.3, presenta un ejemplo de dos eventos de baja energía descubiertos al reducir el nivel de ruido, estos eventos se encuentran ubicados en  $0,8min$  y en  $3min$ .

### Estimación SNR

Para evaluar el desempeño y el incremento de SNR, se estima la SNR de los eventos sísmicos presentados en la base de datos [9], en dicha base de datos se dispone del

punto de inicio y el punto final de cada evento.

Para analizar el incremento en SNR, con la deconvolución homomórfica se estima la SNR, para esto se puede considera que diferentes ventanas del registro sísmico se pueden interpretar a través de una hipótesis binaria Ec. 3.16. [32]. Con lo que si se calcula la potencia de una ventana con ruido y la potencia de una ventana con evento sísmico se puede estimar la SNR.

$$x_s = \begin{cases} x_r + x_e, & H_1 \\ x_r, & H_0 \end{cases} \quad (3.16)$$

donde,  $x_s$  es el registro sísmico, la hipótesis  $H_1$  posee  $x_r$  ventana de ruido y  $x_e$  ventana de evento; y la hipótesis  $H_0$  solo posee ventana de ruido.

La ventana de señal sísmica con hipótesis  $H_1$  y  $H_0$  tienen media 0, para calcular la potencia de señales estocásticas se tiene  $P = \sigma^2 + \mu^2$  [38], [39], donde  $\sigma^2$  es la varianza y  $\mu$  la media de la señal, a partir de esto se plantea la potencia de una ventana con eventos sísmico y una solo con ruido, Ec. (3.17) y Ec. (3.18), respectivamente.

$$P_e = \sigma_e^2 + \mu_e^2 = E[x_e^2] + E[x_e]^2 \quad (3.17)$$

$$P_r = \sigma_r^2 + \mu_r^2 = E[x_r^2] + E[x_r]^2 \quad (3.18)$$

Al no tener la potencia del evento sísmico se puede aproximar con la Ec. (3.19).

$$P_e \approx E[(x_r + x_e)^2] - E[x_r^2] \quad (3.19)$$

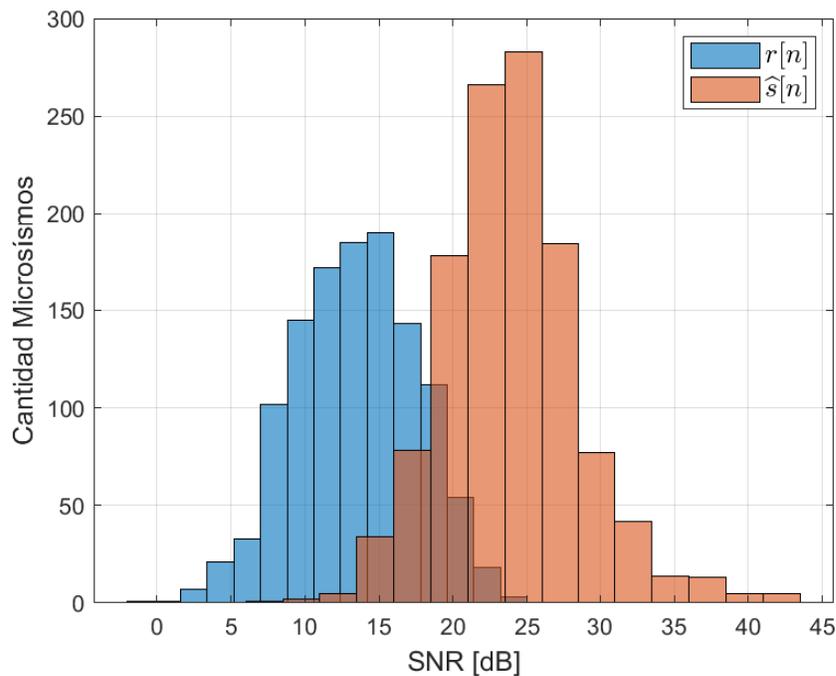
Finalmente, se obtiene la estimación de SNR:

$$SNR \approx \frac{P_e}{P_r} \quad (3.20)$$

$$SNR_{dB} \approx 10 \times \log_{10} \left( \frac{P_e}{P_r} \right) \quad (3.21)$$

Una vez realizado esto se estimó la SNR de cada uno de los eventos de la base de datos [9], antes y después de aplicar el proceso de deconvolución homomórfica.

**Figura 3.4**  
Comparación SNR, con y sin deconvolución homomórfica



En la Fig. 3.4, se presenta dos histogramas, el histograma de color azul presenta la SNR estimada de 1187 eventos, en la cual la media de SNR se encuentra en  $13,5dB$  y el histograma en rojo representa la SNR estimada de los mismo eventos luego de aplicar el proceso de deconvolución homomórfica, en este caso se presenta una media de  $24dB$ . Analizando el histograma se tiene una mejora de  $10dB$  con el proceso de deconvolución homomórfica, también se puede destacar que el rango de SNR de los eventos sin el pre-procesamiento es de  $3dB$  a  $25dB$ , mientras que luego de aplicar la deconvolución el rango es de  $5dB$  a  $44dB$ , por lo que, se muestra que no se tiene una ganancia lineal de los  $10dB$ .

## Análisis en Frecuencia

Para validar que el proceso propuesto solo elimine las perturbaciones adicionales por el trayecto que recorre la señal sísmica, se toman diferentes eventos sísmico y se analiza el comportamiento en frecuencia antes y después de aplicar la deconvolución homomórfica; para este proceso se plantea utilizar el periodograma de Welch [20].

La característica principal del periodograma de Welch es el solapamiento entre ventanas, para incrementar la estabilidad (reducir varianza del estimador), aunque como consecuencia se pierde resolución [20]. La Ec. (3.22) define las ventanas de datos con las que se realizará la estimación espectral, para luego, ser promediadas conforme al método de Welch.

$$x^{(p)}[n] = w[n]x[n + pS] \quad (3.22)$$

donde,  $p$  es el superíndice de número de ventana,  $w[n]$  la función de ventana y  $S$  las muestras de solapamiento.

La Ec. (3.23) estima la densidad espectral de potencia de cada vector  $X^{(p)}(f)$  Ec. (3.24), donde  $E_w$  representa la energía de la función de ventana Ec. (3.25).

$$P_{xx}^{(p)}(f) = \frac{1}{E_w} \frac{1}{D \times T} |X^{(p)}(f)|^2 \quad (3.23)$$

donde,  $D$  es el número de muestras de cada ventana,  $T$  es el periodo de muestreo,  $(p)$  superíndice que denota el número de segmento.

$$X^{(p)}(f) = T \sum_{n=0}^{D-1} x^{(p)}[n] \exp(-j2\pi fnT) \quad (3.24)$$

$$E_w = T \sum_{n=0}^{D-1} |w[n]|^2 \quad (3.25)$$

Finalmente, en la Ec. (3.26) se realiza el promedio de los vectores de frecuencia

obteniendo el periodograma de Welch [20].

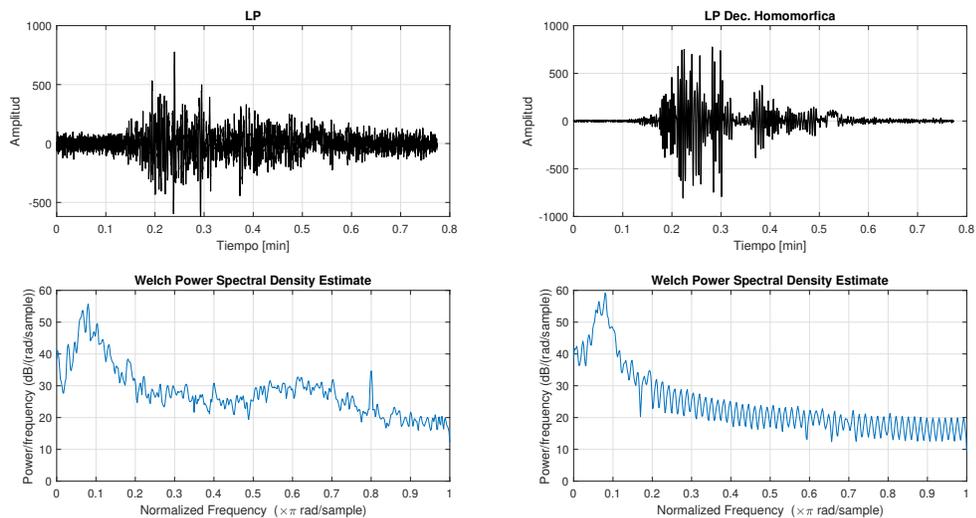
$$P_W(f) = \frac{1}{P} \sum_{p=0}^{P-1} P_{xx}^{(p)}(f) \quad (3.26)$$

En las Fig. 3.5, Fig. 3.6 y Fig. 3.7 se presenta el periodograma de Welch de eventos sísmicos LP, VT y Tremor.

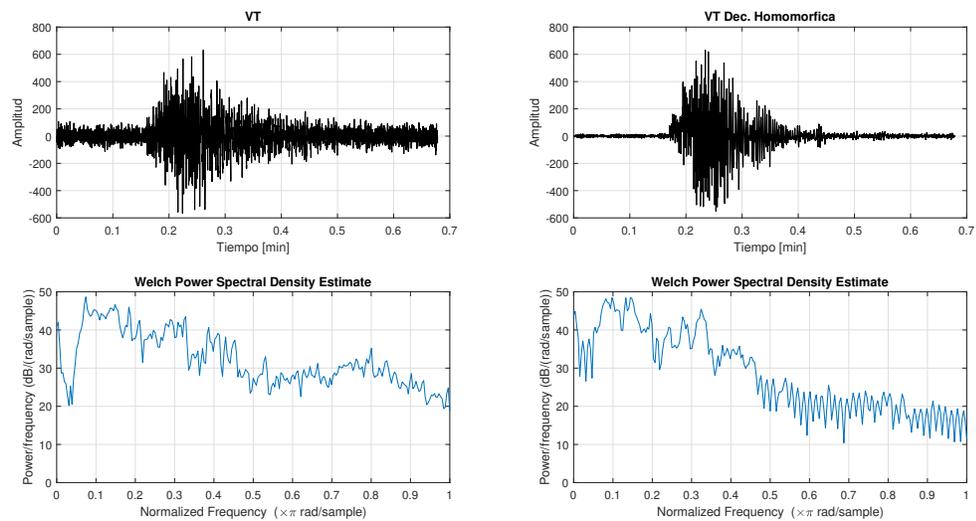
En la Fig. 3.5, se observa que la componente principal o de mayor potencia se encuentra entre  $2,5Hz$  y  $4Hz$ , comportamiento característico de un evento LP, luego de aplicar el proceso de deconvolución homomórfica se observa que en las bandas de frecuencia del evento LP no se tiene alteraciones, y se presenta una mayor estabilidad, en frecuencias superiores correspondientes al ruido se presenta una atenuación y la presencia de lóbulos de baja potencia periódicos.

En la Fig. 3.6, se presenta un ejemplo de evento VT, la señal se encuentra muestreada a  $100Hz$ , por lo que, el evento tiene presencia en la banda de  $3Hz$  hasta  $22Hz$ , lo que corresponde a un evento VT, en la comparación de tiempo se observa una reducción considerable del nivel de ruido, por otra parte, en la comparación en frecuencia no se tiene cambios en la banda del evento, en las bandas superiores si se tiene una reducción de energía. El ejemplo de Tremor tiene un comportamiento similar a los dos casos descritos, esto se ve en la Fig. 3.7, con presencia de evento en la banda de  $2,5Hz$  a  $7,5Hz$ .

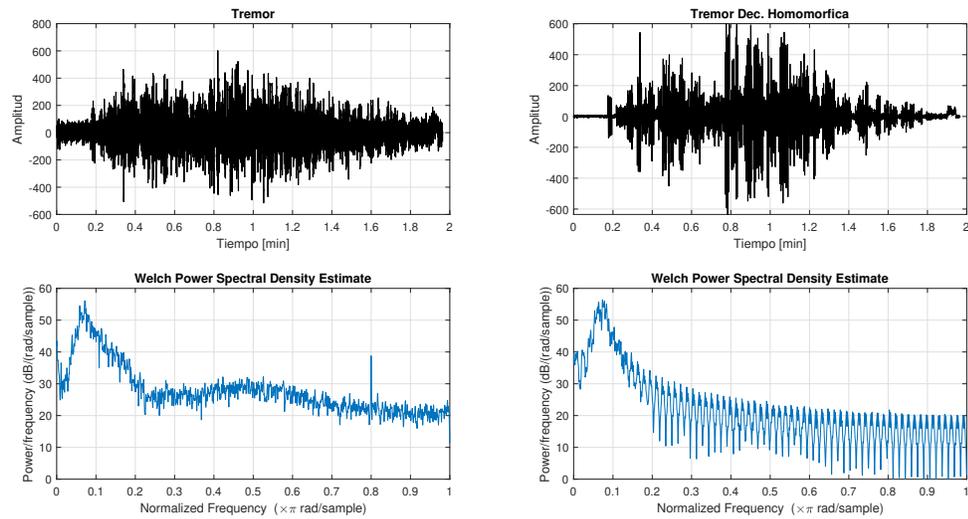
**Figura 3.5**  
*Análisis de Frecuencia LP, comparación con y sin deconvolución homomórfica*



**Figura 3.6**  
*Análisis de Frecuencia VT, comparación con y sin deconvolución homomórfica*



**Figura 3.7**  
*Análisis de Frecuencia Tremor, comparación con y sin deconvolución homomórfica*



## Filtro Digital

Al no existir componentes en frecuencia sobre  $25\text{Hz}$  conocidas en los diferentes tipos de eventos, se aplica un filtro pasa bajos de  $25\text{Hz}$  [28], para eliminar las componentes superiores y centrar los espectrogramas para detección [32].

En el siguiente capítulo, se describe dos propuestas de detección de microsismos, la primera propuesta se basa en una modificación del algoritmo STA/LTA y la segunda se basa en el uso de redes neuronales convolucionales; en la modificación del algoritmo STA/LTE se utiliza la energía cuadrática media de la señal  $\widehat{s}[n]$  y en la propuesta de CNN se utiliza espectrogramas para entrenar la red y realizar la detección de microsismos.

## Detección

### Modificación STA/LTA

El algoritmo STA/LTA pertenece a la familia de algoritmos *Trigger* [40], esto significa que se tiene una condición de activación, cuando el valor de la función  $g(x)$  de ventana corta supera el valor  $g(x)$  de la ventana larga, a esta activación se le atribuye una detección.

El algoritmo STA/LTA se puede describir a través de la Ec. (4.1), Ec. (4.2) y la relación de la Ec. (4.3) [41].

$$STA = \frac{1}{N_S} \sum_{n=1}^{N_S} g(r[n]) \quad (4.1)$$

$$LTA = \frac{1}{N_L} \sum_{n=-N_L}^0 g(r[n]) \quad (4.2)$$

$$SL = \frac{STA}{LTA} \quad (4.3)$$

donde,  $N_S$  es el número de muestras en la ventana corta,  $N_L$  es el número de muestras en la ventana larga,  $r[n]$  registro sísmico y  $g(x)$  es la función utilizada para permitir la activación del algoritmo en presencia de los eventos sísmicos, en la literatura existen varias funciones las principales se muestran en la Ec. (4.4) [42] que es el valor absoluto de la señal sísmica, Ec. (4.5) [43] cada muestra de la señal al cuadrado y Ec. (4.6) [44] representa la envolvente de la señal sísmica.

$$g(r[n]) = y = |r[n]| \quad (4.4)$$

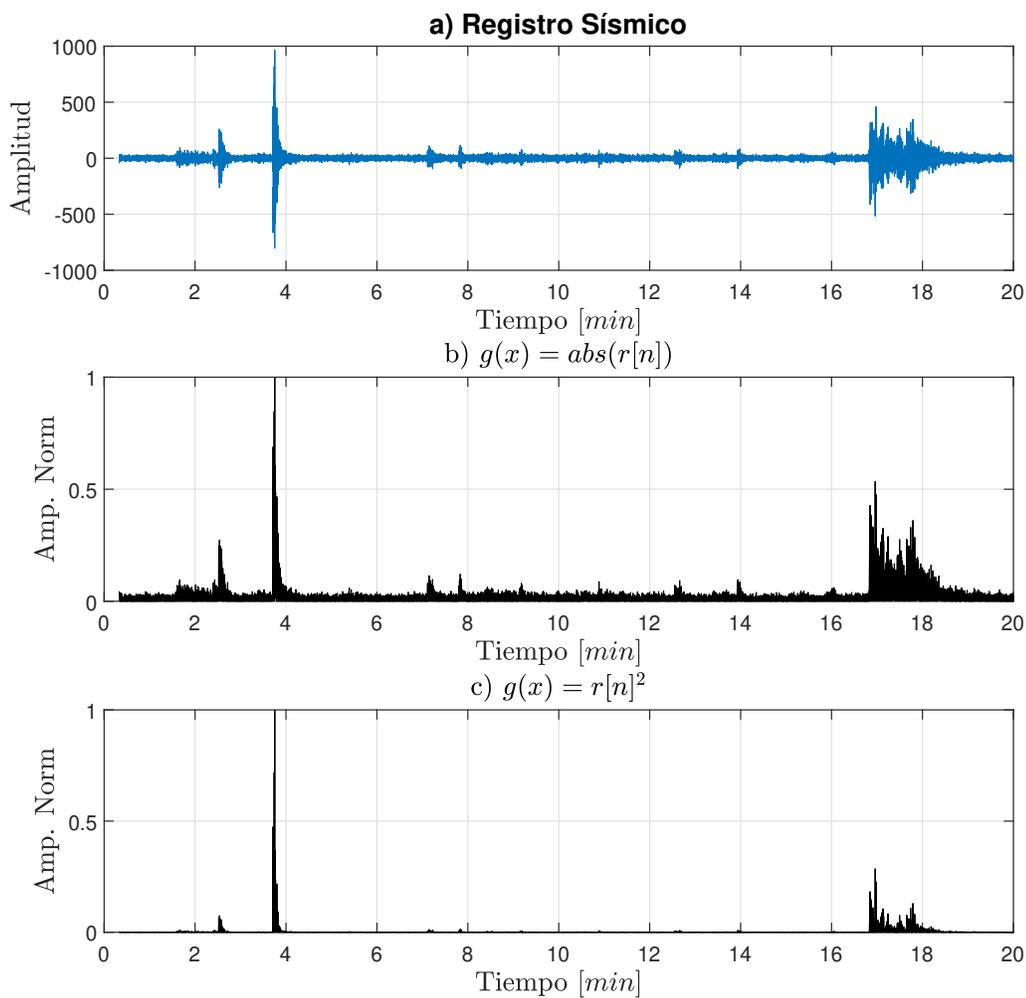
$$g(r[n]) = y = r^2[n] \quad (4.5)$$

$$g(r[n]) = y = \sqrt{r^2[n] + h(r[n])^2} \quad (4.6)$$

En la Fig. 4.1, se presentan las funciones  $g(x)$  de la Ec. (4.4) y Ec. (4.5), donde se observa que al utilizar la Ec. (4.5) se tiene una reducción de falsos positivos, en la gráfica se observa la importancia de la función de activación, por lo que, en este trabajo se plantea una nueva función  $g(x)$ .

**Figura 4.1**

*Funciones  $g(x)$  clásicas: a) Registro Sísmico, b)  $g(x) = |r[n]|$ , c)  $g(x) = r^2[n]$*

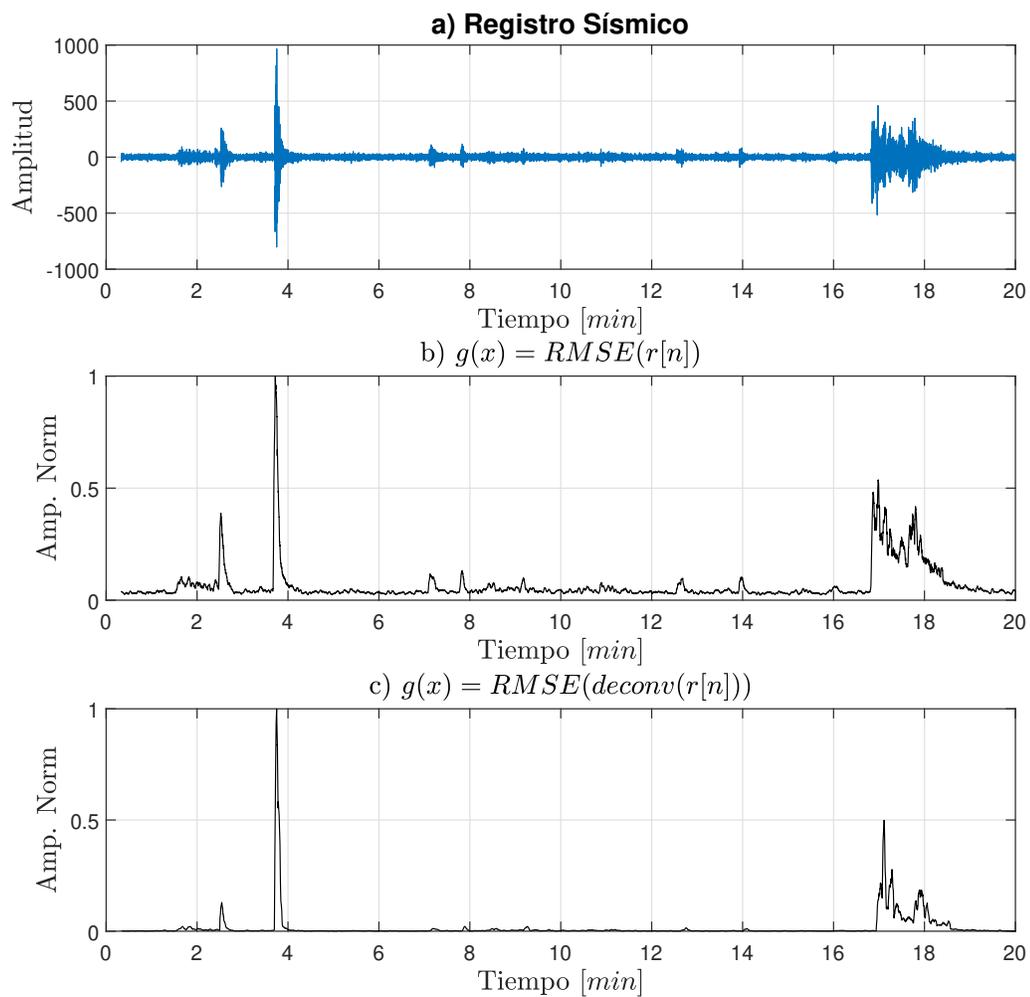


Para lo cual, se plantea calcular la energía cuadrática media (RMSE del inglés, *Root mean square energy*) de la señal  $\widehat{s}[n]$ , la RMSE se presenta en la Ec. (4.7) [45]. La función  $g(x)$  planteada se puede expresar como  $g(r[n]) = y = RMSE(deconv(r[n]))$  o  $g(\widehat{s}[n]) = y = RMSE(\widehat{s}[n])$ .

$$y_R[m] = \sqrt{\frac{1}{N} \sum_{n=mN}^{(m+1)N-1} |\widehat{s}[n]|^2} \quad (4.7)$$

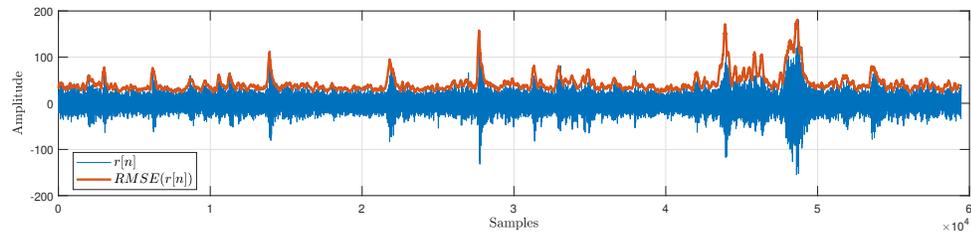
**Figura 4.2**

*Funciones  $g(x)$  propuesta: a) Registro Sísmico, b)  $g(x) = RMSE(r[n])$ , c)  $g(x) = RMSE(deconv(r[n]))$*

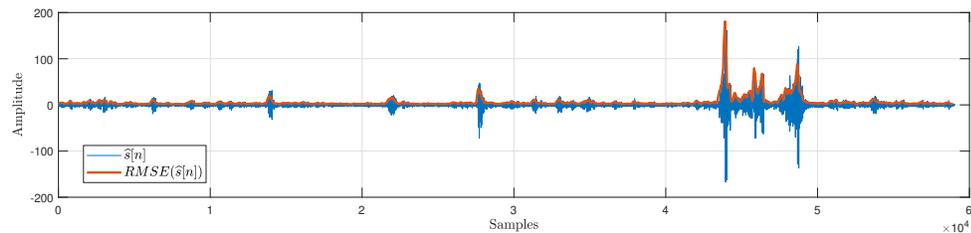


En la Fig. 4.2, se prueba la función  $RMS E$  tanto en la señal  $r[n]$  como en la señal  $\hat{r}[n]$ , donde se observa la reducción de falsos positivo e incremento en la estabilidad al utilizar  $g(r[n]) = y = RMS E(deconv(r[n]))$ , y una ganancia respecto a la Fig. 4.1, por ejemplo en el evento ubicado en el minuto 2,5 y en el evento ubicado en el minuto 17, se observan la misma ganancia entre las dos funciones  $g(x)$  de la figura, pero el nivel de ruido se reduce de 0,1 de media a aproximadamente 0, mientras que las señales de posibles eventos sísmicos no reducen su amplitud.

**Figura 4.3**  
RMSE señal sísmica  $r[n]$



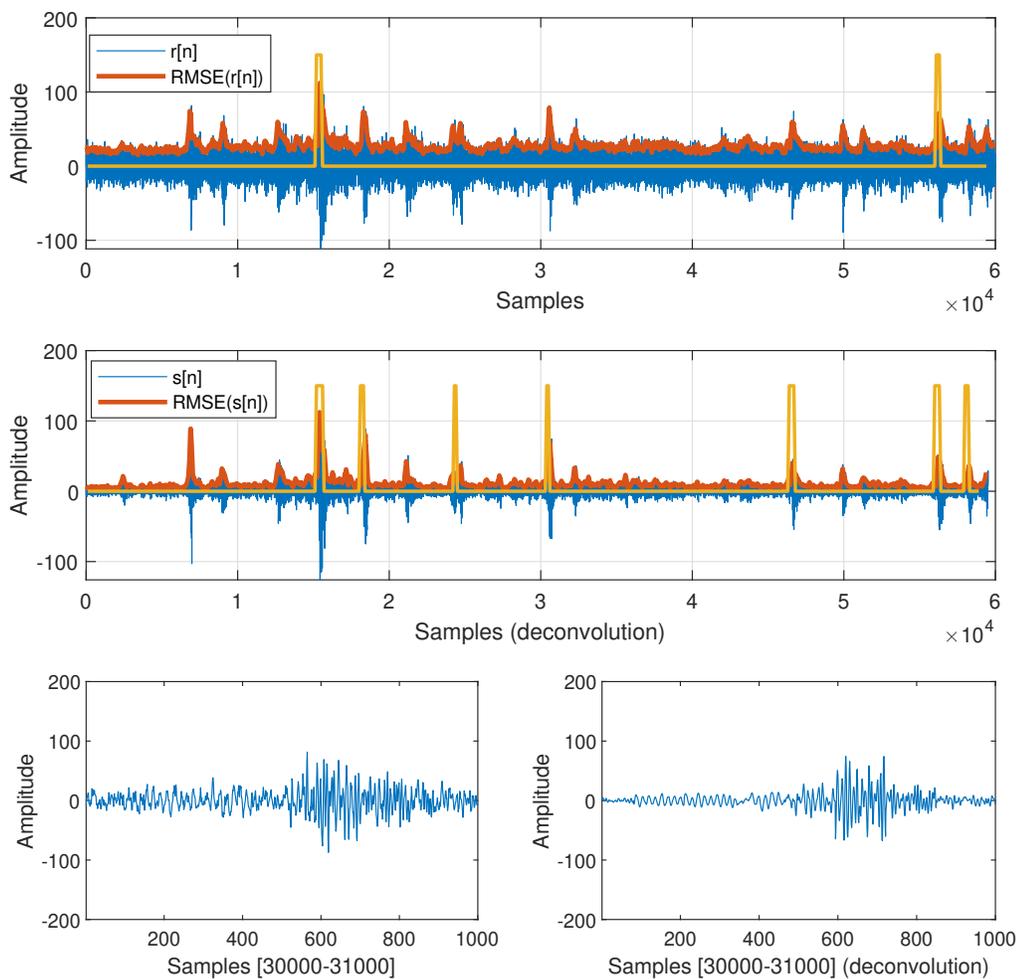
**Figura 4.4**  
RMSE señal sísmica estimada  $\hat{s}[n]$



En la Fig. 4.3, se presenta el registro sísmico y la correspondiente curva de RMSE, que actúa como una curva envolvente para la detección, y en la Fig. 4.4 se presenta la señal  $\hat{s}[n]$  y la curva de RMSE, esta gráfica busca resaltar la reducción de ruido y el seguimiento o acción envolvente de la función RMSE.

**Figura 4.5**

Ejemplo de detección con  $g(r[n]) = \text{RMSE}(\text{deconv}(r[n])) = \text{RMSE}(\widehat{s}[n])$



Finalmente, en la Fig. 4.5, se presenta un ejemplo de STALTA con la función  $\text{RMSE}$  de  $r[n]$  y de  $\widehat{s}[n]$ , donde se observa la reducción del nivel de ruido y un incremento en la detección de sismos, sin la deconvolución homomórfica se tiene una detección de dos eventos en el registro de  $20\text{min}$ , y con la deconvolución se presentan siete eventos, a cada uno de estos eventos se los analizó en frecuencia para determinar que correspondan a un evento de origen volcánico, este incremento en la detección permite ver la mejora en sensibilidad del sistema propuesto.

## Evaluación

Para tener una métricas de desempeño se utilizan métricas estadísticas comunes del área de inteligencia computacional como son la Exactitud ( $A_c$ ) Ec. (4.8), Precisión ( $P_r$ ) Ec. (4.9), Sensibilidad ( $S_e$ ) Ec. (4.10), Especificidad ( $S_p$ ) Ec. (4.11) y Tasa de Error Balanceada (BER del inglés, *balance error rate*) Ec. (4.12) [46], [47].

$$A_c(\%) = \frac{N_c}{N_v} \times 100 \quad (4.8)$$

$$P_r(\%) = \frac{N_{TP}}{N_{TP} + N_{FP}} \times 100 \quad (4.9)$$

$$S_e(\%) = \frac{N_{TP}}{N_{TP} + N_{FN}} \times 100 \quad (4.10)$$

$$S_p(\%) = \frac{N_{TN}}{N_{TN} + N_{FP}} \times 100 \quad (4.11)$$

$$BER = 1 - \frac{S_p + S_e}{2 \times 100} \quad (4.12)$$

donde:

- $N_c$  - Número correcto de detecciones
- $N_v$  - Número total de ventanas de análisis
- $N_{TP}$  - Verdaderos Positivos
- $N_{TN}$  - Verdaderos Negativos
- $N_{FP}$  - Falsos Positivos
- $N_{FN}$  - Falsos Negativos

Las métricas presentadas en el párrafo anterior, se utilizan para evaluar el detector

propuesto con un registro de 7000min y 350 eventos, este registro fue previamente analizado por expertos del IGEPN, obteniendo las métricas presentadas en la Tabla 4.1.

**Tabla 4.1**  
Métrica de detección STA/LTA  
de  $g(r[n]) = RMS E(\hat{s}[n])$

Parámetros	Valores
Exactitud	99,31 %
Precisión	88,43 %
Sensibilidad	98,29 %
Especificidad	99,36 %
BER	0,01179

## DetECCIÓN CON CNN

### Transferencia de Aprendizaje

La transferencia de aprendizaje en CNN hace referencia a aprovechar la información de entrenamientos profundos, para futuras clasificaciones [48], reentrenando las capas finales y haciendo cambios en su arquitectura (Capa totalmente conectada, Capa Softmax, Capa de Clasificación), y/o permitiendo un ajuste fino de los pesos sinápticos de todas las capas de la CNN [32].

Para este trabajo, se utilizan CNN profundamente entrenadas con la base de datos ImageNet [49], este repositorio tiene 10 millones de imágenes distribuidos en 1000 clases [50]. ImageNet ha sido utilizado para evaluar las principales CNN utilizadas para clasificación de imágenes [49].

Con el concepto de transferencia de aprendizaje se cambian las capas finales para conseguir que las CNN clasifique espectrogramas con la etiqueta de *Evento* y *No Evento*, permitiendo la detección de la existencia de microsismos en la ventana de análisis, inicialmente se consideraron las CNN: Alexnet [51], SqueezeNet [52], ResNet50 [53] y GoogLeNet [54], finalmente, se decidió utilizar GoogLeNet, por las métricas alcanzadas en [32].

## Espectrograma

Antes de generar los espectrogramas se aplica el filtro de 25Hz, descrito en el capítulo anterior.

En [55] se manejan ventanas de 15 segundos sin solapamiento, en [27] se utiliza ventanas de 4 segundos con solapamiento de 3,5 segundos; finalmente, en este trabajo se probó que la ventana con mejores resultados es de 5 segundos y solapamiento de 4 segundos.

Cada registro de 20 minutos, se divide en vectores de 500 muestras, y solapamiento de 400 muestras, por lo que, se tiene  $1 \leq j \leq 1200$  y  $1 \leq i \leq 500$ , y se genera una matriz con todos los vectores Ec. (4.13) [32].

$$\bar{x}_i = [x_{i,1}^T, x_{i,2}^T, \dots, x_{i,j}^T]^T \quad (4.13)$$

Y se genera un espectrograma con cada vector de la matriz:

$$S_{p,j} = g_s(x_{i,j}) \quad (4.14)$$

$$\bar{S}_p = [S_{p,1}^T, S_{p,2}^T, \dots, S_{p,j}^T]^T \quad (4.15)$$

$$X_p\{k\} = \sum_{n=0}^{N-1} x_p[n] e^{-j2\pi k \frac{n}{N}} \quad (4.16)$$

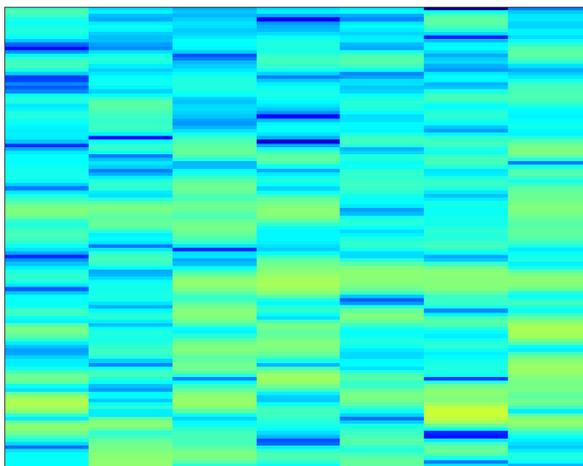
$$|X_p\{k\}| = \sqrt{\Re\{X_p\{k\}\}^2 + \Im\{X_p\{k\}\}^2} \quad (4.17)$$

Finalmente, se aplica la función logaritmo para generar los espectrogramas Ec (4.18), se genera espectrogramas de ventanas con evento sísmico y ventanas solo con ruido para entrenar a las redes con dos etiquetas.

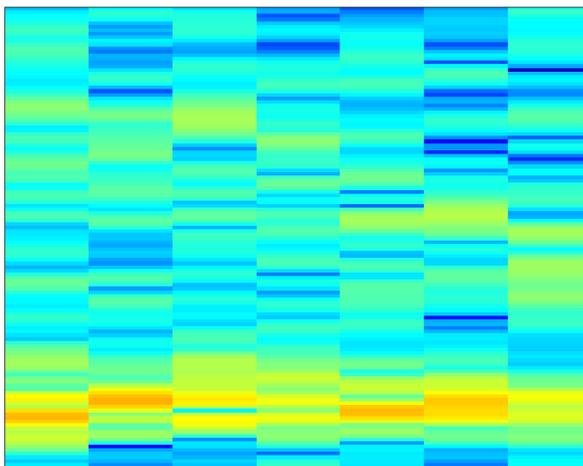
$$S_w = \ln |X_p\{k\}| \quad (4.18)$$

En la Fig. 4.6 y en la Fig. 4.7, se presenta ejemplos de espectrogramas obtenidos para entrenar la CNN (eje x de 1 a 500 muestras, eje y 0 a 50Hz, *no se presenta ejes en la figura para ilustrar las imágenes utilizadas para entrenar la red*), aplicando la función espectrograma directamente a la señal  $r[n]$ , en la Fig 4.7, se observa con claridad la existencia de energía con lo cual la CNN podría detectar la existencia de un evento sísmo volcánico.

**Figura 4.6**  
*Espectrograma ventana No Evento*

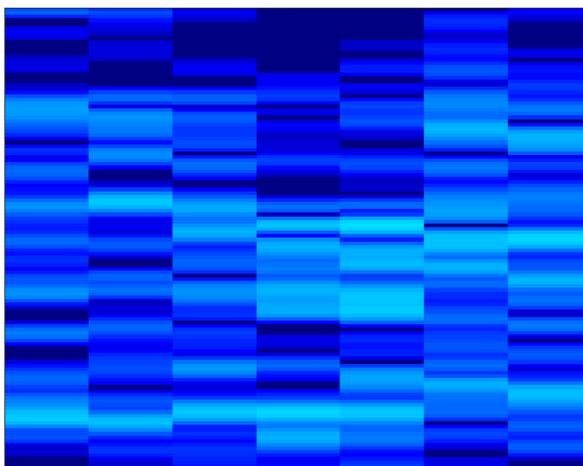


**Figura 4.7**  
*Espectrograma ventana Evento*

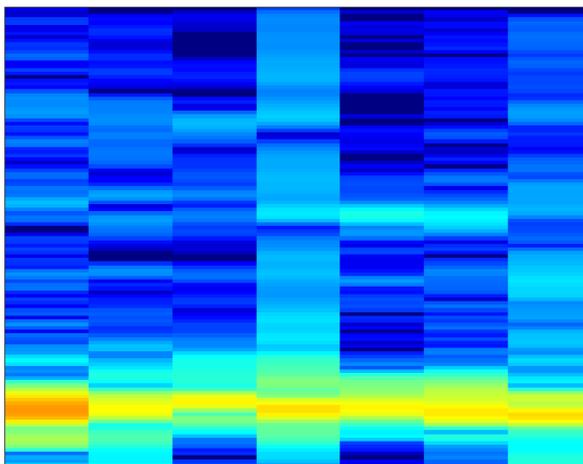


En la Fig. 4.8 y en la Fig. 4.9 se presenta la función espectrograma de la señal  $\widehat{s}[n]$ .  
En las Fig. 4.6, 4.7, 4.8 y 4.9 no se presentan valores en los ejes ( $x$  tiempo (0 a 5  $s$ ) y  $y$  frecuencia (0 a 25  $Hz$ )), para ejemplificar las imágenes de entrenamiento.

**Figura 4.8**  
*Espectrograma ventana No Evento (Deconvolución)*



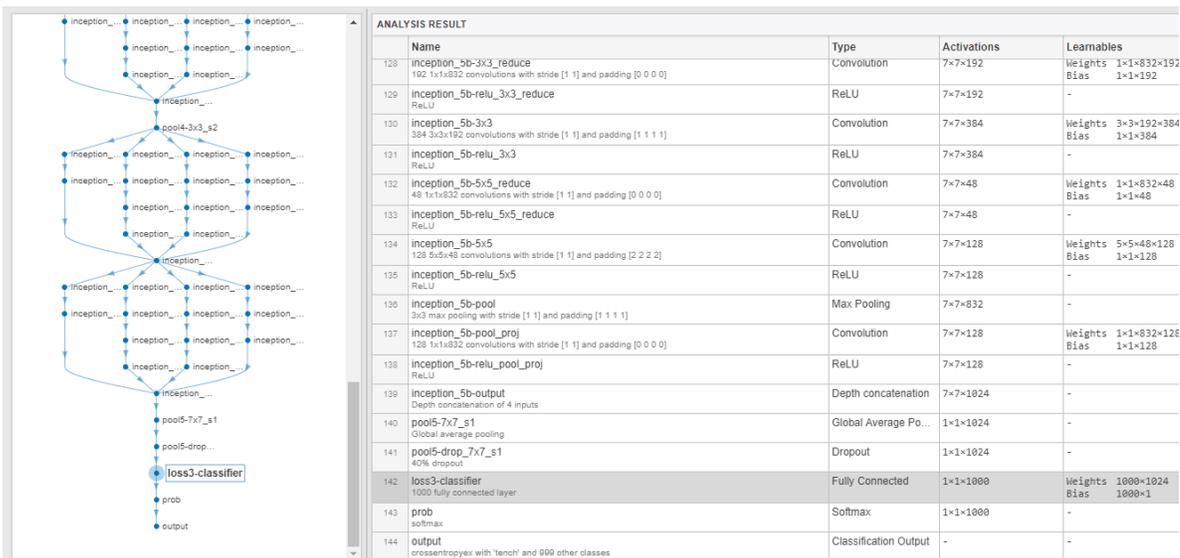
**Figura 4.9**  
*Espectrograma ventana Evento (Deconvolución)*



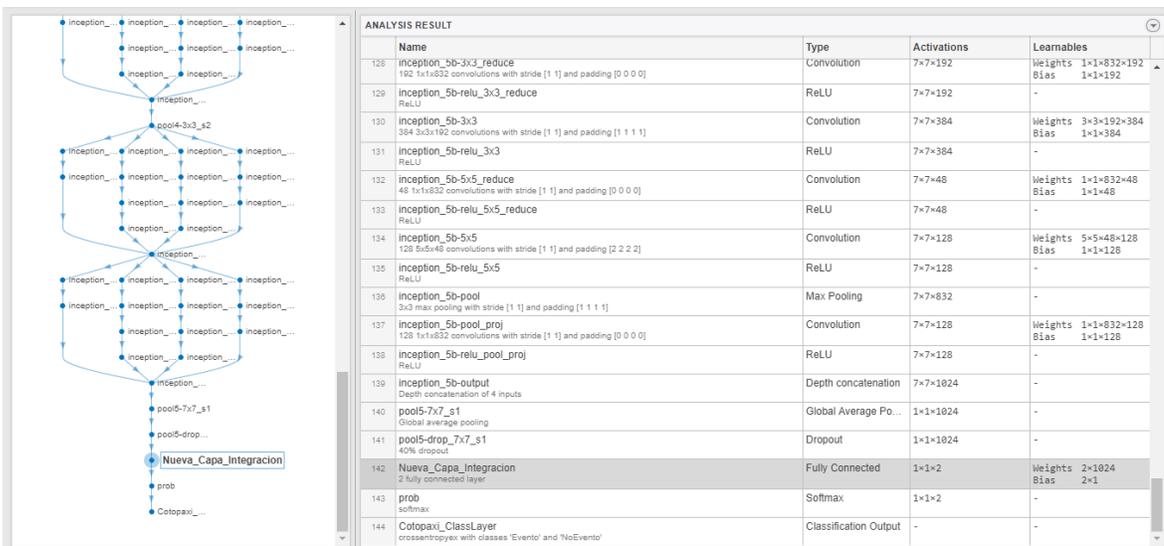
### **Evaluación**

Para desarrollar la detección basada en CNN se elige la red pre-entrenada GoogLeNet debido a los resultados presentados en [32], para realizar la transferencia de aprendizaje se modifica las 3 capas finales de la red, las capas finales son: capa totalmente conectada, capa softmax, capa salida de clasificación esto se observa en la Fig. 4.10.

**Figura 4.10**  
Capas GoogLeNet



**Figura 4.11**  
Capas GoogLeNet Modificado



En la Fig. 4.11, se observa las nuevas capas modificadas preparadas para entrenar los pesos sinápticos, de las capas modificadas, con dimensión 2 y etiquetas Evento - No Evento. Los parámetros de entrenamiento son presentados en [32].

**Figura 4.12**  
Matriz de confusión, GoogLeNet entrenada con  $r[n]$

		GOOGLENET		
Output Class	Evento	41 40.2%	2 2.0%	95.3% 4.7%
	NoEvento	10 9.8%	49 48.0%	83.1% 16.9%
		80.4% 19.6%	96.1% 3.9%	88.2% 11.8%
		Evento	NoEvento	
		Target Class		

**Figura 4.13**  
Matriz de confusión, GoogLeNet entrenada con  $\hat{s}[n]$

		GOOGLENET Deconvolución		
Output Class	EventoHomo	43 42.2%	1 1.0%	97.7% 2.3%
	NoEventoHomo	8 7.8%	50 49.0%	86.2% 13.8%
		84.3% 15.7%	98.0% 2.0%	91.2% 8.8%
		EventoHomo	NoEventoHomo	
		Target Class		

Para evaluar el desempeño del detector C2N, se realizan pruebas entrenando la red con espectrogramas a partir de  $r[n]$ , y también se prueba con espectrogramas a partir

de  $\widehat{s}[n]$ , para mitigar la influencia de la base de datos de espectrogramas (imágenes), se genera espectrogramas que tanto para  $r[n]$  y para  $\widehat{s}[n]$ , corresponden al mismo segmento de la señal.

Para el entrenamiento se dispone de un conjunto de 680 imágenes, divididas en dos grupos 340 imágenes de eventos, y 340 imágenes sin la presencia de eventos sísmicos, con esta pequeña base de datos se generan tres conjuntos para entrenamiento, validación y prueba. El conjunto de entrenamiento posee 510 imágenes, validación 68 y para evaluación 102 imágenes [56]. Para generar esta base de datos, se evitó el solapamiento, y se buscó que las señales estén distanciadas en tiempo en el registro original, para evitar la existencia de correlación entre los espectrogramas.

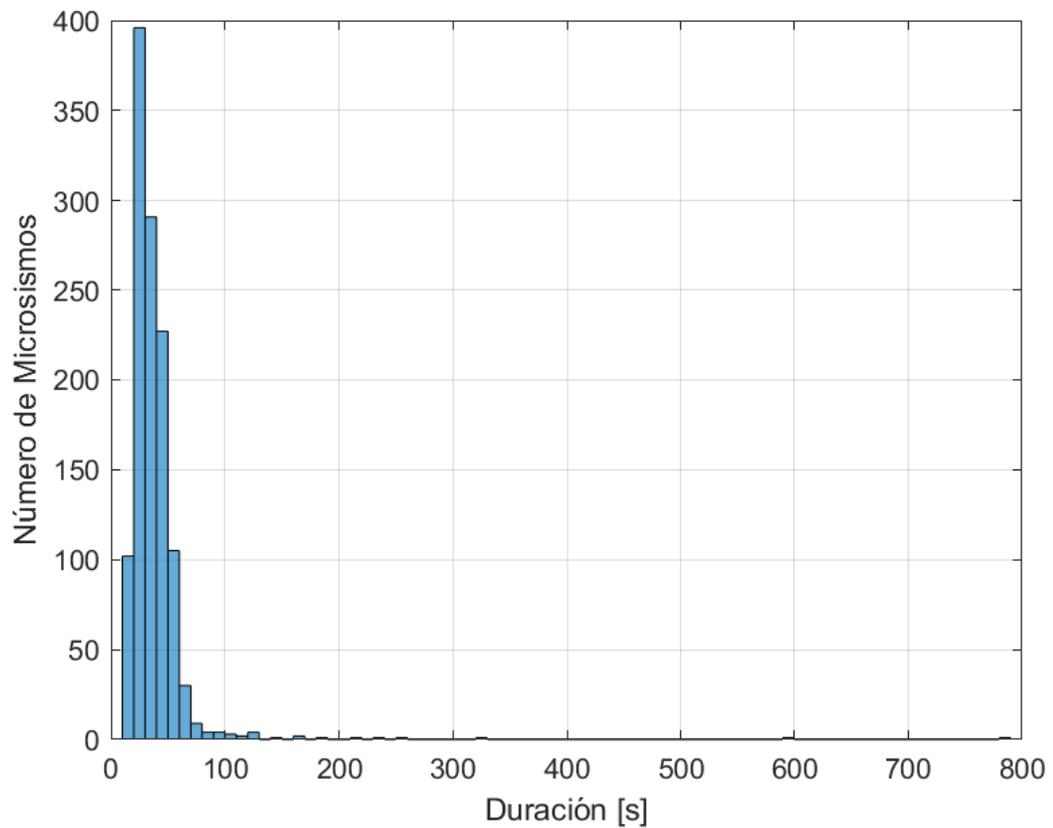
Luego de entrenar la red y el proceso de validación, se evaluó la red, y se obtuvieron las métricas presentadas en la Fig. 4.12 y Fig 4.13, a partir de la matriz de confusión se obtienen las métricas de desempeño presentadas en la Tabla 4.2.

**Tabla 4.2**  
*Métrica de detección C2N*

<b>Parámetros</b>	<b>C2N <math>r[n]</math></b>	<b>C2N <math>\widehat{s}[n]</math></b>
Exactitud	88,20 %	91,2 %
Precisión	95,35 %	97,73 %
Sensibilidad	80,39 %	84,31 %
Especificidad	96,08 %	98,04 %
BER	0,118	0,088

En la Tabla 4.2, se observa que el uso de la deconvolución homomórfica incrementa el desempeño del detector basado en CNN, también es importante destacar que la Tabla 4.2 presenta el desempeño en detección por ventana, y que la reducción de desempeño frente a [32], se debe a la reducción del tamaño de la ventana de 15 segundos a 5 segundos, para encontrar la probabilidad de detección por microsismos volcánicos, se debe conocer la duración de los eventos, esto se presenta en la Fig. 4.14, donde se tiene una duración mínima de 12 segundos, duración media 38 segundos y máxima de 790 segundos.

**Figura 4.14**  
*Histograma duración microsismos volcánicos*



Considerando la duración mínima de 12 segundos, se tiene que con ventanas de 5 segundos y solapamiento de 4 segundos, se tiene al menos 6 ventanas por evento, por lo cual, para calcular la probabilidad de detección se tiene la Ec. (4.19), donde se obtiene una  $P_d = 99\%$ .

$$P_d = 1 - \prod_{n=1}^{N_w} (1 - S_e) \quad (4.19)$$

donde,  $N_w$  es el número de ventanas, y  $S_e$  la sensibilidad por ventana.

En el siguiente capítulo, se presenta la descripción del clasificador propuesto, con el clasificador se completan las tres etapas del sistema de reconocimiento de microsismos, la etapa de clasificación se basa en redes neuronales convolucionales, se utiliza una base

de datos de 1187 eventos para el entrenamiento y evaluación de la red; adicionalmente, se realiza un análisis espectral de los diferentes tipos de microsismos para con esa información mejorar el proceso de generación de espectrogramas utilizados como entrada en las CNN.

## Clasificación

### Análisis en Frecuencia

Para el análisis en frecuencia se plantea obtener la representación en frecuencia de cada evento de la base de datos [9], [57] con el periodograma de Welch (Ec. (3.26)), y de este extraer las 10 componentes principales de frecuencia o las componentes con mas energía, esto se ve en la Ec. (5.1), y de la matriz  $F_{Pr}$  se obtiene el histograma, representando las componentes de mayor ocurrencia dentro del conjunto de datos, por lo que, con esto se representa a las componentes en frecuencia principales y mas relevantes dentro de la base de datos, permitiendo conocer las bandas de frecuencia de cada tipo de evento sísmico.

$$F_{Pr}^{(q)}(f_{max}) = \max_{10}(\bar{P}_w(f, q)) \quad (5.1)$$

donde,  $q$  es el número de evento dentro del conjunto de análisis,  $\max_{10}(x)$  función para extraer los 10 elementos máximos y  $\bar{P}_w(f, q)$  la matriz con las representaciones en frecuencia del conjunto de datos.

Con la técnica descrita en el párrafo anterior se plantea analizar dos conjuntos de datos de eventos sísmicos, el primer evento corresponde al utilizado del Volcán Cotopaxi [9], que contiene 1187 eventos, distribuidos de la siguiente forma:

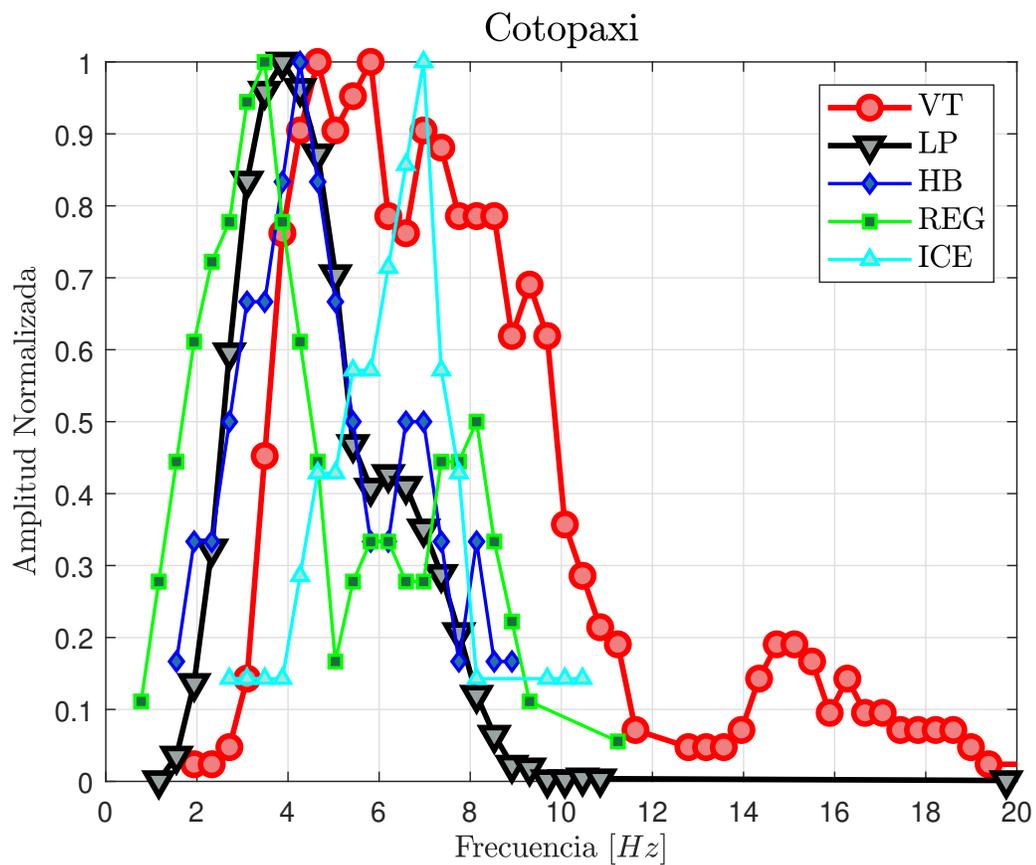
- 1044 - LP
- 101 - VT
- 27 - Regionales
- 8 Híbridos
- 7 - Icequake

Y para tener un marco de comparación se analiza la base de datos del Volcán Llaima (Chile) [57], esta base de datos contiene 3592 eventos sismo volcánicos, los eventos se encuentran distribuidos de la siguiente manera:

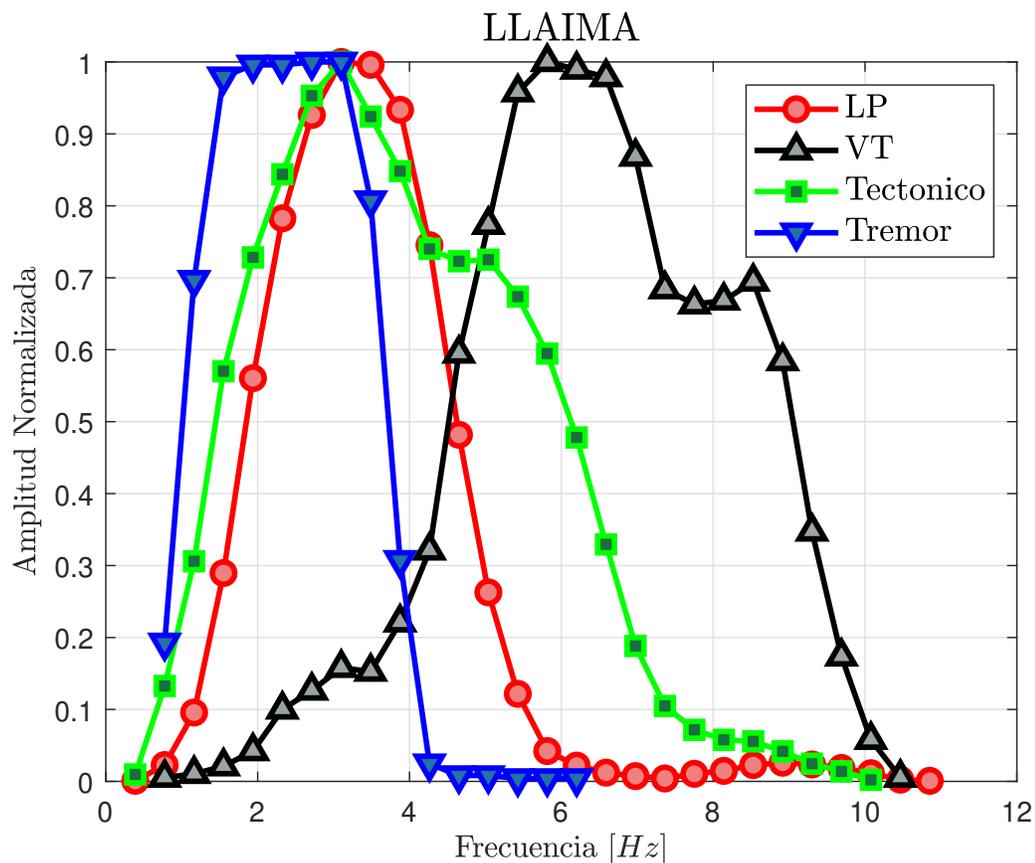
- 1310 - LP
- 304 - VT
- 490 - Tremor
- 1488 - Tectónicos (No volcánico)

Las dos bases de datos tienen una frecuencia de muestreo  $F_s = 100Hz$ , luego de analizar cada tipo de microsismo de la base de datos del Volcán Cotopaxi, se obtiene la Fig. 5.1, donde se observa la banda en frecuencia para cada tipo de microsismo. Y el conjunto de señales del Volcán Llaima luego de analizarse se presenta en la Fig. 5.2.

**Figura 5.1**  
*Histograma de componentes principales de frecuencia Volcán Cotopaxi*



**Figura 5.2**  
*Histograma de componentes principales de frecuencia Volcán Llaima*



**Tabla 5.1**  
*Análisis en frecuencia por tipos de microsismo Volcán Cotopaxi*

Evento	Inicial	Final
LP	2,1Hz	5,9Hz
VT	3,5Hz	10Hz
Híbrido	2,1Hz	7,5Hz
Regional	1,7Hz	8,2Hz
Icequake	4,9Hz	8Hz

**Tabla 5.2**  
*Análisis en frecuencia por tipos de microsismo Volcán Llaima*

<b>Evento</b>	<b>Inicial</b>	<b>Final</b>
LP	1,8Hz	4,5Hz
VT	4,3Hz	9,2Hz
Tremor	0,9Hz	3,9Hz
Tectónico	1,2Hz	6,2Hz

La Tabla 5.1, presenta las bandas de frecuencia de los eventos LP, VT, Regional, Híbrido y Icequake del Volcán Cotopaxi, obtenido de la Fig. 5.1, donde se denota que los eventos VT tiene un mayor ancho de banda que los eventos LP, y también una presencia en frecuencias superiores hasta 11Hz; por otra parte, la Tabla 5.2, muestra la banda de frecuencia para los eventos LP, VT, Tremor y Tectónico del Volcán Llaima, estos valores se obtienen de la Fig. 5.2.

Para comparar los valores obtenidos, con los valores característicos (Tabla 2.1), se utiliza la Tabla 5.1 y la Tabla 5.2, con eso se genera la Tabla 5.3, considerando las bandas características de los eventos LP se encuentran dentro de la región típica, aunque como se menciona anteriormente cada volcán presenta un comportamiento distinto, por lo que, a pesar de estar en la banda característica existen diferencias en la banda de frecuencia, al comparar los eventos LP del Volcán Cotopaxi con los eventos LP del Volcán Llaima, se observa que los eventos en el Cotopaxi tienen registros 1.4Hz superiores a los del Volcán Llaima, los registros de eventos LP del Volcán Cotopaxi son ligeramente superiores (0.9 Hz) a las bandas típicas presentadas en capítulos anteriores; esto sucede también con los eventos VT, donde el Volcán Cotopaxi presenta 0.8Hz más como frecuencia máxima, respecto al Volcán Llaima, los dos se encuentran dentro de las frecuencias típicas.

**Tabla 5.3**  
Análisis en frecuencia por tipos de microsismo

Evento	Volcán Cotopaxi	Volcán Llaima	Característico
LP	2,1 – 5,9Hz	1,8 – 4,5Hz	1 – 5Hz
VT	3,5 – 10Hz	4,3 – 9,2Hz	5 – 15Hz
Tremor	-	0,9 – 3,9Hz	2 – 3Hz
Icequake	4,9 – 8Hz	-	1 – 10Hz

### Generación de Espectrogramas

Para la generación de espectrogramas, para la clasificación de micro eventos sísmicos se plantea utilizar como función de generación, la función periodograma, con distintas funciones de ventana con la intención de resaltar las frecuencias que distingue un tipo de evento de otro, y atenuar las frecuencias comunes, en este caso las frecuencias comunes entre eventos LP y VT están en las bandas de (3,5 – 5,9Hz y 10 – 25Hz, Tabla 5.1).

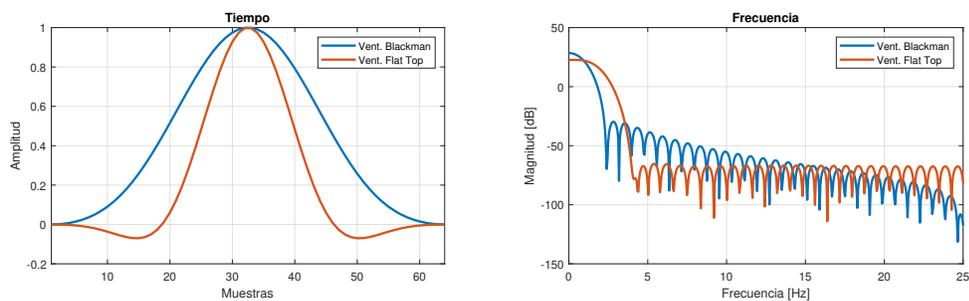
Con esto se plantea utilizar dos funciones de ventana [32], la función Blackman Ec. (5.2) [37] y la función FlatTop Ec. (5.3) [58], la función Blackman presenta un lóbulo principal más angosto y una diferencia entre el lóbulo principal y el lóbulo secundario de 60dB, mientras, la función de ventana Flat Top presenta un lóbulo principal mucho más amplio, y una relación lóbulo principal a lóbulo secundario de 80dB, y también existe una diferencia en la ganancia del lóbulo principal, donde la ventana de Blackman tiene 6dB más en el lóbulo principal respecto a la ventana de Flat Top. Todo lo descrito en este párrafo se presenta en la Fig. 5.3.

$$w_B[n] = 0,42 - 0,5\cos\left(\frac{2\pi n}{L-1}\right) + 0,08\cos\left(\frac{4\pi n}{L-1}\right) \quad (5.2)$$

$$w_{FT}[n] = \alpha_0 - \alpha_1\cos\left(\frac{2\pi n}{L-1}\right) + \alpha_2\cos\left(\frac{4\pi n}{L-1}\right) - \alpha_3\cos\left(\frac{6\pi n}{L-1}\right) + \alpha_4\cos\left(\frac{8\pi n}{L-1}\right) \quad (5.3)$$

**Figura 5.3**

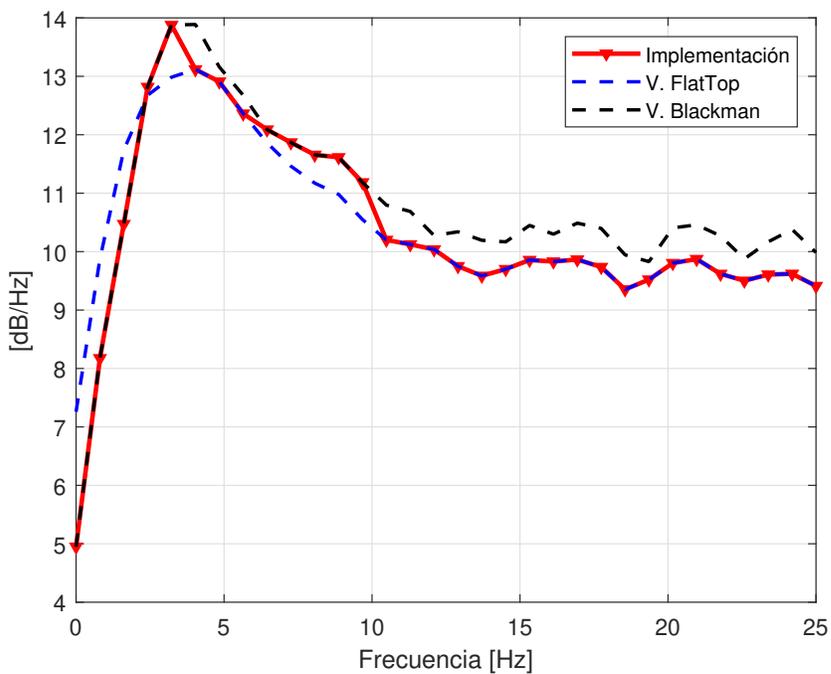
Análisis ventanas Blackman - Flat Top: a) Tiempo - Se las ventanas en tiempo, b) Frecuencia - Se presenta análisis en frecuencia de las ventanas



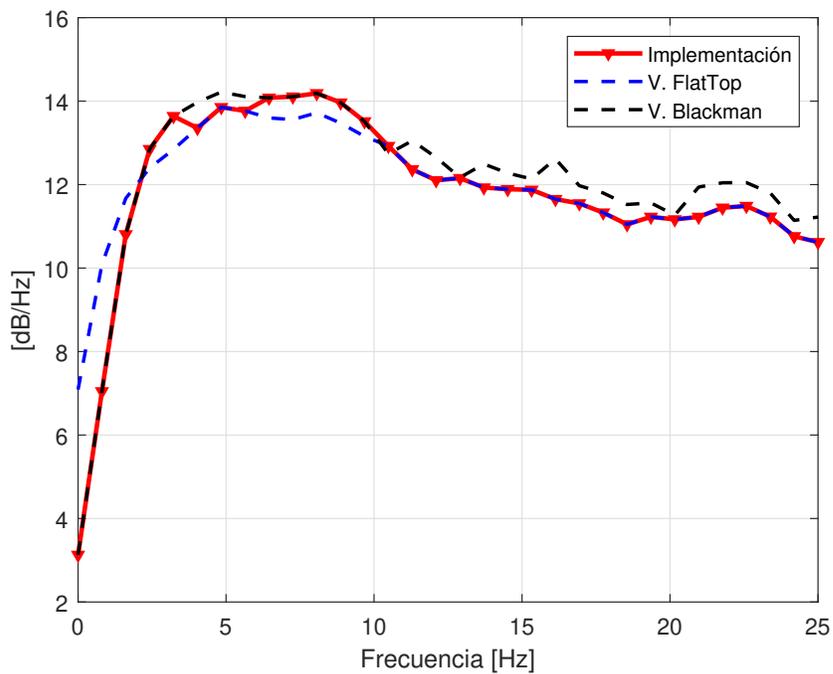
Se usa la función de ventana FlatTop para generar periodograma en las bandas de frecuencia que tienen en común los eventos VT y LP, ya que esta función tiene una menor ganancia, y en las frecuencias distintas o de interés entre los dos eventos se utiliza la función de ventana Blackman.

**Figura 5.4**

Periodograma microsismo LP

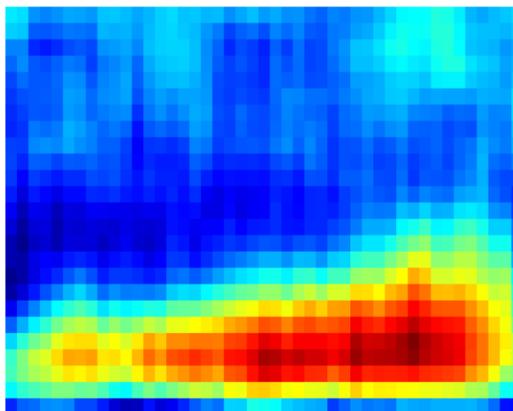


**Figura 5.5**  
*Periodograma microsismo VT*

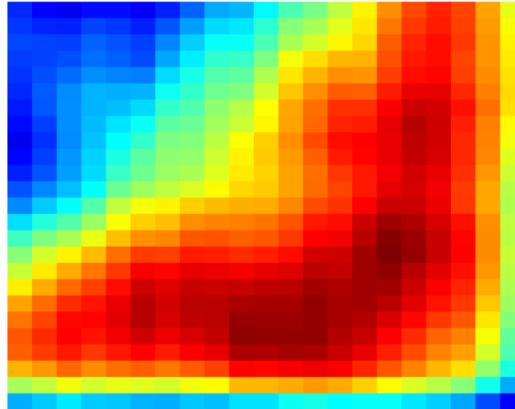


En las Fig. 5.4 y Fig. 5.5 se presenta los periodogramas de eventos LP y VT, respectivamente, con las ventanas Blackman y FlatTop, y en rojo la función periodograma que se toma, para la generación de espectrogramas.

**Figura 5.6**  
*Espectrograma microsismo LP*



**Figura 5.7**  
*Espectrograma microsismo VT*



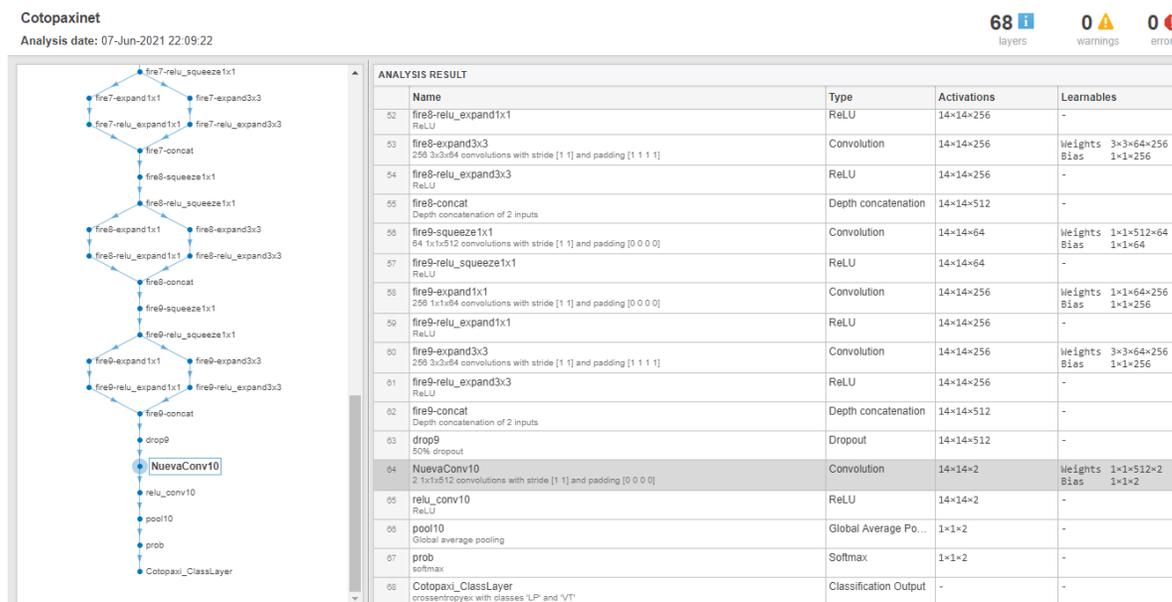
Con la técnica presentada en los párrafos anteriores, se genera espectrogramas de eventos LP y VT, para su clasificación, un ejemplo de estos espectrogramas se presenta en la Fig. 5.6 y Fig. 5.7, la escala del eje  $x$  es tiempo, el tiempo depende de las etiquetas de inicio y fin dadas por el detector [32], y el eje  $y$  es la frecuencia de  $0-25\text{Hz}$ , no se presenta los ejes directamente en las figuras para ilustrar las imágenes usadas para el entrenamiento. También, se utiliza un proceso de suavizado de los espectrogramas utilizando un ventana móvil, y con esto, mejorar el proceso de clasificación.

En los espectrogramas presentados, se puede diferenciar los eventos VT y LP con los niveles de energía al inicio del evento, y las bandas de frecuencia que conforman los eventos.

### **Evaluación**

Como se realiza en detección, para utilizar la red pre entrenada y entrenarla para realizar la tarea de clasificación permitiendo un ajuste fino se modifican 3 capas de la red SqueezeNet: Capa convolucional, capa softmax y capa de salida [32]. Esto se observa en la Fig. 5.8, donde se presenta una descripción de las últimas capas de la red neuronal y sus correspondientes dimensiones, y en la sección izquierda se presenta una ilustración gráfica de las últimas capas de la red neuronal.

**Figura 5.8**  
Entrenamiento SqueezeNet



Para evaluar el desempeño de la CNN para clasificación de eventos sísmicos se plantean dos escenarios de entrenamiento, primero considerando un entrenamiento balanceado, es decir, igual número de elementos por etiqueta y un conjunto no balanceado, donde, la cantidad de elementos por etiqueta no son iguales.

El conjunto de entrenamiento balanceado esta formado por 50 % de eventos LP y 50 % VT, teniendo un total de 202 registros divididos en tres conjuntos de datos: conjunto de datos de prueba 80 eventos, conjunto de entrenamiento 102 eventos y conjunto de validación 20 eventos, por otra parte, el conjunto de entrenamiento no balanceado esta formado por 303, incrementando el número de eventos LP por tener una mayor frecuencia de aparición, se tiene 202 eventos LP y 101 eventos VT, es decir, una distribución de 66,67 % LP y 33,33 % VT. De igual forma este conjunto se divide en tres subconjuntos: Conjunto de pruebas 121 eventos, conjunto de entrenamiento 152 eventos y validación 30 eventos. Para reducir la influencia del tamaño del conjunto de datos y solo comprobar el desempeño al probar un conjunto de datos balanceado y no balanceado, se hace una prueba entrenando con un conjunto de datos no balanceado y evaluando con uno balanceado.

**Figura 5.9**  
Matriz de confusión balanceado

**SQUEEZENETNET**

Output Class	LP	39 48.8%	4 5.0%	90.7% 9.3%
	VT	1 1.3%	36 45.0%	97.3% 2.7%
		97.5% 2.5%	90.0% 10.0%	93.8% 6.3%
		↵	↵	Target Class

**Figura 5.10**  
Matriz de confusión No balanceado

**SQUEEZENETNET**

Output Class	LP	81 66.9%	3 2.5%	96.4% 3.6%
	VT	0 0.0%	37 30.6%	100% 0.0%
		100% 0.0%	92.5% 7.5%	97.5% 2.5%
		↵	↵	Target Class

**Figura 5.11**  
Matriz de confusión No balanceado (Prueba Balanceada)

**SQUEEZENETNET**

Output Class	LP	38 47.5%	0 0.0%	100% 0.0%
	VT	2 2.5%	40 50.0%	95.2% 4.8%
		95.0% 5.0%	100% 0.0%	97.5% 2.5%
		↵	↵	Target Class

Luego de entrenar las CNN y evaluar su desempeño se obtiene la matriz de confusión Fig. 5.9 Y Fig. 5.10. Y de la segunda prueba entrenando con un conjunto no balanceado y evaluando con un conjunto balanceado se presenta en la Fig. 5.11.

Para tener métricas de evaluación entre los 3 procesos se calcula las métricas presentadas en capítulos anteriores exactitud, precisión, sensibilidad y BER, esto se presenta en la Tabla 5.4, donde se ve que al entrenar la CNN con un mayor número de elementos así el conjunto sea desbalanceado se tiene un mejor desempeño, presentando un incremento de 3,79 % en la exactitud y un BER 60 % menor, es importante destacar que al utilizar transferencia de aprendizaje para entrenar con un menor número de elementos, pequeñas variaciones en la cantidad de elementos y su calidad influyen considerablemente en el resultado de los experimentos.

**Tabla 5.4**  
*Métrica de clasificación C2N*

<b>Parámetros</b>	<b>Balanceado</b>	<b>No Balanceado</b>	<b>No Balanceado (Conj. prueba Bal.)</b>
Exactitud	93,8 %	97,5 %	97,5 %
Precisión	90,70 %	96,43 %	100,0 %
Sensibilidad	97,50 %	100,0 %	95,00 %
Especificidad	90,00 %	92,50 %	100,0 %
BER	0,0625	0,0375	0,0250

### **Evaluación Múltiples Etiquetas**

La metodología propuesta tiene la capacidad de clasificar múltiples etiquetas, siempre que haya sido entrenado previamente, en este caso la base de datos disponible del Volcán Cotopaxi, es insuficiente para clasificar múltiples eventos, por lo que, para probar la capacidad de la metodología de reconocer múltiples tipos de eventos se entrena la CNN SqueezeNet, con espectrogramas del Volcán Llaima, generados con la misma técnica utilizada para generar los espectrogramas del Volcán Cotopaxi.

Con esto se entrena la red separando el conjunto de espectrogramas en tres subconjuntos entrenamiento (1796 eventos), validación (359 eventos) y prueba (1437 even-

tos), con esto luego de entrenar y evaluar el sistema para las etiquetas LP, TC, TR y VT se obtiene un 95,5 % de exactitud, esto se observa en la Fig. 5.12.

**Figura 5.12**  
*Matriz de confusión No balanceado Volcán Llaima*

SQUEEZENETNET					
Output Class	LP	TC	TR	VT	
	LP	503 35.0%	2 0.1%	2 0.1%	11 0.8%
TC	7 0.5%	576 40.1%	7 0.5%	4 0.3%	97.0% 3.0%
TR	6 0.4%	4 0.3%	187 13.0%	0 0.0%	94.9% 5.1%
VT	8 0.6%	13 0.9%	0 0.0%	107 7.4%	83.6% 16.4%
	96.0% 4.0%	96.8% 3.2%	95.4% 4.6%	87.7% 12.3%	95.5% 4.5%
	LP	TC	TR	VT	
	Target Class				

En la Fig. 5.12, se puede observar que el mayor error cometido por la CNN, es la correcta clasificación de eventos VT, de los 122 eventos VT, utilizados para evaluar la CNN, 11 eventos son etiquetados de forma incorrecta como eventos LP. Y la exactitud mayor se encuentra en los eventos TC (No volcánicos) con un 96,8 % de aciertos, por lo que, el sistema es robusto para distinguir eventos de origen volcánico de eventos tectónicos.

La exactitud del 95,5 % en clasificación de múltiples etiquetas da una muestra de la capacidad de clasificación de eventos volcánicos de diferentes tipos, si se tiene el mínimo de datos etiquetados por evento. Frente al sistema de dos etiquetas (LP-VT) del sistema propuesto para el Volcán Cotopaxi, se tiene una reducción de 2 % en la exactitud al incrementar dos etiquetas, es importante mencionar que el conjunto de datos del Volcán Llaima posee una mayor cantidad de registros, lo que aporta significativamente a mantener la exactitud alta.

En el siguiente capítulo, se describe los detalles del software realizado con los algo-

ritmos de pre entrenamiento, detección y clasificación, que en conjunto forman el software diseñado *Ariq Kuyuy*, que se probará en el IGEPN para realizar análisis de registros sísmicos del Volcán Cotopaxi.

## Software

En el presente capítulo se presenta una breve descripción del software desarrollado para analizar microsismos, el cual cuenta con los algoritmos descritos en los capítulos anteriores. El software está desarrollado en MATLAB App Designer [59]. Esta contribución parte de la presente tesis permite adicionalmente dejar en evidencia que las propuestas científicas planteadas en la Maestría de Investigación en Electrónica mención Telecomunicaciones del Departamento de Eléctrica, Electrónica y Telecomunicaciones de la Universidad de las Fuerzas Armadas ESPE van a servir para que en el IGEPN, se analicen registros sísmicos generados por los distintos sensores ubicados en el Volcán Cotopaxi, como resultado del análisis de la información de los sensores se podría buscar posible correlación entre eventos sismo volcánicos y procesos pre eruptivos, además de buscar posibles nuevos tipos de eventos sísmicos presentes en el volcán Cotopaxi como eventos de muy largo periodo (VLP, del inglés *Very Long Period*).

### Funciones

- **creacionColeccionEventos** - genera un objeto `evento sísmico`, para almacenar el archivo en el que se encuentra un evento, muestra inicial, muestra final, tiempo, tipo de evento entre otros.
- **rdmseed** - Función para la lectura de archivos `*.mseed`
- **stringArchivo** - Genera todos los nombres de archivos de la colección a procesar
- **downSampling** - Se reduce la frecuencia de muestreo eliminando las muestras pares del registro original.
- **homomorfico** - Requiere como atributo una señal  $r[n]$  y retorna una señal  $\hat{s}[n]$
- **detectorHomomorfico** - Contiene el algoritmo STA/LTA modificado
- **ECM\_PDS** - Devuelve la RSME de una señal  $\hat{s}[n]$

- **periodograma\_N** - Retorna una matriz con el espectrograma de la señal ingresada, este espectrograma se genera con las funciones de ventana explicadas en capítulos anteriores, también se requiere un lista de frecuencias de interés

## Interfaz

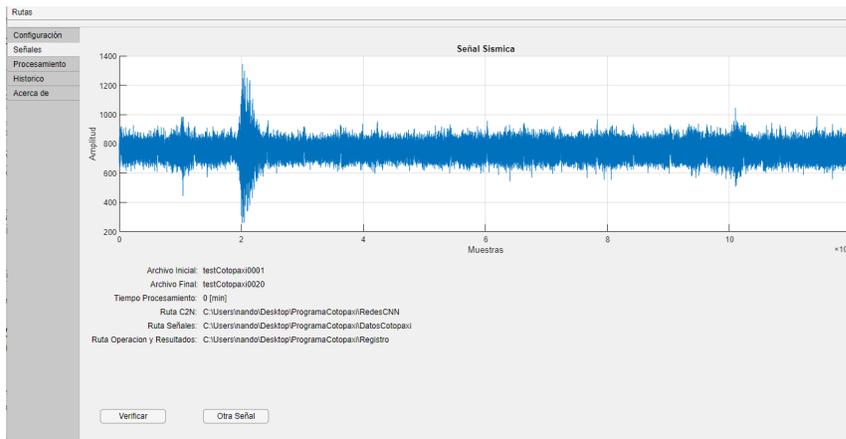
En la pantalla principal o de configuración (Fig. 6.1), se muestra varias opciones del sistema destacando la capacidad de procesamiento de colecciones de archivos, en formato \*.mat (Nativo Matlab) y \*.seed (Formato estándar de intercambio de datos de microsismos) [60]. El sistema cuenta con un modo de operación rápido que inhabilita todas las animaciones gráficas para la detección de microsismos.

El formato utilizado para cargar las redes neuronales es \*.mat o \*.onnx [61], que es un formato estándar, por lo que, se podría cargar redes entrenadas en otros lenguajes como Python o R.

**Figura 6.1**  
*Pantalla principal Software Ariq Kuyuy*

La pantalla de verificación presentada en la Fig. 6.2, es una pantalla que comprueba la correcta lectura de la señal o la colección de señales a procesar, en el caso de una correcta lectura se gráfica la primera señal de la colección, y se muestra la descripción de la colección de archivos a leer.

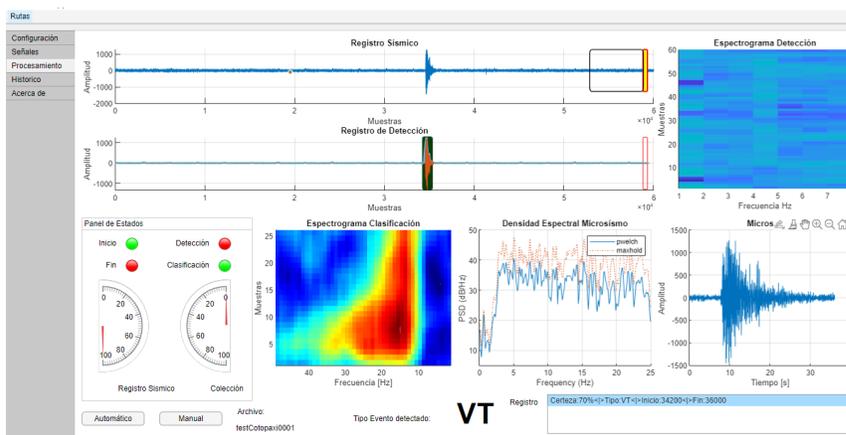
**Figura 6.2**  
Pantalla de Verificación Ariq Kuyuy



En la Fig. 6.3, se ilustra la ventana de operación, donde se grafica el espectrograma de la ventana de detección, la señal con procesamiento homomórfico, la señal del registro cargado, luego de la detección de eventos se presenta la gráfica del espectrograma, periodograma de Welch y eventos sísmico en tiempo.

Finalmente, luego del análisis de datos el software muestra en una tabla el resultado del reconocimiento de eventos, esta tabla puede ser almacenada en formato \*.xlsx o \*.dat (Fig. 6.4).

**Figura 6.3**  
Pantalla de Operación Ariq Kuyuy



**Figura 6.4**  
**Pantalla de Registro Ariq Kuyuy**

Configuración		Datos de microsismos reconocidos					
Señales		Inicio	Fin	Tipo	Duración	Archivo	Número
Historico		0	0	ND	0	NA	0
Acerca de		34200	36000	VT	36	testCotopaxi0001	1
		54600	56400	LP	36	testCotopaxi0002	1
		9500	11600	LP	40	testCotopaxi0003	1
		36200	38300	LP	42	testCotopaxi0004	1
		20300	22400	VT	42	testCotopaxi0005	1

Estado 

En los dos últimos capítulos se presentan las conclusiones y recomendaciones producto del desarrollo de la presente tesis, en las cuales se resalta las contribuciones y desempeño del sistema propuesto.

Adicionalmente, se presenta en la sección Apéndice, el manual de usuario del software desarrollado, el cual, fue denominado *Ariq Kuyuy*, por las palabras Quechuas *Ariq* - Volcán y *Kuyuy* - Movimiento.

## Conclusiones

Con la etapa de preprocesamiento, destacando el uso de la deconvolución homomórfica incrementa la SNR teniendo una ganancia de  $10,5dB$  o un incremento del  $77\%$ , esto hace que se mejore la detección de microsismos y descubrir microsismos de baja energía que están ocultos en el ruido, estos microsismos puede ser de ayuda en trabajos en los que se busque entender el comportamiento sísmico de un volcán antes de un proceso eruptivo. Es posible que la técnica de deconvolución homomórfica permita descubrir nuevos eventos sísmicos o nuevos tipos de eventos como eventos VLP - Eventos largos LP.

No se tiene alteraciones en frecuencia al aplicar la deconvolución homomórfica, se tiene una ligera reducción en el nivel de energía de toda la banda, esto se debe a la mitigación del ruido que esta presente en todas las bandas de frecuencia.

El detector **MarGra** (nombre dado por el autor) propuesto basado en una modificación del clásico STALTA presenta una exactitud de  $99,31\%$  y un BER de  $0,01179$ , lo cual, se encuentra dentro de los rangos exigidos por el IGEPN. Al utilizar como función  $g(x) = RMSE$ , se puede controlar la SNR de los eventos que se desea detectar, considerando que la ventana larga tiene ruido y la ventana corta el evento.

El detector C2N presenta una exactitud de  $88,20\%$  cuando se generan los espectrogramas con  $r[n]$ , y  $91,20\%$  cuando se usa  $\widehat{s}[n]$ , presentando una mejora de  $3,2\%$  al utilizar la deconvolución homomórfica. Además, al reducir el tamaño de ventana a  $5s$  y utilizar solapamiento se incrementa la probabilidad de detección de microsismos de  $91,20\%$  a  $99\%$ .

Al analizar los componentes en frecuencia de dos volcanes, ratifica que cada volcán tiene un comportamiento en particular, y conocer las componentes en frecuencia mejora la generación de espectrogramas para la clasificación automática de tipos de microsismos. La Tabla 5.1 permite conocer las frecuencias en las que se diferencian los diferentes tipos sísmicos.

Al realizar el proceso de entrenamiento de las CNN con un conjunto de datos no balanceado, se tiene una mejora en las métricas evaluadas, teniendo un incremento de 3,7 % en la exactitud, frente a los dos escenarios no balanceados planteados. Considerando esto para el software *Ariq Kuyuy*, se utiliza la CNN entrenada con el conjunto de datos no balanceado.

La técnica de transferencia de aprendizaje empleada, a partir de redes entrenadas con imágenes da como resultado un alta exactitud en la clasificación y detección de eventos sísmicos, por lo que, se valida la técnica como una alternativa para superar el problema de disponer de pocos registros para entrenar las redes.

Las CNN tienen un alto desempeño para clasificar eventos LP, cometiendo el mayor número de errores al etiquetar eventos VT como LP, esto se ve reflejado con la métrica de precisión (90,70 %, 96,43 % y 100,0 %). Por otra parte, los errores al etiquetar eventos LP como VT son significativamente menores, comparando la métrica de sensibilidad (97,50 %, 100,0 % y 95,00 %).

El sistema es robusto para clasificar múltiples etiquetas, si se mantiene el número mínimo de eventos para aplicar la técnica de transferencia de aprendizaje, en el caso probado al incrementar a 4 etiquetas (LP, TC, TR y VT) se tuvo un reducción de apenas el 2 %, frente al sistema de dos etiquetas presentado (LP - VT).

Finalmente, se concluye que el sistema cumple con las métricas requeridas por el IGEPN, por lo que, es aplicable al sistema de monitorización del Volcán Cotopaxi en las instalaciones del IGEPN, al ser un sistema basado en técnicas de aprendizaje de maquina, mientras mas datos se sigan obteniendo a través de su uso y de datos analizados por expertos se espera que el desempeño incremente.

## Recomendaciones

Al mejorar la SNR se tiene un mayor número de eventos de baja energía, por lo que, es importante utilizar información de varias estaciones para garantizar que sean sismos de origen volcánico, y no perturbaciones locales en la posición de los sensores. Es por esto, que se recomienda al menos el uso de la información de tres estaciones para garantizar que los sismos de baja energía sean producidos por procesos naturales del Volcán Cotopaxi, o cualquier otro donde se aplique esta técnica.

Con los resultados obtenidos, los dos detectores propuestos superan las métricas mínimas requeridas para aplicarlos en sistemas automáticos de reconocimiento, métricas dadas por el IGEPN, por lo cual, el factor determinante es el costo computacional, en este sentido al ser una aplicación que opera en quasi tiempo real, no es tan determinante, pero si se quiere tener una aplicación en tiempo real (muestra a muestra) se recomienda el uso de la modificación de STA/LTA.

Analizar las componentes de frecuencia de las bases de datos disponibles de distintos volcanes para extrapolar la metodología de clasificación de micro eventos presentada en este trabajo.

Realizar pruebas utilizando el proceso de deconvolución predictiva y comparar el posible incremento de SNR, con la propuesta de deconvolución homomórfica.

Integrar el sistema de reconocimiento propuesto, a otras tecnologías para permitir tener un sistema de alerta temprana automático que vigile al Volcán Cotopaxi.

Evaluar el desempeño de la transferencia de aprendizaje, transfiriendo el conocimiento de una red entrenada para un volcán a otro, con lo que se podría incrementar los conjuntos de datos al combinar señales de varios volcanes para el entrenamiento.

## Referencias

- [1] P. Mothes, *Actividad volcánica y pueblos precolombinos en el Ecuador*. Editorial Abya Yala, 1998.
- [2] M. Hall, P. Samaniego, J. Le Pennec y J. Johnson, "Ecuadorian Andes volcanism: A review of Late Pliocene to present activity," *Journal of Volcanology and Geothermal Research*, vol. 176, n.º 1, págs. 1-6, 2008.
- [3] O. Padilla y J. Bosque, "Determinación de puntos de evacuación vertical y horizontal en caso de una erupción del volcán cotopaxi en el Valle de los Chillos, Sangolquí, Ecuador," *Revista Geoespacial*, vol. 11, págs. 67-79, 2014.
- [4] E. Aguilera, M. Pareschi, M. Rosi y G. Zanchetta, "Risk from lahars in the northern valleys of Cotopaxi Volcano (Ecuador)," *Natural Hazards*, vol. 33, n.º 2, págs. 161-189, 2004.
- [5] S. McNutt y D. Roman, "Volcanic seismicity," en *The Encyclopedia of Volcanoes*, Elsevier, 2015, págs. 1011-1034.
- [6] J. Robert, R. D'Ercole, P. Pigeon y T. Serrano, "Complejidad, incertidumbre y vulnerabilidad: el riesgo asociado al volcán Cotopaxi en el Valle de los Chillos (Quito-Ecuador)," *Bulletin de l'Institut français d'études andines*, n.º 38 (3), págs. 709-733, 2009.
- [7] S. Carn, A. Krueger, S. Arellano, N. Krotkov y K. Yang, "Daily monitoring of Ecuadorian volcanic degassing from space," *Journal of Volcanology and Geothermal Research*, vol. 176, n.º 1, págs. 141-150, 2008.
- [8] B. Chouet, "Long-period volcano seismicity: its source and use in eruption forecasting," *Nature*, vol. 380, n.º 6572, págs. 309-316, 1996.
- [9] N. Pérez, D. Benítez, F. Grijalva, R. Lara-Cueva, M. Ruiz y J. Aguilar, "ESeismic: Towards an Ecuadorian volcano seismic repository," *Journal of Volcanology and Geothermal Research*, vol. 396, pág. 106 855, 2020.

- [10] C. Bean, L. De Barros, I. Lokmer, J. Métaixian, G. O'Brien y S. Murphy, "Long-period seismicity in the shallow volcanic edifice formed from slow-rupture earthquakes," *Nature Geoscience*, vol. 7, n.º 1, págs. 71-75, 2014.
- [11] A. Bell, M. Naylor, S. Hernandez, I. Main, H. Gaunt, P. Mothes y M. Ruiz, "Volcanic eruption forecasts from accelerating rates of drumbeat long-period earthquakes," *Geophysical Research Letters*, vol. 45, n.º 3, págs. 1339-1348, 2018.
- [12] A. Bell y C. Kilburn, "Trends in the aggregated rate of pre-eruptive volcano-tectonic seismicity at Kilauea volcano, Hawaii," *Bulletin of volcanology*, vol. 75, n.º 1, págs. 1-10, 2013.
- [13] R. White y W. McCausland, "Volcano-tectonic earthquakes: A new tool for estimating intrusive volumes and forecasting eruptions," *Journal of Volcanology and Geothermal Research*, vol. 309, págs. 139-155, 2016, ISSN: 0377-0273. DOI: <https://doi.org/10.1016/j.jvolgeores.2015.10.020>.
- [14] R. Ramis, A. Garcia, J. Marrero, S. De la Cruz, R. Carniel y J. Vila, "Volcanic and volcano-tectonic activity forecasting: a review on seismic approaches," *Annals of Geophysics*, vol. 62, n.º 1, pág. 06, 2019.
- [15] S. McNutt, "Observations and analysis of B-type earthquakes, explosions, and volcanic tremor at Pavlof Volcano, Alaska," *Bulletin of the Seismological Society of America*, vol. 76, n.º 1, págs. 153-175, feb. de 1986, ISSN: 0037-1106.
- [16] H. Langer, S. Falsaperla y G. Thompson, "Application of artificial neural networks for the classification of the seismic transients at Soufriere Hills volcano, Montserrat," *Geophysical research letters*, vol. 30, n.º 21, 2003.
- [17] J. Métaixian, S. Araujo, M. Mora y P. Lesage, "Seismicity related to the glacier of Cotopaxi Volcano, Ecuador," *Geophysical Research Letters*, vol. 30, n.º 9, 2003.
- [18] R. Lara, M. Rodriguez y J. Larco, "A real-time microearthquakes-detector based on voice activity detection and endpoint detection: An approach to Cotopaxi Volcano," *Journal of Volcanology and Geothermal Research*, pág. 106 867, 2020.

- [19] L. Rabiner y R. Schafer, *Theory and applications of digital speech processing*. Prentice Hall Press, 2010.
- [20] L. Marple Jr, *Digital spectral analysis*. Dover Publications, 2019.
- [21] W. Koenig, H. Dunn y L. Lacy, "The sound spectrograph," *The Journal of the Acoustical Society of America*, vol. 18, n.º 1, págs. 19-49, 1946.
- [22] S. Albawi, T. Mohammed y S. Al-Zawi, "Understanding of a convolutional neural network," en *2017 International Conference on Engineering and Technology (ICET)*, IEEE, 2017, págs. 1-6.
- [23] K. Murphy, *Machine learning: a probabilistic perspective*. MIT press, 2012.
- [24] J. Wu, "Introduction to convolutional neural networks," *National Key Lab for Novel Software Technology*, vol. 5, pág. 23, 2017.
- [25] M. Paluszek y S. Thomas, *MATLAB machine learning*. Apress, 2016.
- [26] K. O'Shea y R. Nash, "An introduction to convolutional neural networks," *arXiv preprint arXiv:1511.08458*, 2015.
- [27] M. Titos, A. Bueno, L. García, M. Benítez y J. Ibañez, "Detection and classification of continuous volcano-seismic signals with recurrent neural networks," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 57, n.º 4, págs. 1936-1948, 2018.
- [28] M. Titos, A. Bueno, L. García, C. Benítez y J. Segura, "Classification of isolated volcano-seismic events based on inductive transfer learning," *IEEE Geoscience and Remote Sensing Letters*, vol. 17, n.º 5, págs. 869-873, 2019.
- [29] M. Curilem, J. Canário, L. Franco y R. Rios, "Using cnn to classify spectrograms of seismic events from Llaima volcano (chile)," en *2018 International Joint Conference on Neural Networks (IJCNN)*, IEEE, 2018, págs. 1-8.
- [30] J. Woollam, A. Rietbrock, A. Bueno y S. De Angelis, "Convolutional neural network for seismic phase classification, performance demonstration over a local seismic network," *Seismological Research Letters*, vol. 90, n.º 2A, págs. 491-502, 2019.

- [31] S. Lapins, B. Goitom, J.-M. Kendall, M. J. Werner, K. V. Cashman y J. O. Hammond, "A little data goes a long way: automating seismic phase arrival picking at Nabro Volcano with transfer learning," *Journal of Geophysical Research: Solid Earth*, e2021JB021910, 2021.
- [32] F. Lara, R. Lara-Cueva, J. Larco, E. Carrera y R. León, "A deep learning approach for automatic recognition of seismo-volcanic events at the Cotopaxi volcano," *Journal of Volcanology and Geothermal Research*, vol. 409, pág. 107-142, 2021, ISSN: 0377-0273. DOI: <https://doi.org/10.1016/j.jvolgeores.2020.107142>. dirección: <https://www.sciencedirect.com/science/article/pii/S0377027320305783>.
- [33] F. Lara, R. Leon, R. Lara-Cueva, A. Tinoco y M. Ruiz, "Detection of volcanic microearthquakes based on homomorphic deconvolution and STA/LTA (En Revisión)," *Journal of Volcanology and Geothermal Research*, 2021, ISSN: 0377-0273.
- [34] S. Haykin, *Adaptive filter theory*. Pearson Education India, 2008.
- [35] A. Oppenheim, R. Schafer y J. Buck, *Tratamiento de señales en tiempo discreto*. Pearson Educación, 2011.
- [36] J. Sullivan, L. Crone y J. Jalickee, "Approximation of the unit step function by a linear combination of exponential functions," *Journal of Approximation Theory*, vol. 28, n.º 4, págs. 299-308, 1980, ISSN: 0021-9045. DOI: [https://doi.org/10.1016/0021-9045\(80\)90064-7](https://doi.org/10.1016/0021-9045(80)90064-7). dirección: <https://www.sciencedirect.com/science/article/pii/0021904580900647>.
- [37] A. Oppenheim, J. Buck y R. Schafer, *Discrete-time signal processing. Vol. 2*. Upper Saddle River, NJ: Prentice Hall, 2001.
- [38] S. Kay, *Fundamentals of statistical signal processing: Practical algorithm development*. Pearson Education, 2013, vol. 3.
- [39] S. Miller y D. Childers, *Probability and random processes: With applications to signal processing and communications*. Academic Press, 2012.

- [40] M. Withers, R. Aster, C. Young, J. Beiriger, M. Harris, S. Moore y J. Trujillo, "A comparison of select trigger algorithms for automated global seismic phase and event detection," *Bulletin of the Seismological Society of America*, vol. 88, n.º 1, págs. 95-106, 1998.
- [41] Y. Vaezi y M. Van der Baan, "Comparison of the STA/LTA and power spectral density methods for microseismic event detection," *Geophysical Supplements to the Monthly Notices of the Royal Astronomical Society*, vol. 203, n.º 3, págs. 1896-1908, 2015.
- [42] W. Swindell y N. Snell, "Station processor automatic signal detection system, phase i: Final report, station processor software development," *Texas Instruments Report No. ALEX (01)-FR-77-01, AFTAC Contract Number FO8606-76-C-0025, Texas Instruments Incorporated, Dallas, Texas, 1977.*
- [43] T. McEvelly y E. Majer, "ASP: An automated seismic processor for microearthquake networks," *Bulletin of the Seismological Society of America*, vol. 72, n.º 1, págs. 303-325, 1982.
- [44] P. Earle y P. Shearer, "Characterization of global seismograms using an automatic-picking algorithm," *Bulletin of the Seismological Society of America*, vol. 84, n.º 2, págs. 366-376, 1994.
- [45] O. Seryasat, F. Honarvar y A. Rahmani, "Multi-fault diagnosis of ball bearing using FFT, wavelet energy entropy mean and root mean square (RMS)," en *2010 IEEE international conference on systems, man and cybernetics*, IEEE, 2010, págs. 4295-4299.
- [46] L. Igual y S. Seguí, "Introduction to Data Science," en *Introduction to Data Science*, Springer, 2017, págs. 1-4.
- [47] R. Lara-Cueva, E. Carrera, J. Morejon y D. Benitez, "Comparative analysis of automated classifiers applied to volcano event identification," en *2016 IEEE Colombian conference on communications and computing (colcom)*, IEEE, 2016, págs. 1-6.

- [48] D. Marmanis, M. Datcu, T. Esch y U. Stilla, "Deep learning earth observation classification using ImageNet pretrained networks," *IEEE Geoscience and Remote Sensing Letters*, vol. 13, n.º 1, págs. 105-109, 2015.
- [49] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla y M. Bernstein, "Imagenet large scale visual recognition challenge," *International journal of computer vision*, vol. 115, n.º 3, págs. 211-252, 2015.
- [50] B. Zhou, A. Khosla, A. Lapedriza, A. Torralba y A. Oliva, "Places: An image database for deep scene understanding," *arXiv preprint arXiv:1610.02055*, 2016.
- [51] A. Krizhevsky, I. Sutskever y G. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, vol. 25, págs. 1097-1105, 2012.
- [52] F. Iandola, S. Han, M. Moskewicz, K. Ashraf, W. Dally y K. Keutzer, "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5 MB model size," *arXiv preprint arXiv:1602.07360*, 2016.
- [53] K. He, X. Zhang, S. Ren y J. Sun, "Deep residual learning for image recognition," en *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, págs. 770-778.
- [54] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke y A. Rabinovich, "Going deeper with convolutions," en *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, págs. 1-9.
- [55] R. Lara-Cueva, D. Benítez, E. Carrera, M. Ruiz y J. Rojo-Álvarez, "Feature selection of seismic waveforms for long period event detection at Cotopaxi Volcano," *Journal of Volcanology and Geothermal Research*, vol. 316, págs. 34-49, 2016.
- [56] A. Ng, "Machine learning yearning," URL: [http://www. mlyearning. org/\(96\)](http://www.mlyearning.org/(96)), vol. 139, 2017.

- [57] J. Canário, R. de Mello, M. Curilem, F. Huenupan y R. Rios, “Llaima volcano dataset: In-depth comparison of deep artificial neural network architectures on seismic events classification,” *Data in brief*, vol. 30, pág. 105 627, 2020.
- [58] G. D’Antona y A. Ferrero, *Digital signal processing for measurement systems: theory and applications*. Springer Science & Business Media, 2005, págs. 70-72.
- [59] N. Harun, H. Hambali, M. Hassan y K. Karim, *MATLAB APP Designer: Learn By Example*. UUM Press, 2017.
- [60] C. Trabant, T. Ahern y R. Benson, “IRIS perspectives on the future of the SEED format,” en *EGU General Assembly Conference Abstracts*, 2016, EPSC2016-10 684.
- [61] A. Shridhar, P. Tomson y M. Innes, “Interoperating Deep Learning models with ONNX.jl,” en *Proceedings of the JuliaCon Conferences*, vol. 1, 2020, pág. 59.