



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

**DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA**

**CARRERA DE INGENIERÍA EN ELECTRÓNICA Y  
TELECOMUNICACIONES**

**TRABAJO DE TITULACIÓN, PREVIO A LA  
OBTENCIÓN DEL TÍTULO DE INGENIERO EN  
ELECTRÓNICA Y TELECOMUNICACIONES**

**TEMA: EXTRACCIÓN DE CARACTERÍSTICAS DE  
SEÑALES SÍSMICAS EMPLEANDO WAVELETS**

**AUTOR: ENRÍQUEZ FUSTILLOS, JULIO ANDRÉS**

**DIRECTOR: ING. BERNAL OÑATE, CARLOS PAÚL  
SANGOLQUÍ**

**2017**

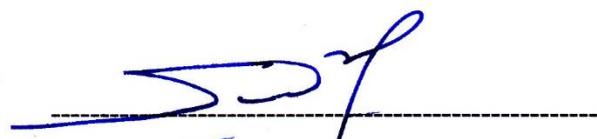


DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA  
CARRERA DE INGENIERÍA EN ELECTRÓNICA Y TELECOMUNICACIONES

### CERTIFICACIÓN

Certifico que el trabajo de titulación, “EXTRACCIÓN DE CARACTERÍSTICAS DE SEÑALES SÍSMICAS EMPLEANDO WAVELETS” realizado por el señor JULIO ANDRÉS ENRÍQUEZ FUSTILLOS, ha sido revisado en su totalidad y analizado por el software anti-plagio, el mismo cumple con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Universidad de Fuerzas Armadas ESPE, por lo tanto me permito acreditarlo y autorizar al señor JULIO ANDRÉS ENRÍQUEZ FUSTILLOS para que lo sustente públicamente.

Sangolquí, 23 de febrero del 2017



ING. CARLOS PAÚL BERNAL OÑATE  
DIRECTOR



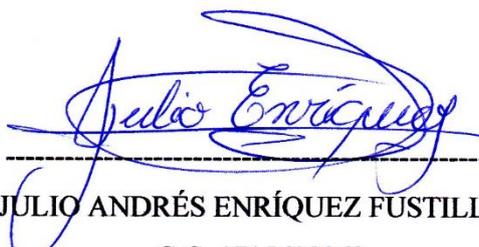
DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA  
CARRERA DE INGENIERÍA EN ELECTRÓNICA Y TELECOMUNICACIONES

AUTORÍA DE RESPONSABILIDAD

Yo, JULIO ANDRÉS ENRÍQUEZ FUSTILLOS, con cédula de identidad N° 1715608962, declaro que este trabajo de titulación “EXTRACCIÓN DE CARACTERÍSTICAS DE SEÑALES SÍSMICAS EMPLEANDO WAVELETS” ha sido desarrollado considerando los métodos de investigación existentes, así como también se ha respetado los derechos intelectuales de terceros considerándose en las citas bibliográficas.

Consecuentemente declaro que este trabajo es de mi autoría, en virtud de ello me declaro responsable del contenido, veracidad y alcance de la investigación mencionada.

Sangolquí, 23 de febrero del 2017



JULIO ANDRÉS ENRÍQUEZ FUSTILLOS  
C.C. 1715608962



DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA  
CARRERA DE INGENIERÍA EN ELECTRÓNICA Y TELECOMUNICACIONES

AUTORIZACIÓN

Yo, JULIO ANDRÉS ENRÍQUEZ FUSTILLOS, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar en la biblioteca Virtual de la institución el presente trabajo de titulación “EXTRACCIÓN DE CARACTERÍSTICAS DE SEÑALES SÍSMICAS EMPLEANDO WAVELETS” cuyo contenido, ideas y criterios son de mi autoría y responsabilidad.

Sangolquí, 23 de febrero del 2017

  
-----  
JULIO ANDRÉS ENRÍQUEZ FUSTILLOS  
C.C. 1715608962

## **DEDICATORIA**

Deseo dedicar este trabajo a todas aquellas personas que han estado conmigo en los momentos buenos y malos, que me han brindado su apoyo incondicional, solidaridad, conocimiento, comprensión y sobretodo, las que nunca perdieron la fe en mí. Esto es para ustedes.

## AGRADECIMIENTO

En primer lugar, agradezco a Dios y a mi Madre Dolorosa, que supieron guiar mi camino para alcanzar esta meta. Así como también a mis padres Delia y Julio, quienes me criaron y educaron de la mejor manera e hicieron posible, con su apoyo, comprensión y amor, que haya conseguido este gran logro.

Agradezco también a mis extraordinarios amigos, por acompañarme entre risas y experiencias a lo largo de toda esta travesía, dándome una mano cada vez que me hizo falta. De igual manera a mi familia por estar conmigo y a Gabriela Onofre, quién supo darme ánimos en los momentos más difíciles y jamás dejó que me rinda.

Quiero agradecer a mis profesores, quienes a más de ser mis mentores y compartirme su conocimiento, se convirtieron en buenos amigos, especialmente mi tutor de tesis Paúl Bernal, a quién respeto, admiro y aprecio mucho.

Este proyecto fue en parte apoyado por la Universidad de las Fuerzas Armadas – ESPE y la Escuela Politécnica Nacional mediante el Proyecto de Investigación N° 2016-EXT-038.

## ÍNDICE DE CONTENIDOS

|   |      |
|---|------|
| CERTIFICADO .....                           | ii   |
| AUTORÍA DE RESPONSABILIDAD .....            | iii  |
| AUTORIZACIÓN .....                          | iv   |
| DEDICATORIA .....                           | v    |
| AGRADECIMIENTO .....                        | vi   |
| ÍNDICE DE CONTENIDOS .....                  | vii  |
| ÍNDICE DE TABLAS .....                      | ix   |
| ÍNDICE DE FIGURAS .....                     | x    |
| RESUMEN.....                                | xii  |
| ABSTRACT.....                               | xiii |
| CAPÍTULO 1 .....                            | 1    |
| 1. INTRODUCCIÓN .....                       | 1    |
| 1.1. Antecedentes.....                      | 1    |
| 1.2. Justificación e Importancia.....       | 2    |
| 1.3. Alcance del Proyecto .....             | 3    |
| 1.4. Objetivos.....                         | 4    |
| 1.4.1. General .....                        | 4    |
| 1.4.2. Específicos.....                     | 4    |
| CAPÍTULO 2 .....                            | 6    |
| 2. MARCO TEÓRICO.....                       | 6    |
| 2.1. Eventos Sísmico-Volcánicos .....       | 6    |
| 2.1.1. Términos Sismológicos .....          | 6    |
| 2.1.2. Eventos de Largo Periodo (LP) .....  | 6    |
| 2.1.3. Eventos Volcano Tectónicos (VT)..... | 6    |
| 2.1.4. Eventos Híbridos (HYB) .....         | 7    |

|                  |  |    |
|------------------|--|----|
| 2.1.5.           | Eventos Tremores (TRE).....  | 7  |
| 2.1.6.           | Base de Datos .....  | 7  |
| 2.2.             | Transformada <i>Wavelet</i> .....  | 9  |
| 2.2.1.           | Descomposición <i>Wavelet</i> .....  | 9  |
| 2.2.2.           | Transformada <i>Wavelet</i> Continua (CWT) .....                             | 10 |
| 2.2.3.           | <i>Wavelets</i> Comúnmente usadas .....                                      | 10 |
| 2.2.4.           | Escalograma de energía.....  | 13 |
| 2.3.             | Procesamiento Digital de Imágenes.....                                       | 14 |
| 2.3.1.           | Sistema de Visión y Procesamiento de Imágenes .....                          | 14 |
| 2.3.2.           | Procesamiento Digital de Imágenes PDI.....                                   | 14 |
| 2.3.3.           | Morfología Matemática .....  | 14 |
| 2.3.4.           | Características de una imagen .....  | 15 |
| 2.4.             | Clasificadores.....  | 15 |
| 2.4.1.           | k-Vecino Más Cercano kNN (del inglés, k-Nearest Neighbors).....              | 15 |
| 2.4.2.           | Árboles de Decisión .....  | 16 |
| 2.4.3.           | Máquinas de Vector de Soporte SVM (del inglés, Support Vector Machine) ..... | 17 |
| CAPÍTULO 3 ..... |  | 19 |
| 3.               | DISEÑO DEL PROGRAMA.....   | 19 |
| 3.1.             | Descripción general del programa .....                                       | 19 |
| 3.1.1.           | Escalograma de energías .....  | 19 |
| 3.1.2.           | Energía.....   | 19 |
| 3.2.             | Obtención de la imagen (escalograma).....                                    | 19 |
| 3.3.             | Proceso morfológico de la imagen.....  | 21 |
| 3.3.1.           | Binarización.....  | 21 |
| 3.3.2.           | Erosión.....   | 23 |

|                  |  |    |
|------------------|--|----|
| 3.3.3.           | Dilatación .....   | 23 |
| 3.4.             | Extracción de características de la imagen .....         | 24 |
| 3.5.             | Extracción de características en base a la energía ..... | 25 |
| 3.5.1.           | Niveles Wavelet .....                                    | 25 |
| 3.5.2.           | Energía de la imagen .....                               | 25 |
| 3.6.             | Total de Características.....                            | 26 |
| CAPÍTULO 4 ..... |  | 27 |
| 4.               | PRUEBAS Y RESULTADOS .....                               | 27 |
| 4.1.             | Características en bruto.....                            | 28 |
| 4.1.1.           | Vecino Más Cercano (KNN).....                            | 28 |
| 4.1.2.           | Árboles de Decisión .....                                | 29 |
| 4.1.3.           | Máquinas de Vectores de Soporte (SVM).....               | 30 |
| 4.2.             | Características Normalizadas.....                        | 31 |
| 4.2.1.           | Vecino Más Cercano (KNN).....                            | 31 |
| 4.2.2.           | Árboles de Decisión .....                                | 33 |
| 4.2.3.           | Máquinas de Vectores de Soporte (SVM).....               | 34 |
| 4.3.             | Discriminación de Características .....                  | 35 |
| 4.3.1.           | Vecino Más Cercano (KNN).....                            | 35 |
| 4.3.2.           | Árboles de Decisión .....                                | 36 |
| 4.3.3.           | Máquinas de Vectores de Soporte (SVM).....               | 37 |
| CAPÍTULO 5 ..... |  | 38 |
| 5.               | CONCLUSIONES Y RECOMENDACIONES.....                      | 38 |
| 5.1.             | Conclusiones.....  | 38 |
| 5.2.             | Recomendaciones .....                                    | 39 |
| 5.3.             | Trabajos Futuros .....                                   | 40 |
| Referencias..... |  | 41 |

## ÍNDICE DE TABLAS

|   |    |
|---|----|
| Tabla 1: Tabla resumen de las características obtenidas.....          | 26 |
| Tabla 2: Porcentaje de los parámetros de evaluación (kNN – 16).....   | 29 |
| Tabla 3: Porcentaje de los parámetros de evaluación (AD – 16).....    | 30 |
| Tabla 4: Porcentaje de los parámetros de evaluación (SVM – 16).....   | 31 |
| Tabla 5: Porcentaje de los parámetros de evaluación (kNN – 16N).....  | 32 |
| Tabla 6: Porcentaje de los parámetros de evaluación (AD – 16N).....   | 33 |
| Tabla 7: Porcentaje de los parámetros de evaluación (SVM – 16N).....  | 34 |
| Tabla 8: Porcentaje de los parámetros de evaluación (kNN – 8N).....   | 35 |
| Tabla 9: Porcentaje de los parámetros de evaluación (AD – 8N).....    | 36 |
| Tabla 10: Porcentaje de los parámetros de evaluación (SVM – 16N)..... | 37 |

## ÍNDICE DE FIGURAS

|  |    |
|--|----|
| Figura 1: Ejemplos de (a) HYB, (b) LP, (c) TRE y (d) VT (Cortés, 2013).....          | 8  |
| Figura 2: Ejemplo de descomposición multinivel de Wavelet (Lara R., 2013).....       | 9  |
| Figura 3: Wavelet Haar - Representación gráfica (Mistiti M., 2011).....              | 11 |
| Figura 4: Wavelet Daubechies valor N desde 2 hasta 10 (Mistiti M., 2011).....        | 11 |
| Figura 5: Wavelet Daubechies N=2 y N=4 (Mistiti M., 2011).....                       | 12 |
| Figura 6: Wavelet Symlet con valor N desde 2 hasta 10 (Mistiti M., 2011).....        | 13 |
| Figura 7: Escalograma del porcentaje de energía resultante.....                      | 13 |
| Figura 8: Elemento estructural e imagen fuente (Sinha, 2010).....                    | 15 |
| Figura 9: Ejemplo de escalograma de energías.....                                    | 20 |
| Figura 10: Ejemplo de escalograma de energías (escala de grises).....                | 20 |
| Figura 11: Escala de grises.....   | 21 |
| Figura 12: Histograma de la Figura 10.....   | 21 |
| Figura 13: Señal sísmica original.....   | 22 |
| Figura 14: Escalograma de energías (izquierda) e imagen binarizada (derecha).....    | 22 |
| Figura 15: Imagen binarizada (izquierda) e imagen erosionada (derecha).....          | 23 |
| Figura 16: Imagen erosionada (izquierda) e imagen dilatada (derecha).....            | 24 |
| Figura 17: Parámetros de evaluación en función del número de vecinos (B).....        | 28 |
| Figura 18: Árbol de decisión resultante tras evaluar las 16 características (B)..... | 30 |
| Figura 19: Parámetros de evaluación en función del número de vecinos (N).....        | 32 |
| Figura 20: Árbol de decisión resultante tras evaluar las 16 características (N)..... | 34 |
| Figura 21: Parámetros de evaluación en función del número de vecinos (D).....        | 35 |
| Figura 22: Árbol de decisión resultante tras evaluar 8 características (D).....      | 36 |

## RESUMEN

La Tierra es un planeta volcánicamente activo, donde a lo largo de la historia, erupciones volcánicas han sido causantes de desastres naturales. Con el objetivo de minimizar consecuencias catastróficas producto de erupción volcánica, se ha vuelto indispensable la generación de estrategias de alerta temprana para la población que esté bajo este riesgo. Es así que, varios sistemas de monitoreo equipados con instrumentos de alta precisión, registran las señales sísmicas que viajan por la superficie o el interior del suelo. Las señales sísmicas volcánicas son almacenadas, caracterizadas, reconocidas y clasificadas. La clasificación de las mismas tiene un papel clave para identificar eventos que puedan ser producto de un posible proceso eruptivo. Se han realizado estudios en lo que se refiere a reducir el tiempo de respuesta frente a un evento sísmico, motivo por el que este trabajo propone una extracción de características con el uso de la Transformada *Wavelet* para obtener un escalograma que representa el porcentaje de energía de cada coeficiente de la señal, graficarlo y posteriormente identificar los niveles de energía más significativos, mismos que son sinónimo de un evento sísmico. Los gráficos del escalograma se trabajaron mediante procesamiento digital de imágenes, para tratar al evento como una figura geométrica y así extraer características de la misma. Además, se calculó el coeficiente de energía de cada nivel de descomposición *Wavelet*, así como también la energía contenida en cada imagen obtenida. Estos coeficientes representaron individualmente una característica diferente del evento sísmico. Finalmente se obtuvo un banco de 16 características, que fue evaluado por tres diferentes clasificadores, en los cuales se corroboró que las características les brindaban las pautas necesarias para clasificar un evento, con una baja tasa de error.

Palabras claves:

- SEÑALES SÍSMICAS
- TRANSFORMADA WAVELET
- ESCALOGRAMA DE ENERGÍAS
- PROCESAMIENTO DIGITAL DE IMÁGENES
- EXTRACCIÓN DE CARACTERÍSTICAS
- CLASIFICADOR

## **ABSTRACT**

The Earth is a volcanically active planet, where throughout history, volcanic eruptions have been the cause of natural disasters. In order to minimize the catastrophic consequences of a volcanic eruption, it has become indispensable to generate early warning strategies for the population that is at risk. Thus, several monitoring systems equipped with high-precision instruments, record the seismic signals that travel through the surface or the interior of the floor. Volcanic seismic signals are stored, characterized, recognized and classified. The classification of them has a key role to identify events that may be the product of a possible eruptive process. Studies have been carried out to reduce the response time to a seismic event, which is why this work proposes an extraction of characteristics with the use of the Wavelet Transform to obtain a scalogram which represents the energy percentage of Each signal coefficient, plot it and then identify the most significant energy levels, which are synonymous of a seismic event. The scalogram graphs were worked by digital image processing, to treat the event as a geometric figure and to extract characteristics of it. In addition, the energy coefficient of each wavelet decomposition level was calculated, as well as the energy contained in each image obtained. These coefficients individually represented a different characteristic of the seismic event. Finally, a bank of 16 characteristics was obtained, which was evaluated by three different classifiers, in which it was corroborated that the characteristics gave them the necessary guidelines to classify an event, with a low error rate.

Keywords:

- SEISMIC SIGNAL
- WAVELET TRANSFORM
- ENERGY SCALOGRAM
- DIGITAL IMAGE PROCESSING
- CHARACTERISTICS EXTRACTION
- CLASSIFIER

# CAPÍTULO 1

## 1. INTRODUCCIÓN

### 1.1. Antecedentes.

La Tierra es un planeta volcánicamente activo, por lo que a lo largo de la historia, erupciones volcánicas han sido causantes de desastres naturales, entre los que se puede recalcar sismos de gran intensidad, mismos que han producido pérdidas humanas y materiales incalculables (Zobin, 2011).

El volcán Vesubio fue el primero al cual se le hicieron alusión sismos en la literatura científica y tuvo su observatorio en 1847, además fue el primero en ser monitorizado usando equipo sísmico (Zobin, 2011). Así es como con el pasar de los años se han registrado señales sísmicas provenientes de actividad volcánica alrededor del mundo.

La observación y clasificación de eventos sísmicos, elaborada de manera manual, se vuelve una tarea sumamente larga y exhaustiva, razón por la que se busca desarrollar una herramienta automatizada capaz de clasificar dichos eventos en tiempo real, para lo cual es necesario extraer las características más relevantes de una señal sísmica, mismas que permitan categorizarla evitando un alto costo computacional. Estudios relacionados se realizaron en la Universidad de Colombia en 2002, donde se realizó un estudio clasificatorio para señales de varios tipos usando árboles de decisión, redes neuronales y máquinas vectoriales (Hurtado, 2002).

La Transformada *Wavelet*, básicamente proporciona una señal filtrada en el dominio de la escala, usando filtros pasa bajo y pasa alto que remueven ciertos componentes de alta o baja frecuencia. El análisis *Wavelet* es una técnica de ventanas con regiones de tamaño variable, este análisis permite el uso en largos periodos de tiempo donde es necesario extraer información de baja frecuencia con un mayor detalle (Castro, 2002). Además, con la ayuda de la plataforma Matlab<sup>®</sup>, se puede calcular el escalograma que representa el porcentaje de energía para cada coeficiente de la señal,

a través de una función que aplica la mencionada transformada, la cual incluso muestra gráficamente estos niveles de energía.

En lo que a extracción de características se refiere, se pueden utilizar las imágenes donde se observan los niveles de energía de cada coeficiente de la señal, detectando los más significativos y obteniendo características de los mismos con la ayuda del procesamiento digital de imágenes, así se trabaja con figuras geométricas, resultando más sencillo que aplicar algoritmos de procesamiento digital de señales para extracción de características.

## **1.2. Justificación e Importancia.**

Con el objetivo de minimizar consecuencias catastróficas que podrían presentarse tras una erupción volcánica, es indispensable generar estrategias de alerta temprana para la población que esté bajo riesgo de una erupción inminente. Es así que, varios sistemas de monitorización equipados con instrumentos de alta precisión, pueden registrar las señales sísmicas que viajen por la superficie o el interior del suelo (Y. Peng, 2008).

Generalmente, las señales sísmicas volcánicas son almacenadas, caracterizadas, detectadas y clasificadas. La clasificación de las mismas tiene un papel clave para identificar eventos que puedan ser producto de un posible proceso eruptivo (R. P. Duin, 2010), (M. Alvarez, 2007). Actualmente la clasificación, misma que es una tarea visual, depende de la interpretación subjetiva y destrezas específicas del analista a cargo; por esta razón, los observatorios de vulcanología tienen la necesidad de sistemas modernos que ayuden a solventar esta tarea con alta fidelidad y reduciendo el tiempo que se emplea en este proceso (R. Lara-Cueva, 2014, 2015).

Se han realizado varios estudios en lo que se refiere a reducir el tiempo de respuesta frente a un evento sísmico. La principal diferencia entre estos métodos es la metodología y herramientas empleadas para distinguir de qué tipo de evento se trata. Por ejemplo en (R. Lara-Cueva, 2014, 2015), se extrajeron un total de 79

características diferentes para desarrollar un clasificador, considerando el índice Gini, la regla de *Toving* y la desviación estándar; la exactitud en detección entre LP y ruido de fondo alcanzada por este sistema fue aproximadamente del 99%. En (Cárdenas-Pea, 2013), un estudio de señales del Nevado del Ruiz de Colombia muestra que existen diferencias entre cada evento sísmico de acuerdo a una medición de tipo estocástica para un amplio rango de características variantes en el tiempo. Otro claro ejemplo se presenta en (Ibáñez, 2009), donde los volcanes Etna y Stromboli fueron estudiados en términos de eventos VT y TRE para el primer volcán, y ruido de fondo y VLP para el segundo; los autores encontraron un total de 39 parámetros de datos de características principales temporales y características espectrales, incluyendo coeficientes de la evolución de la señal en el tiempo y de la energía en la banda de frecuencia, mediante el uso de HMM (del inglés, *Hidden Markov Models*), alcanzando porcentajes de clasificación exitosa de 86% y 84% respectivamente. Por otro lado, en (Álvarez, 2012), un filtro pasa banda de 1 a 25 Hz, usando en primer lugar ventanas de 4 s y luego extendiéndolas a 8 s, fue usado para extraer características espectrales y temporales de la información obtenida en el volcán Colima de México, produciendo dos vectores de características con 39 y 84 características, extendiendo el vector de características definido por (Ibáñez, 2009) con la consideración de la presencia o ausencia de armónicos y la envolvente espectral.

De esta manera, al proponer una extracción de características tras utilizar la Transformada *Wavelet* para obtener el escalograma que representa el porcentaje de energía de cada coeficiente de la señal, graficarlo y posteriormente identificar los niveles de energía más significativos mediante procesamiento digital de imágenes, se busca extraer características que logren mejorar el rendimiento de los clasificadores.

### **1.3. Alcance del Proyecto**

La extracción de características de las señales sísmicas se realizó a través de diferentes técnicas, obteniendo resultados favorables para aplicaciones de este tipo. En este caso, el proceso consistió en obtener un escalograma que represente el porcentaje de energía de cada coeficiente de la señal, mismo que fue graficado y en el que

posteriormente se identificaron los niveles de energía más significativos mediante procesamiento digital de imágenes, donde finalmente se extrajeron las características de los niveles detectados en cada señal para clasificarlos mediante aprendizaje supervisado y determinar de qué clase de evento sísmico se trata.

La identificación de una figura sólida fue una vía más simple que detectar una variación de amplitud en una señal que signifique un evento sísmico. Del mismo modo, analizar y extraer características de la figura antes mencionada, como largo, ancho, área, etc., fue más sencillo que establecer un algoritmo que determine características de las variaciones de la señal. Con esto se buscó simplificar y optimizar tanto la detección del evento como la obtención de sus características para posteriormente clasificarlo.

## **1.4. Objetivos**

### **1.4.1. General**

Extraer características de señales sísmicas a través de la obtención de un escalograma de energía de las mismas mediante el empleo de la Transformada *Wavelet*.

### **1.4.2. Específicos**

- Aplicar la Transformada *Wavelet* en una base de datos de señales sísmicas, provenientes del volcán Cotopaxi para obtener un escalograma que represente el porcentaje de energía de cada coeficiente de la señal.
- Identificar los niveles de energía más significativos, mediante procesamiento digital de imágenes, que representen un evento.
- Visualizar cada nivel de energía identificado mediante un proceso morfológico y eliminar píxeles de ruido o eventos falsos.

- Extraer las características de las figuras que representan un evento.
- Validar a un clasificador empleando las características extraídas para clasificar el tipo de evento al que pertenecen.

## CAPÍTULO 2

### 2. MARCO TEÓRICO

#### 2.1. Eventos Sísmico-Volcánicos

##### 2.1.1. Términos Sismológicos

La ruptura a lo largo de las fracturas y fallas, así como la actividad eruptiva, produce en la superficie de la Tierra terremotos. El lugar de la radiación inicial de ondas sísmicas en el interior del planeta se conoce como “foco”, y su proyección en la superficie como “epicentro”.

Las ondas sísmicas están divididas en “ondas de cuerpo” y “ondas de superficie”. Las ondas de cuerpo *P* (ondas de compresión con cambios volumétricos) y *S* (ondas de corte sin cambio de volumen) irradian desde el foco del terremoto; la superficie *Rayleigh* y las ondas *Love* son formadas como un resultado de la interacción entre las ondas de cuerpo con la superficie de la Tierra. El registro de ondas sísmicas se trata de un sismograma. El tamaño del terremoto es descrito por la magnitud *M* (Zobin, 2011).

##### 2.1.2. Eventos de Largo Periodo (LP)

Los eventos LP son caracterizados por ser de baja frecuencia, puesto que poseen un contenido espectral entre los 0.5 Hz y 5Hz, junto con una duración que va de varios segundos hasta algo más de un minuto. El inicio de estos eventos es de difícil determinación, ya que se trata de eventos altamente aleatorios. Son producto del movimiento de fluidos de magma y gas. Estos eventos son bastante comunes en presencia de volcanes (Viracucha, 2013). Un ejemplo de LP se observa en la Figura 1 (b).

##### 2.1.3. Eventos Volcano Tectónicos (VT)

Los eventos VT tienen un contenido espectral que supera los 10 Hz para algunos casos. Son producto de liberación de energía acumulada a causa de esfuerzos en una región determinada, donde al superarse la resistencia del material, existe una ruptura

de dicha zona. Estos eventos incrementan como anticipo de una erupción (Ibañez, 2006). Un ejemplo de VT se observa en la Figura 1 (d).

#### **2.1.4. Eventos Híbridos (HYB)**

Los eventos HYB se componen de la ocurrencia simultánea de un LP y un VT. Son producto de una fractura de roca tras someterse a presión de fluidos volcánicos, lo que desencadena una ruptura de determinada zona (VT), y el relleno de dichas fracturas por aquellos fluidos (LP). Estos eventos inician con alta frecuencia y terminan con una más baja (Ibañez, 2006). Un ejemplo de HYB se observa en la Figura 1 (a).

#### **2.1.5. Eventos Tremores (TRE)**

Los eventos TRE mantienen una amplitud constante a lo largo de varios minutos e incluso horas, producto de la salida de gases, vapor y ceniza. Poseen una subclasificación basada en el rango de frecuencia de su contenido espectral. Un ejemplo de LP se observa en la Figura 1 (c).

- *TRE de Baja Frecuencia:* Frecuencias menores a 0.5 Hz, asociado con oscilaciones de la cámara magmática o transporte de magma.
- *TRE de Alta Frecuencia:* Frecuencias mayores a 6 Hz, relacionado con desgasificaciones en cráteres, caídas de rocas o avalanchas.
- *TRE de Frecuencia Intermedia:* Frecuencias entre 1 Hz y 6 Hz, denominado una suma temporal de LP (Viracucha, 2013).

#### **2.1.6. Base de Datos**

En el Ecuador, el Instituto Geofísico de la Escuela Politécnica Nacional (IGEPN) es la institución que se encarga de la monitorización e investigación de eventos de origen tectónico y volcánico. Para esto, cuenta con una Red de sismógrafos y acelerógrafos de alta intensidad, que abarcan un 70% del territorio nacional, mismos que entregan información de forma permanente, con lo que se puede analizar datos hipocentrales, mecanismos focales, magnitudes y otros (Rivera, 2013). El volcán

Cotopaxi, posee una red de monitorización de seis estaciones de corto periodo, con una respuesta en frecuencia de 1 a 50 Hz y seis estaciones de banda ancha, con una respuesta en frecuencia de 0.1 a 50 Hz, donde cada una posee instrumentos capaces de almacenar señales en registros de 120s de duración.

La base datos proporcionada por el IGEPN constó de 759 LP, 116 VT, 30 HYB y 9 TRE. Para la realización de este proyecto se tomaron un total de 232 registros, 116 correspondientes a eventos LP tomados al azar y los 116 que corresponden a VT, cada uno de estos registros fue etiquetado para identificar el tipo de evento al que pertenecen y la duración de los mismos. Los eventos HYB y TRE no se usaron ya que su número de registros no era suficiente para realizar un estudio fidedigno.

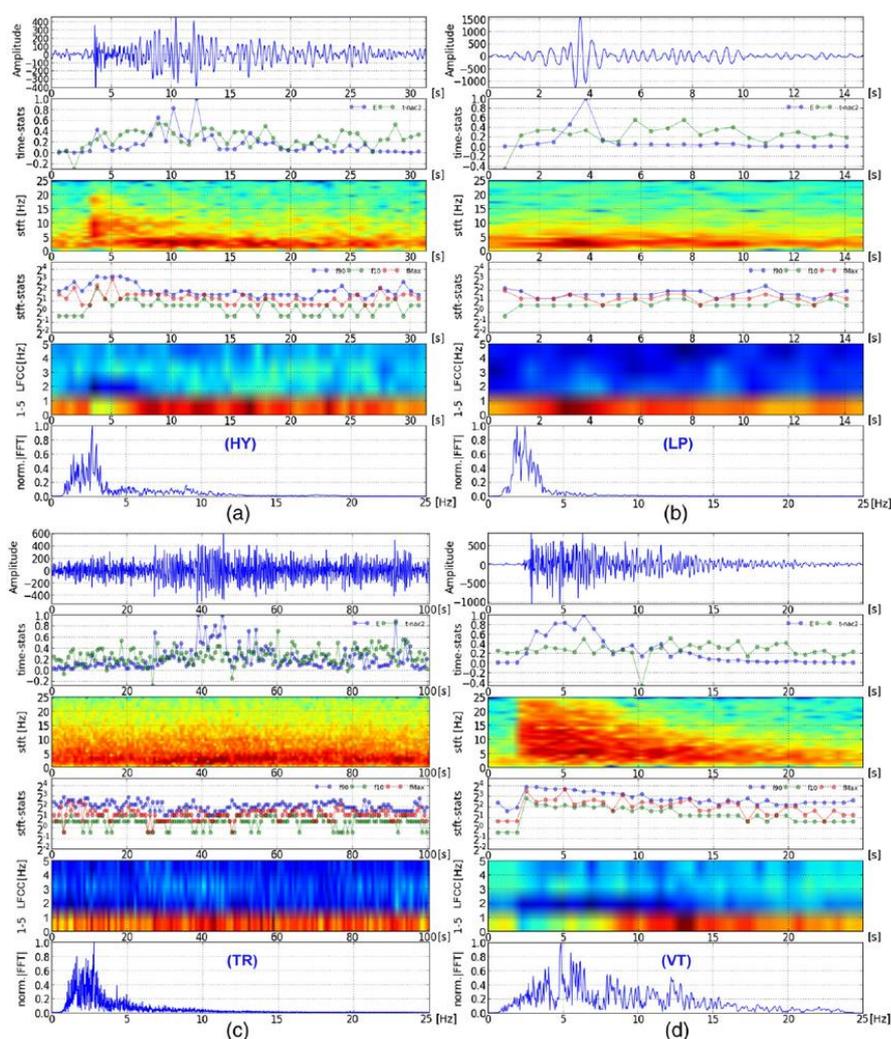


Figura 1: Ejemplos de (a) HYB, (b) LP, (c) TRE y (d) VT. En cada subfigura, fila 1: Componente vertical del sismograma de velocidad; fila 2: Energía (líneas azules) y

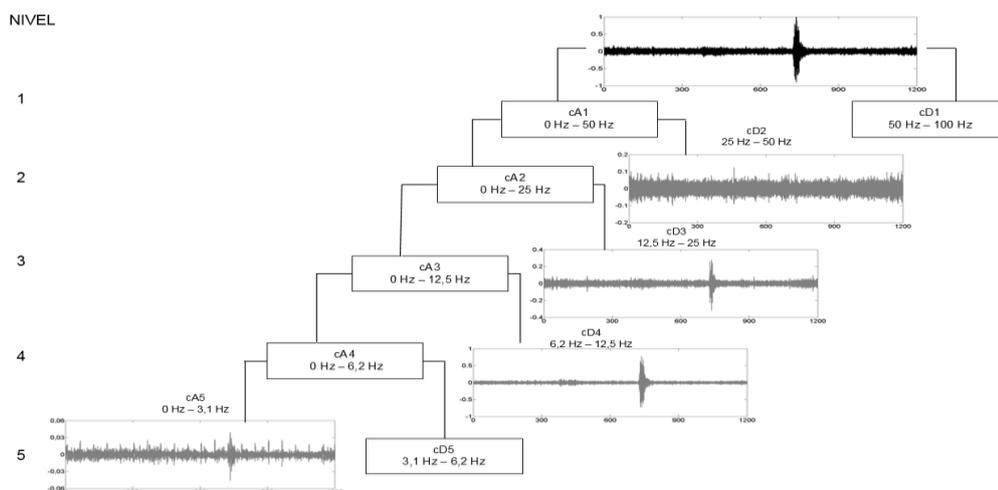
*autocorrelación (líneas verdes) de cada trama en el dominio del tiempo; fila 3: Espectrograma de Fourier de corta duración; fila 4: Frecuencias para las que la energía acumulada del espectrograma es 10% (verde), 50% (rojo) y 90% (azul), respectivamente; fila 5: Coeficientes LFCC-cepstrograma; fila 6: Espectro de Fourier normalizado (Cortés, 2013)*

## 2.2. Transformada Wavelet

El funcionamiento de la transformada *Wavelet* consiste en filtrar una señal en el dominio del tiempo por medio de filtros pasa alto y pasa bajo, los cuales eliminan ciertas componentes de baja o alta frecuencia de la misma. Este proceso se repite para las señales que resultan del filtrado previo (Castro, 2002). Un ejemplo se observa en la Figura 2.

### 2.2.1. Descomposición Wavelet

En la primera etapa de filtrado, la señal se divide en dos partes después de someterla a un filtro pasa bajo y un pasa alto, con lo que se obtiene dos versiones de ella, la que corresponde a frecuencias desde 0 Hz hasta la mitad del valor de frecuencia más alto, y la que abarca desde dicha mitad hasta el valor más alto. Como siguiente paso, se escoge cualquiera de estas dos versiones (generalmente la del filtro pasa bajo) o ambas, y se realiza de nuevo la misma división (Castro, 2002).



*Figura 2: Ejemplo de descomposición multinivel de Wavelet de un evento sísmico-volcánico LP, basado en bandas de frecuencia (Lara-Cueva R., 2013)*

### **2.2.2. Transformada *Wavelet* Continua (CWT)**

Los parámetros de la Transformada *Wavelet* Continua, como su nombre lo dice, cambian de forma continua. Esta representación ofrece la máxima libertad a la hora de elegir una *Wavelet*, con la única restricción de que satisfaga la condición de media nula. Este condicionante permite que la CWT sea invertible en rango. La CWT consiste en calcular un índice de semejanza entre la señal analizada y la *Wavelet* (Castro, 2002).

#### **2.2.2.1 Proceso de Cálculo de la CWT**

1. Establecimiento de una *Wavelet* madre
2. Cálculo del coeficiente que represente la correlación entre la *Wavelet* y la sección de la señal bajo análisis. Cuanto mayor sea éste, mayor es la similitud, por lo que los resultados dependerán de la forma de la *Wavelet*.
3. Desplazamiento de la *Wavelet* en el sentido positivo del eje temporal y repetición de los puntos anteriores (1, 2) hasta cubrir la totalidad de la señal.
4. Escalamiento de la *Wavelet* en el tiempo y repetición de los primeros tres puntos (1, 2, 3).

### **2.2.3. *Wavelets* Comúnmente usadas**

#### **2.2.3.1. *Wavelet* Haar**

Es una *Wavelet* ortogonal y simétrica en su naturaleza, es la más simple posible y representa lo mismo que una *Wavelet* db1 (Mistiti M., 2011). Tiene características de fase lineales, es decir, cuando una operación de filtrado *Wavelet* se ejecuta en una señal con esta base, no habrá ninguna distorsión de fase en la señal filtrada. Por otro lado, es la base *Wavelet* más simple con la más alta resolución en el tiempo dado por un soporte compacto de uno (Daubechies, 1992). Sin embargo, su forma rectangular determina su espectro correspondiente con características de degradación lenta, resultando una resolución de baja frecuencia.

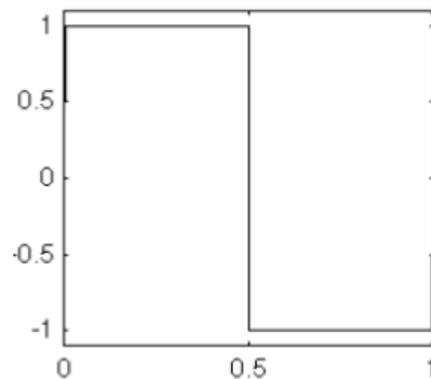


Figura 3: Wavelet Haar - Representación gráfica (Mistiti M., 2011)

### 2.2.3.2. Wavelet Daubechies

Caracterizada por ser ortogonal y compactamente soportada, lo que hace posible que pueda trabajarse con la *Wavelet* discreta, sin embargo, también es asimétrica, por lo que introduce una gran distorsión de fase, significando que no puede ser usada en aplicaciones en las que la información de fase de la señal deba mantenerse.

La familia Daubechies se representa con dbN, donde N representa el orden de la *Wavelet* base, que al ser compactamente soportada, posee una anchura de ventana de  $2N - 1$  (Daubechies, 1992) (Zamorano, 2010). Teóricamente N puede ir hasta el infinito, pero en aplicaciones reales se ha utilizado hasta un valor de 20. Algunos de los órdenes N se ilustran en la Figura 4.

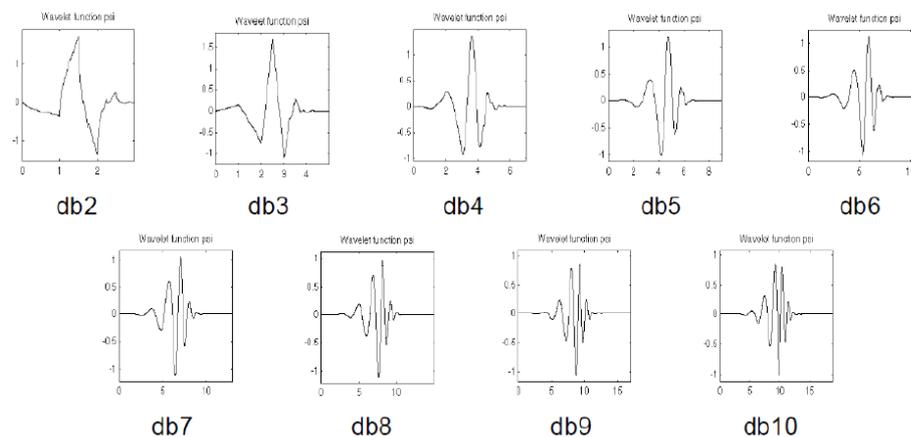


Figura 4: Wavelet Daubechies valor N desde 2 hasta 10 (Mistiti M., 2011)

Al aumentarse el orden de la *Wavelet* de base, la *Wavelet* Daubechies se torna cada vez más suave, consiguiéndose una mejor localización de frecuencia, por ende, los espectros de magnitud para cada *Wavelet* Daubechies decaen rápidamente. Un ejemplo se puede observar en la Figura 5, donde se tiene las *Wavelet* Daubechies al lado izquierdo y su respectiva magnitud de espectro al lado derecho.

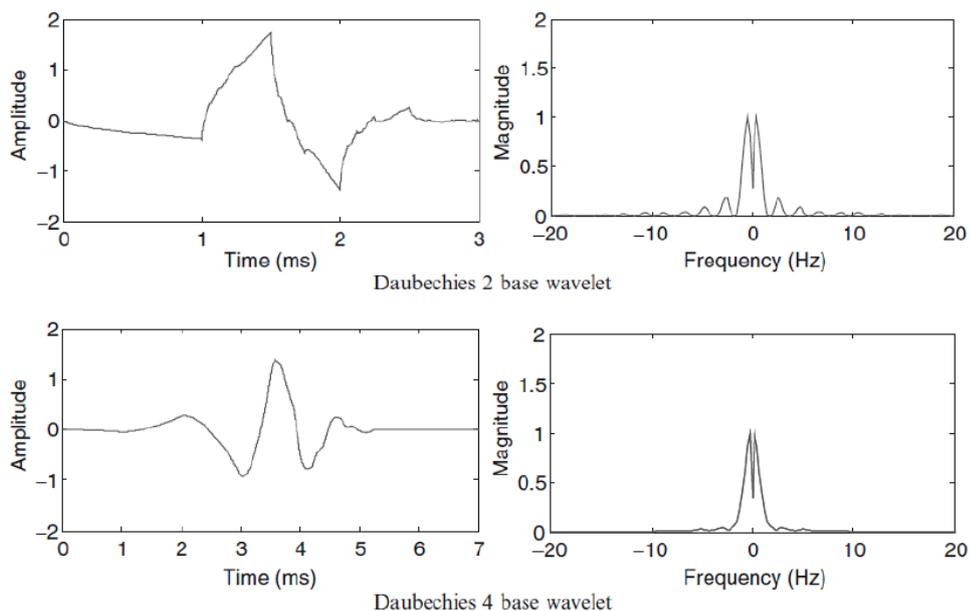


Figura 5: *Wavelet* Daubechies  $N=2$  y  $N=4$  (Mistiti M., 2011)

### 2.2.3.3. Wavelet Symlet

Estas *Wavelet* se asimilan a la familia Daubechies, pero con la diferencia de que son ortogonales y más simétricas (Daubechies, 1992). Gracias a estas características, aseguran que la distorsión de fase sea mínima. Esta familia también trabaja con un orden de ventana de  $2N - 1$ . En la Figura 6 se pueden observar algunos ejemplos de *Wavelet* Symlet.

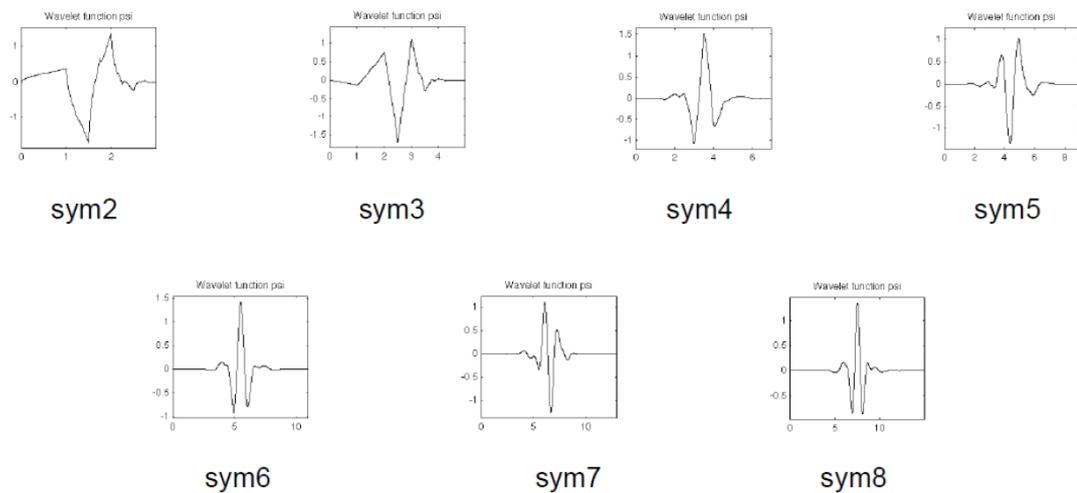


Figura 6: Wavelet Symlet con valor  $N$  desde 2 hasta 10 (Mistiti M., 2011)

#### 2.2.4. Escalograma de energía

La plataforma Matlab<sup>®</sup> es capaz de calcular el escalograma que representa el porcentaje de energía para cada coeficiente resultante de aplicar la Transformada Wavelet Continua a una señal. Para el caso de señales sísmicas, los porcentajes energéticos más altos representan la existencia de un evento sísmico (The MathWorks, Inc., s.f.). Un ejemplo se puede observar en la Figura 7.

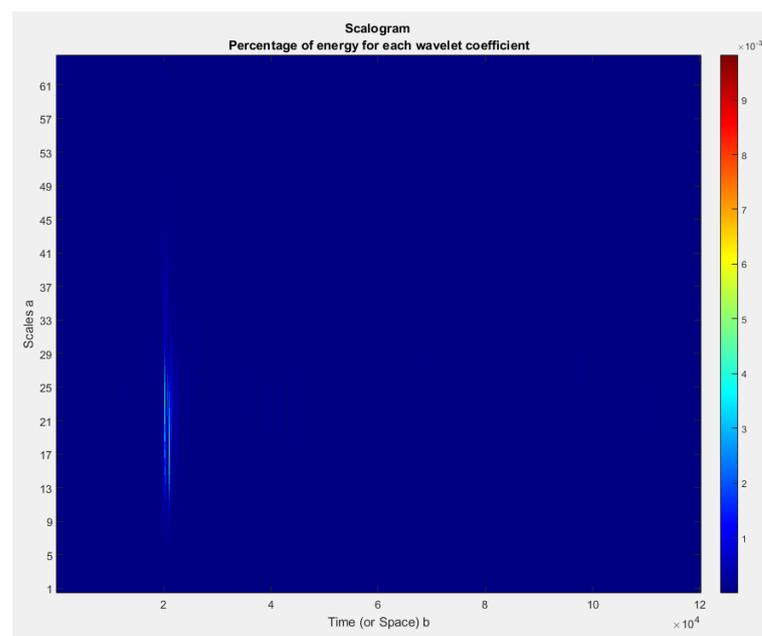


Figura 7: Escalograma del porcentaje de energía resultante de aplicar la Transformada Wavelet Continua a una señal

## **2.3. Procesamiento Digital de Imágenes**

### **2.3.1. Sistema de Visión y Procesamiento de Imágenes**

Un sistema de visión y procesamiento de imagen se constituye de una serie de subsistemas que operan sobre una escena con el fin de interpretar alguna característica notable en la misma. Este sistema se compone de procesos de bajo nivel (suavizado, umbralización, eliminación de ruido, etc.), también conocido como el pre-procesamiento, procesos de nivel medio que involucran definición de límites y extracción de características y finalmente los de alto nivel, donde se establecen relaciones semánticas entre los objetos de la descripción de la escena (Cuevas E., 2010).

### **2.3.2. Procesamiento Digital de Imágenes PDI**

Este procesamiento puede definirse como la operación de imágenes con ayuda de una computadora. El tipo de operaciones que se realizan coinciden con los procesos de un sistema de visión y procesamiento de imágenes. Una importante diferencia entre el procesamiento de imágenes y la visión está en que las imágenes con las que se trabaja en el primer caso, no corresponden únicamente a la captación del espectro visible de la que es capaz el sistema de visión biológico, puesto que las imágenes pueden ser captadas por cualquier área del espectro electromagnético. Actualmente existen sistemas de procesamiento de imagen que trabajan sobre imágenes generadas por rayos gamma, microondas, resonancia magnética, y otras (Cuevas E., 2010).

### **2.3.3. Morfología Matemática**

La morfología matemática es una técnica usada no solamente en imágenes, sino también en gráficas, mallas o cualquier elemento que tenga una naturaleza espacial. En la Figura 8 se observan las dos partes que constituyen a la morfología: La imagen y el elemento estructural. El elemento estructural es mucho más pequeño que la imagen, pues trabaja a nivel de píxeles; este elemento se desliza a lo largo de la imagen y la transforma, pues puede crear nuevos píxeles o eliminarlos, según sea su función (Sinha, 2010).

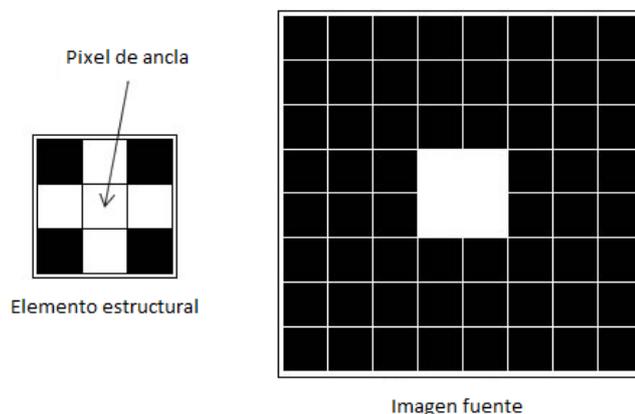


Figura 8: Elemento estructural e imagen fuente (Sinha, 2010)

### 2.3.4. Características de una imagen

Una imagen digital es la representación numérica de una imagen de dos dimensiones, conformada por píxeles, que son la unidad básica de una imagen digitalizada a base de puntos de color o escala de grises. Al analizar un grupo de píxeles de interés, se lo puede trabajar como una figura geométrica, de la cual es posible extraer varias características como los ejes que la conforman, perímetro, área, orientación en base a la horizontal, ente otras. Además, al estar una imagen digital representada por coeficientes numéricos, puede calcularse la energía de la misma tras realizar un proceso matemático, resultado que le suma otra característica. (Carlson A. Bruce, 2007)

## 2.4. Clasificadores

### 2.4.1. k-Vecino Más Cercano kNN (del inglés, k-Nearest Neighbors)

kNN realiza predicciones usando directamente la base de datos de entrenamiento. Las predicciones son hechas para una nueva instancia ( $x$ ) mediante la búsqueda a través de toda la base de datos de entrenamiento para las  $k$  instancias más similares (los vecinos) y sintetizando la variable de salida para dichas instancias  $k$ . Para la regresión, ésta será probablemente la media de la variable de salida, en clasificación será probablemente el valor de la clase.

Para determinar cuál de todas las instancias  $k$  en la base de datos de entrenamiento son más similares a una nueva entrada, es usada una medición de distancia. En el caso de variables de entrada reales y similares en tipo (por ejemplo, bases y alturas de una figura geométrica), la medición de distancia más comúnmente usada es la distancia euclidiana. (Brownlee, K-Nearest Neighbors for Machine Learning, 2016)

La distancia euclidiana ( $D_e$ ) es calculada como la raíz cuadrada de la sumatoria de las diferencias elevadas al cuadrado entre un nuevo punto ( $p$ ) y un punto existente ( $pe$ ) a lo largo de todos los atributos de entrada ( $j$ ). Como se observa en la ecuación (2.1).

$$D_e = \sqrt{\sum_{i=1}^j (p_i - pe_i)^2} \quad (2.1)$$

#### 2.4.1.1. Clasificador kNN

Cuando kNN es usado para clasificación, la salida puede ser calculada como la clase con la frecuencia más alta de las instancias  $k$  más similares. Cada instancia en esencia vota por su clase y la clase con la mayor cantidad de votos es tomada como la predicción. En el caso de tener un número par de clases a clasificar, es recomendable escoger un valor de  $k$  impar para evitar un empate. (Brownlee, K-Nearest Neighbors for Machine Learning, 2016)

#### 2.4.2. Árboles de Decisión

Los árboles de clasificación y regresión o CART (*del inglés, Classification and Regression Trees*), son un término introducido por Leo Breiman para referirse a los algoritmos de árbol de decisión que puedan usarse para clasificación o regresión de problemas de modelamiento predictivo. Los algoritmos CART proveen una base para algoritmos importantes como árboles de decisión encapsulados, bosques al azar y árboles de decisión potenciados.

En un árbol de decisión, cada nodo raíz representa una variable de entrada y un punto de división en dicha variable. Los nodos hoja del árbol contienen una variable de salida, misma que es usada como una predicción. (Brownlee, Classification And Regression Trees for Machine Learning, 2016)

#### 2.4.2.1. Poda del Árbol de Decisión

Se puede usar la poda después de entrenar el árbol para elevar aún más el rendimiento. Este proceso se realiza a través del criterio de detención, mismo que indica el momento en el que debe detenerse la división de las ramas con la información de entrenamiento. La complejidad del árbol de decisión es definida por el número de divisiones en éste, los árboles mayormente preferidos son los más simples. (Brownlee, Classification And Regression Trees for Machine Learning, 2016)

#### 2.4.3. Máquinas de Vector de Soporte SVM (del inglés, Support Vector Machine)

En SVM se realiza el entrenamiento de un hiperplano mediante la transformación del problema a través de álgebra lineal. Una poderosa herramienta está en que SVM lineal puede ser reformulado usando el producto interno entre dos vectores, el cual es la suma de la multiplicación de cada par de valores de entrada (Brownlee, Support Vector Machines for Machine Learning, 2016). La ecuación utilizada para realizar una predicción para un nuevo valor de entrada usando el producto punto entre la entrada ( $y_i$ ) y cada vector de soporte ( $y_j$ ) es la siguiente:

$$f(y_i) = B_0 + \sum_{j=0}^{\infty} z \times (y_i, y_j) \quad (2.2)$$

Esta es una ecuación que involucra el cálculo de los productos internos para un nuevo vector de entrada ( $y_i$ ) con todos los vectores de soporte en la base de datos de entrenamiento. Los coeficientes  $B_0$  y  $z$  (para cada entrada) tienen que ser estimados

por los datos de entrenamiento mediante el algoritmo de entrenamiento. (Brownlee, Support Vector Machines for Machine Learning, 2016)

## CAPÍTULO 3

### 3. DISEÑO DEL PROGRAMA

#### 3.1. Descripción general del programa

El algoritmo diseñado tiene como objetivo la extracción de características de un evento sísmico, mediante la aplicación de la Transformada *Wavelet*, con la que se obtuvieron los coeficientes de energía de la señal en donde se registró dicho evento, y posteriormente fueron usados para determinar las características del mismo. El programa consta de dos partes:

##### 3.1.1. Escalograma de energías

A través de la transformada *Wavelet*, se obtuvieron los coeficientes de energía de la señal, mismos que se graficaron en un escalograma donde se puede apreciar las zonas con un alto porcentaje energético y que por ende, son sinónimo de la existencia de un evento sísmico. Las características del evento fueron extraídas de cada gráfico a través de procesamiento digital de imágenes.

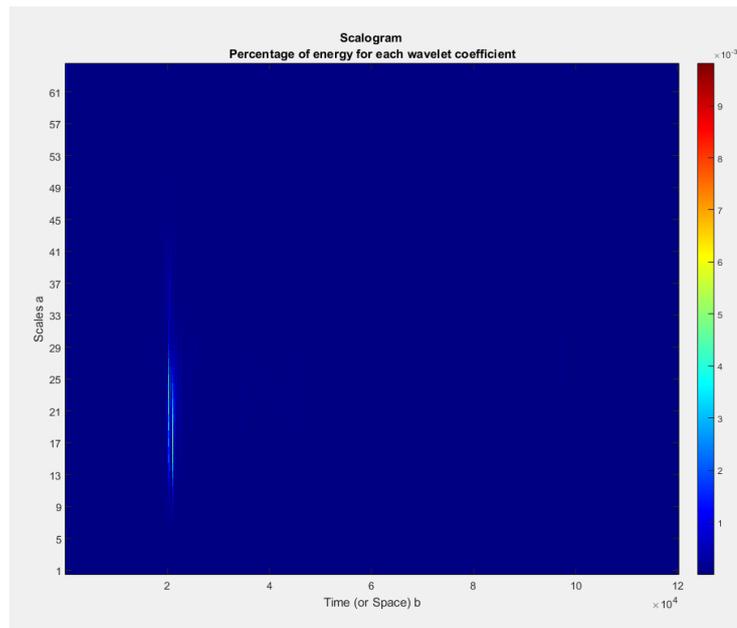
##### 3.1.2. Energía

Se calculó el coeficiente de energía de cada nivel de descomposición *Wavelet*, así como también el de cada escalograma, es decir, la energía contenida en cada imagen obtenida, antes, durante y después de haberse sometido a su respectivo proceso morfológico. Estos coeficientes representan individualmente una característica diferente del evento sísmico.

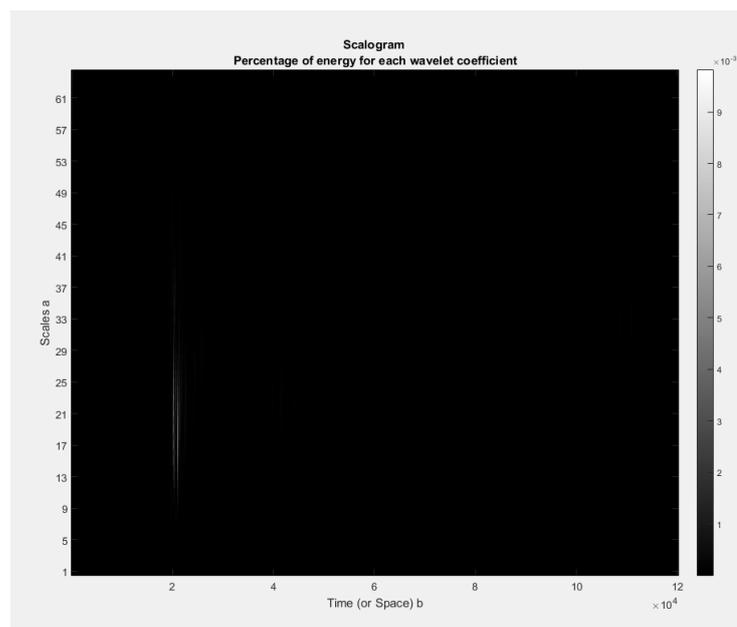
#### 3.2. Obtención de la imagen (escalograma)

Para graficar el escalograma de energías, se obtuvieron los coeficientes mediante la transformada *Wavelet* continua de una dimensión, aplicando 6 niveles de descomposición y la *Wavelet* Daubechies con el orden de la *Wavelet* base igual a 7 (C. Sidney Burrus, 1998), ya que es la más comúnmente utilizada. El escalograma permite que se resalten las zonas con mayor porcentaje energético, mismas que serán las que

identifiquen la presencia de un evento sísmico. Un ejemplo del escalograma puede observarse en la Figura 9, donde a la derecha se presenta la escala de energías con su color correspondiente, y se aprecia el evento claramente definido por un color más claro. Para realizar un procesamiento digital de la imagen, es preferible obtener el escalograma en tonalidades de blanco y negro, como se ve en la Figura 10.



*Figura 9: Ejemplo de escalograma de energías*



*Figura 10: Ejemplo de escalograma de energías (escala de grises)*

### 3.3. Proceso morfológico de la imagen

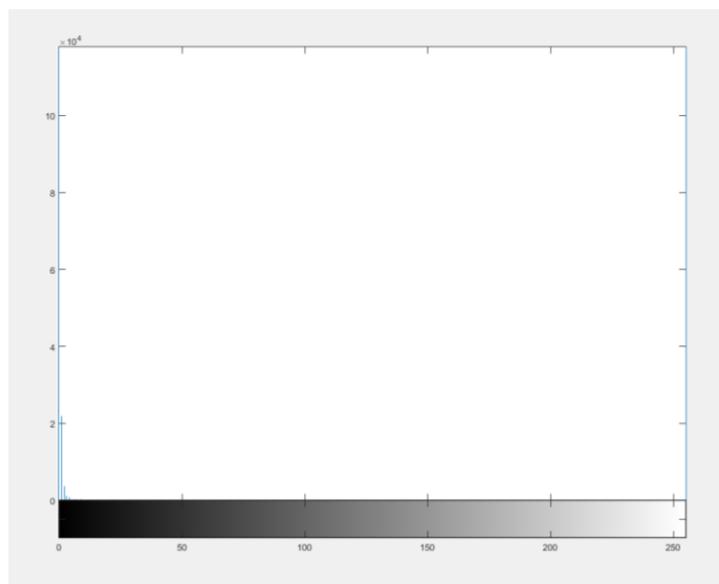
#### 3.3.1. Binarización

La imagen en escala de grises, es una matriz de píxeles que poseen coeficientes con un valor que puede ir desde 0 hasta 1, siendo 0 el color negro absoluto y 1 el blanco, y los valores intermedios tienen una ponderación dependiendo de la intensidad de negro o blanco. Un ejemplo se observa en la Figura 11.



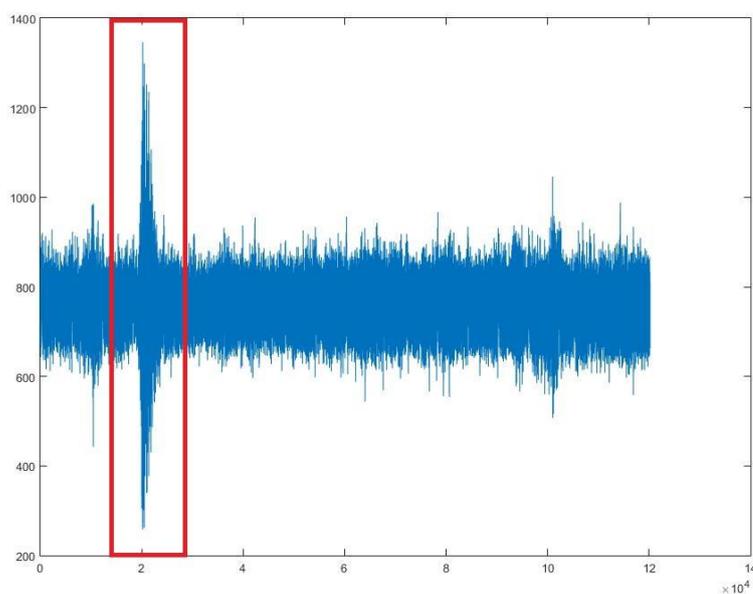
*Figura 11: Escala de grises*

La binarización consiste en establecer el valor de estos píxeles a únicamente 0 o 1, basándose en un umbral que puede tener un valor desde 0 hasta 256. El valor del umbral se define basándose en un histograma de la imagen, para observar en qué rango se encuentra la mayor cantidad de coeficientes. En este caso, el valor escogido para la binarización fue el de 1, ya que, como se aprecia en el histograma de la Figura 10, la mayoría se encuentran en este valor.

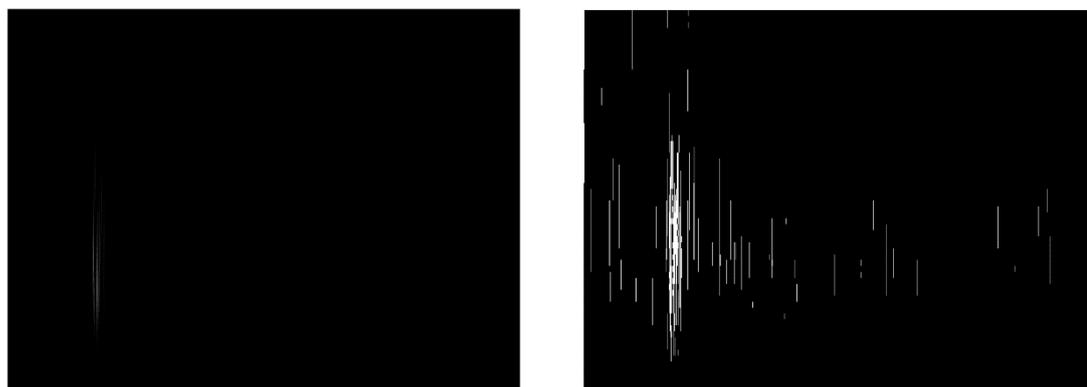


*Figura 12: Histograma de la Figura 10*

Una vez escogido el umbral, se procedió a binarizar la imagen. La señal sísmica original se puede observar en la Figura 13, donde un evento LP se aprecia claramente dentro del rectángulo rojo. En la Figura 14 se muestra su respectivo escalograma de energías (escala de grises) en la parte izquierda y su equivalente binarizado en la parte derecha. Los coeficientes de la matriz de pixeles de la imagen binarizada ya tienen un valor de únicamente 0 o 1, según les corresponda.



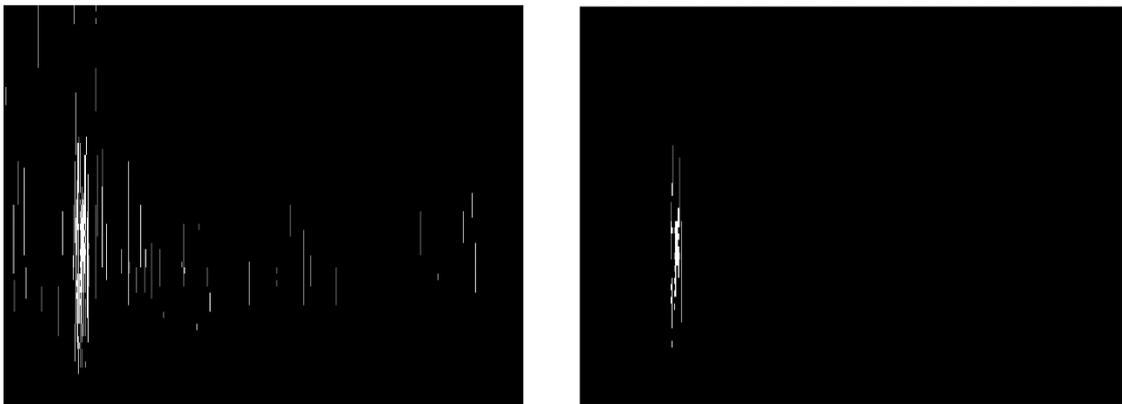
*Figura 13: Señal sísmica original*



*Figura 14: Escalograma de energías (izquierda) e imagen binarizada (derecha)*

### 3.3.2. Erosión

La erosión consiste en eliminar ciertas partes de la imagen basándose en un elemento de estructuración morfológica, este elemento recorre toda la imagen eliminando los píxeles que coincidan con el mismo. La erosión se utilizó para eliminar los píxeles que no tengan relación con el evento sísmico. En la Figura 15 se muestra la imagen binarizada al lado izquierdo y su equivalente erosionado en el lado derecho.



*Figura 15: Imagen binarizada (izquierda) e imagen erosionada (derecha)*

### 3.3.3. Dilatación

La dilatación consiste en agregar píxeles a ciertas partes de la imagen, basándose en un elemento de estructuración morfológica, este elemento recorre toda la imagen agregando píxeles cuando se coincide con el mismo. La dilatación se realizó con el fin de recuperar ciertas muestras perdidas en el proceso de erosión. Para determinar la cantidad de píxeles agregados se efectuó un conteo píxel por píxel en la matriz de la imagen original, para que, al añadirlos en la imagen erosionada, el rango de muestras que contienen al evento, coincida con el rango de muestras que se tenía originalmente. En la Figura 16 se muestra la imagen erosionada al lado izquierdo y su equivalente dilatado en el lado derecho.



Figura 16: Imagen erosionada (izquierda) e imagen dilatada (derecha)

### 3.4. Extracción de características de la imagen

Al obtener finalmente la imagen dilatada, se la tomó como una figura geométrica para realizar la extracción de características. En total se obtuvieron seis características provenientes exclusivamente de la imagen, mismas que serán detalladas a continuación:

1. **Área:** Área total de la figura.
2. **Eje Mayor:** Eje longitudinalmente más grande en la figura.
3. **Eje Menor:** Eje longitudinalmente más pequeño en la figura.
4. **Orientación:** Orientación del eje longitudinal máximo con respecto a la horizontal.
5. **Área Convexa:** Área que encierra el polígono mínimo que contiene a la figura.
6. **Perímetro:** Perímetro de la figura.

Estas características fueron obtenidas a través de la función *regionprops* de la Plataforma Matlab®:

```
%Extracción de características
[H Nest]=bwlabel(Img_Di);
prop=regionprops(H, 'Area', 'MajorAxisLength', 'MinorAxisLength', 'Perimeter', 'ConvexArea', 'Orientation');
```

### 3.5. Extracción de características en base a la energía

#### 3.5.1. Niveles Wavelet

La descomposición *Wavelet* fue realizada con seis niveles, basándose en la frecuencia de muestreo de la señal, misma que fue de 100 Hz. Cada señal fue ajustada a una cantidad de 120 000 muestras para poder trabajar con el mismo número en cada nivel. La energía de los diferentes niveles fue calculada con la ecuación que se presenta a continuación:

$$E_n = \frac{\sum(e_n)^2}{Nm_n} \quad (3.1)$$

Donde,  $E_n$  es la energía del nivel,  $e_n$  representa cada una de las muestras y  $Nm_n$  es el total de muestras de cada nivel correspondiente. Así, al tener seis etapas de descomposición *Wavelet*, se obtuvo al final siete niveles, los cuales fueron tomados independientemente como una característica diferente.

#### 3.5.2. Energía de la imagen

Al trabajar con una matriz de coeficientes para cada imagen, se usó la fórmula detallada a continuación para calcular la energía de la misma, antes, durante y después de haberse realizado el proceso morfológico. Específicamente, se calculó la energía de la imagen original, binarizada y dilatada, tomando a cada resultando como otra característica diferente.

$$E_{im} = \sqrt{\frac{\sum x^2}{M \times N}} \quad (3.2)$$

Donde,  $E_{im}$  es el valor cuadrático medio de la energía de la imagen (valor eficaz),  $x$  representa cada coeficiente de la matriz y  $M \times N$  representa el producto de las filas por las columnas de la imagen digital (Carlson A. Bruce, 2007).

### 3.6. Total de Características

Una vez que se culminó cada uno de los procesos de extracción de características, se obtuvieron un total de 16, seis provenientes del procesamiento digital de la imagen que representa el escalograma de energías, tres obtenidas tras calcular la energía de la imagen en sí y siete resultantes de calcular la energía de cada nivel Wavelet. Las características obtenidas se detallan en la Tabla 1.

**Tabla 1:**  
**Tabla resumen de las características obtenidas**

| <b>CARACTERÍSTICAS</b> |                                     |                             |
|------------------------|-------------------------------------|-----------------------------|
| <b>PDI</b>             | <b>Energía de nivel<br/>Wavelet</b> | <b>Energía de la Imagen</b> |
| 1. Área                | 7. E. Nivel 1                       | 14. E. Original             |
| 2. Eje Mayor           | 8. E. Nivel 2                       | 15. E. Binarizada           |
| 3. Eje Menor           | 9. E. Nivel 3                       | 16. E. Dilatada             |
| 4. Orientación         | 10. E. Nivel 4                      |                             |
| 5. Área Convexa        | 11. E. Nivel 5                      |                             |
| 6. Perímetro           | 12. E. Nivel 6                      |                             |
|                        | 13. E. Nivel 7                      |                             |

## CAPÍTULO 4

### 4. PRUEBAS Y RESULTADOS

Tras realizarse todo el proceso de extracción de características, se obtuvieron un total de 16, mismas que fueron ingresadas a tres tipos de clasificadores de la Plataforma Matlab<sup>®</sup>, para evaluar si con ellas se puede determinar el tipo de evento al que corresponden. Los eventos con los cuales se trabajó fueron 100 LP y 100 VT, correspondientes a la base de datos del volcán Cotopaxi del Ecuador. Se realizó una etapa de entrenamiento del clasificador y otra de pruebas, con la mitad de las señales para cada una respectivamente, dado que dos de los tres tipos de clasificadores (kNN y Árboles de Decisión) presentan buenos resultados con este método (Brownlee, K-Nearest Neighbors for Machine Learning, 2016) (Brownlee, Classification And Regression Trees for Machine Learning, 2016).

Los resultados de cada clasificador fueron analizados bajo cinco parámetros: Exactitud (A), Precisión (P), Sensibilidad (R), Especificidad (S) y Tasa de Error (BER), detallados a continuación.

$$A(\%) = \frac{N_E}{N_T} \times 100 \quad (4.1)$$

$$P(\%) = \frac{N_{VP}}{N_{VP} + N_{FP}} \times 100 \quad (4.2)$$

$$R(\%) = \frac{N_{VP}}{N_{VP} + N_{FN}} \times 100 \quad (4.3)$$

$$S(\%) = \frac{N_{VN}}{N_{VN} + N_{FP}} \quad (4.4)$$

$$BER = 1 - \frac{P(\%) + S(\%)}{200} \quad (4.5)$$

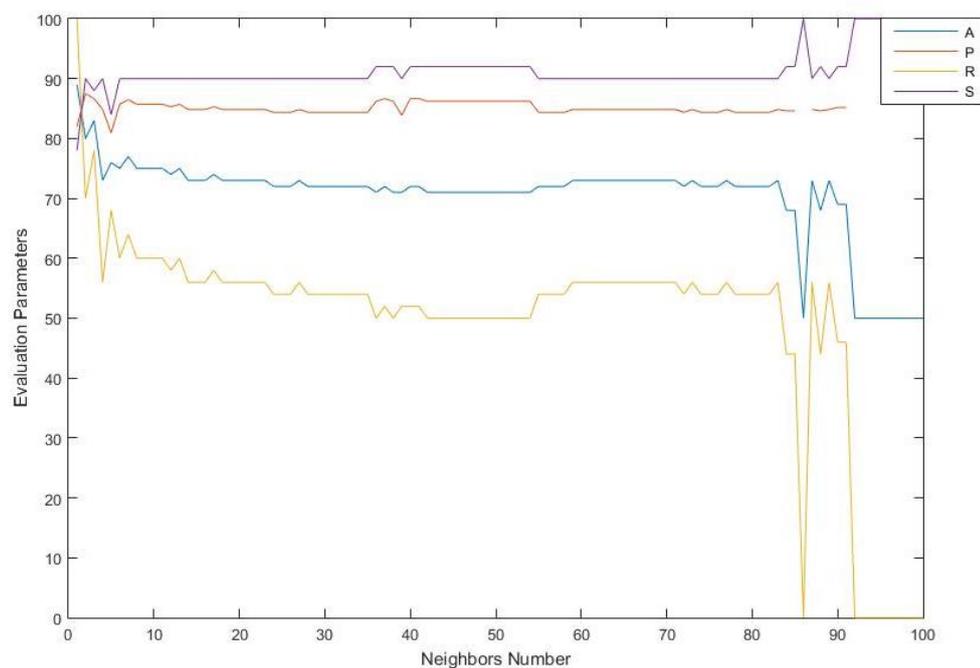
Donde,  $N_E$  es el número de eventos clasificados correctamente,  $N_T$  es el número total de eventos empleados en la clasificación,  $N_{VP}$  es el número de verdaderos positivos,  $N_{FP}$  es el número de falsos positivos,  $N_{VN}$  es el número de verdaderos negativos y  $N_{FN}$  es el número de falsos negativos.

Los diferentes parámetros que rigen a cada clasificador fueron los que Matlab® establece como valores estándar. Además, se realizaron pruebas tanto con los valores de las características en bruto, como con estos valores normalizados, es decir, centrados para tener la media igual a cero y escalados para que su desviación estándar sea uno. Los clasificadores utilizados fueron Vecino Más Cercano (KNN), Árboles de Decisión y Máquinas de Vectores de Soporte (SVM).

#### 4.1. Características en bruto

##### 4.1.1. Vecino Más Cercano (KNN)

En este caso, se realizaron pruebas con un rango de vecinos desde 1 hasta 100, con el fin de determinar con qué número se maximizan todos los parámetros de evaluación del clasificador. Así, los datos obtenidos fueron los siguientes:



*Figura 17: Parámetros de evaluación en función del número de vecinos tras evaluar las 16 características en bruto*

**Tabla 2:**  
**Porcentaje de los parámetros de evaluación en función del número de vecinos tras evaluar las 16 características en bruto**

| N. Vecinos | Exactitud | Precisión | Sensibilidad | Especificidad | BER  |
|------------|-----------|-----------|--------------|---------------|------|
| 1          | 89,00%    | 81,97%    | 100,00%      | 78,00%        | 0,11 |
| 2          | 80,00%    | 87,50%    | 70,00%       | 90,00%        | 0,20 |
| 3          | 83,00%    | 86,67%    | 78,00%       | 88,00%        | 0,17 |
| 4          | 73,00%    | 84,85%    | 56,00%       | 90,00%        | 0,27 |
| 5          | 76,00%    | 80,95%    | 68,00%       | 84,00%        | 0,24 |
| 6          | 75,00%    | 85,71%    | 60,00%       | 90,00%        | 0,25 |
| 7          | 77,00%    | 86,49%    | 64,00%       | 90,00%        | 0,23 |
| 8          | 75,00%    | 85,71%    | 60,00%       | 90,00%        | 0,25 |
| 9          | 75,00%    | 85,71%    | 60,00%       | 90,00%        | 0,25 |
| 10         | 75,00%    | 85,71%    | 60,00%       | 90,00%        | 0,25 |
| 11         | 75,00%    | 85,71%    | 60,00%       | 90,00%        | 0,25 |
| 12         | 74,00%    | 85,29%    | 58,00%       | 90,00%        | 0,26 |
| 13         | 75,00%    | 85,71%    | 60,00%       | 90,00%        | 0,25 |
| 14         | 73,00%    | 84,85%    | 56,00%       | 90,00%        | 0,27 |
| 15         | 73,00%    | 84,85%    | 56,00%       | 90,00%        | 0,27 |
| 16         | 73,00%    | 84,85%    | 56,00%       | 90,00%        | 0,27 |
| 17         | 74,00%    | 85,29%    | 58,00%       | 90,00%        | 0,26 |
| 18         | 73,00%    | 84,85%    | 56,00%       | 90,00%        | 0,27 |
| 19         | 73,00%    | 84,85%    | 56,00%       | 90,00%        | 0,27 |
| 20         | 73,00%    | 84,85%    | 56,00%       | 90,00%        | 0,27 |

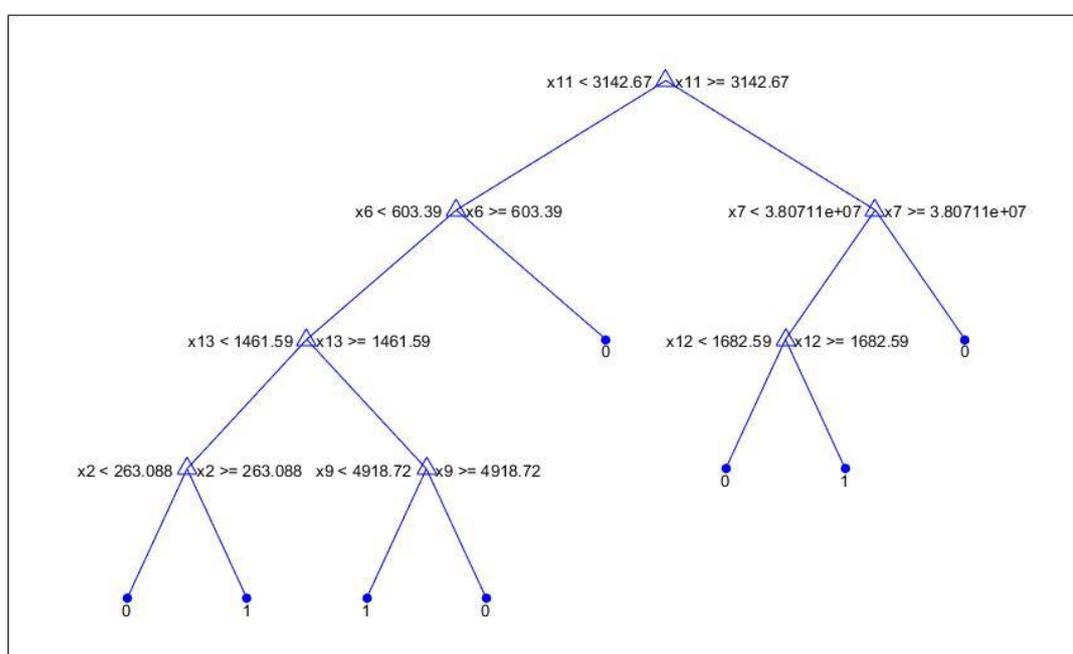
Como se observa en la Figura 17, el número de vecinos que maximiza los parámetros de evaluación es 3, valor que puede corroborarse en la Tabla 2, que muestra de manera más específica los porcentajes obtenidos. El valor de 1 no se toma en cuenta ya que éste ocasiona que cada vector de entrenamiento defina una región en el espacio y los elementos que se encuentren dentro de dicha región se clasificarán como de esa clase. Además, existe la recomendación de que para clasificar dos clases es preferible escoger un número impar de vecinos, y para clasificar más clases, el número de vecinos no debe ser un múltiplo de las mismas. (Körting, 2014)

#### 4.1.2. Árboles de Decisión

El árbol de decisión constituido se puede observar en la Figura 18, donde se especifican las características escogidas para construir el mismo, y los resultados de los parámetros de evaluación se muestran en la Tabla 3.

**Tabla 3:**  
**Porcentaje de los parámetros de evaluación usando árboles de decisión tras evaluar las 16 características en bruto**

| Exactitud | Precisión | Sensibilidad | Especificidad | BER  |
|-----------|-----------|--------------|---------------|------|
| 85,00%    | 80,70%    | 92,00%       | 78,00%        | 0,15 |



*Figura 18: Árbol de decisión resultante tras evaluar las 16 características en bruto*

Se observa que la característica x11 (E. Nivel 5) es la preferida por el clasificador, por ende, es la que determina si el evento corresponde a un LP o un VT. En el nivel dos de prioridad del Árbol de decisión se tiene a x6 (Perímetro) y x7 (E. Nivel 1), en el nivel tres se encuentran x12 (E. Nivel 6) y x13 (E. Nivel 7), finalmente en el nivel cuatro están x2 (Eje Mayor) y x9 (E. Nivel 3).

#### 4.1.3. Máquinas de Vectores de Soporte (SVM)

Los resultados de los parámetros de evaluación al evaluar las características con SVM se presentan en la Tabla 4.

**Tabla 4:**  
**Porcentaje de los parámetros de evaluación usando SVM tras evaluar las 16 características en bruto**

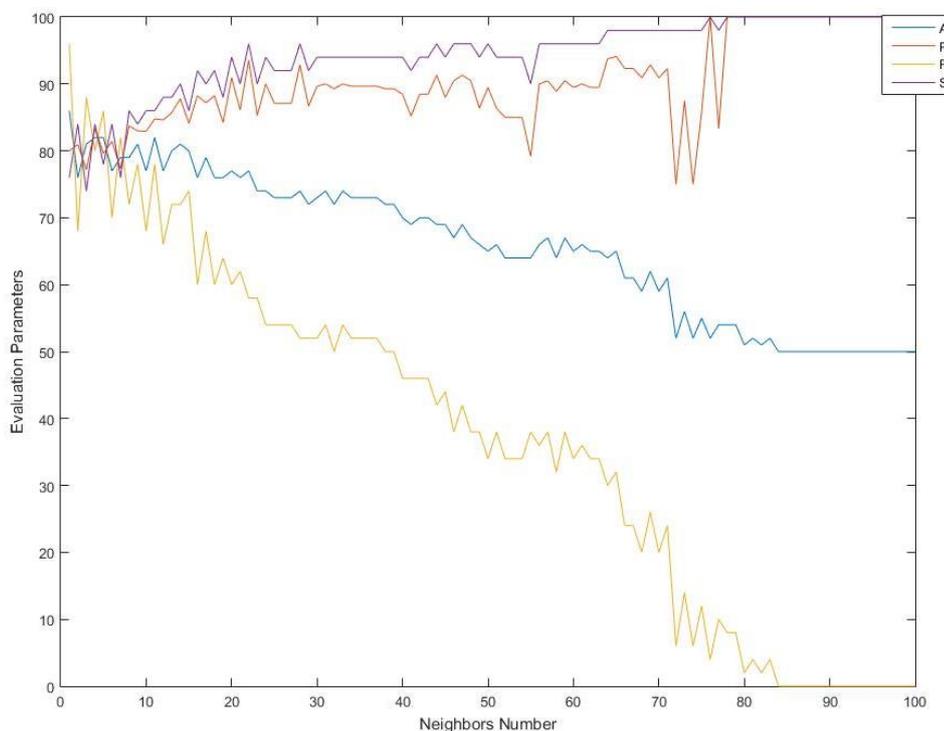
| Exactitud | Precisión | Sensibilidad | Especificidad | BER    |
|-----------|-----------|--------------|---------------|--------|
| 50,00%    | NaN       | 0,00%        | 100,00%       | 50,00% |

Al obtener un valor de NaN se manifiesta que las características no tienen las propiedades necesarias para trabajar con este clasificador.

## **4.2. Características Normalizadas**

### **4.2.1. Vecino Más Cercano (KNN)**

En este caso, se realizaron pruebas con un rango de vecinos desde 1 hasta 100, con el fin de determinar con qué número se maximizan todos los parámetros de evaluación del clasificador. Así, los datos obtenidos fueron los siguientes:



*Figura 19: Parámetros de evaluación en función del número de vecinos tras evaluar las 16 características normalizadas*

**Tabla 5:**  
**Porcentaje de los parámetros de evaluación en función del número de vecinos tras evaluar las 16 características normalizadas**

| N. Vecinos | Exactitud | Precisión | Sensibilidad | Especificidad | BER  |
|------------|-----------|-----------|--------------|---------------|------|
| 1          | 86,00%    | 80,00%    | 96,00%       | 76,00%        | 0,14 |
| 2          | 76,00%    | 80,95%    | 68,00%       | 84,00%        | 0,24 |
| 3          | 81,00%    | 77,19%    | 88,00%       | 74,00%        | 0,19 |
| 4          | 82,00%    | 83,33%    | 80,00%       | 84,00%        | 0,18 |
| 5          | 82,00%    | 79,63%    | 86,00%       | 78,00%        | 0,18 |
| 6          | 77,00%    | 81,40%    | 70,00%       | 84,00%        | 0,23 |
| 7          | 79,00%    | 77,36%    | 82,00%       | 76,00%        | 0,21 |
| 8          | 79,00%    | 83,72%    | 72,00%       | 86,00%        | 0,21 |
| 9          | 81,00%    | 82,98%    | 78,00%       | 84,00%        | 0,19 |
| 10         | 77,00%    | 82,93%    | 68,00%       | 86,00%        | 0,23 |
| 11         | 82,00%    | 84,78%    | 78,00%       | 86,00%        | 0,18 |
| 12         | 77,00%    | 84,62%    | 66,00%       | 88,00%        | 0,23 |
| 13         | 80,00%    | 85,71%    | 72,00%       | 88,00%        | 0,20 |
| 14         | 81,00%    | 87,80%    | 72,00%       | 90,00%        | 0,19 |
| 15         | 80,00%    | 84,09%    | 74,00%       | 86,00%        | 0,20 |
| 16         | 76,00%    | 88,24%    | 60,00%       | 92,00%        | 0,24 |

|           |        |        |        |        |      |
|-----------|--------|--------|--------|--------|------|
| <b>17</b> | 79,00% | 87,18% | 68,00% | 90,00% | 0,21 |
| <b>18</b> | 76,00% | 88,24% | 60,00% | 92,00% | 0,24 |
| <b>19</b> | 76,00% | 84,21% | 64,00% | 88,00% | 0,24 |
| <b>20</b> | 77,00% | 90,91% | 60,00% | 94,00% | 0,23 |

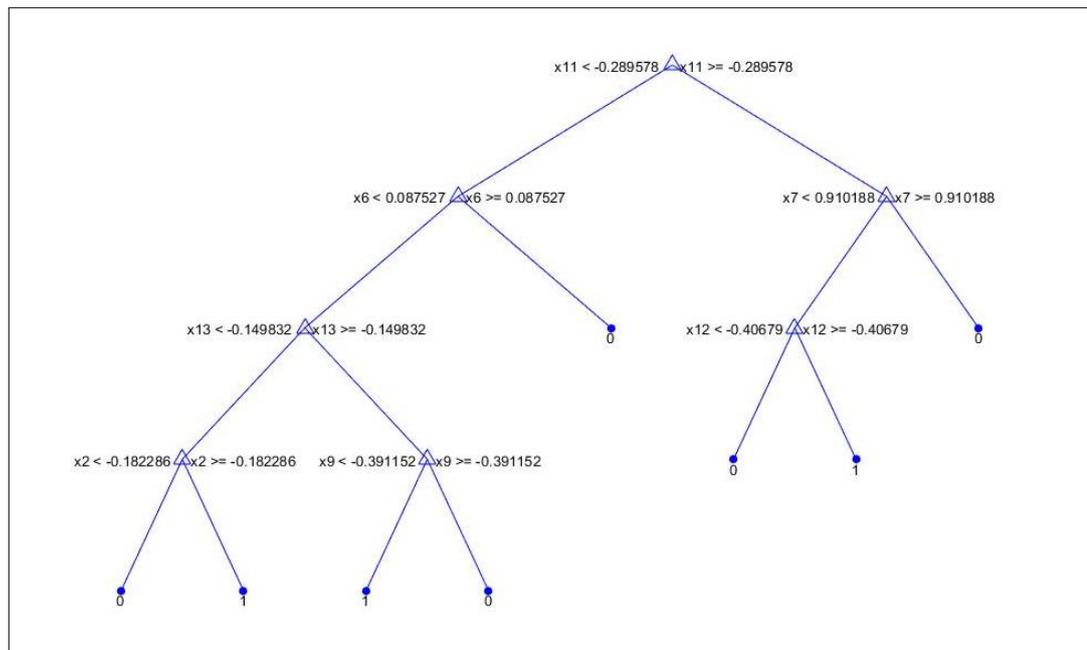
Como se observa en la Figura 19, el número de vecinos que maximiza los parámetros de evaluación es 5, valor que puede corroborarse en la Tabla 5, que muestra de manera más específica los porcentajes obtenidos. El valor de 1 no se toma en cuenta y, aunque el valor de 4 también presente buenos resultados, para clasificar dos clases se escoge un número impar de vecinos.

#### 4.2.2. Árboles de Decisión

El árbol de decisión constituido se puede observar en la Figura 20, donde se especifican las características escogidas para construir el mismo, y los resultados de los parámetros de evaluación se muestran en la Tabla 6.

**Tabla 6:**  
**Porcentaje de los parámetros de evaluación usando árboles de decisión tras evaluar las 16 características normalizadas**

| Exactitud | Precisión | Sensibilidad | Especificidad | BER  |
|-----------|-----------|--------------|---------------|------|
| 73,00%    | 75,56%    | 68,00%       | 78,00%        | 0,27 |



*Figura 20: Árbol de decisión resultante tras evaluar las 16 características normalizadas*

Se observa que la característica  $x_{11}$  (E. Nivel 5) es la preferida por el clasificador, por ende, es la que determina si el evento corresponde a un LP o un VT. En el nivel dos de prioridad del Árbol de decisión se tiene a  $x_6$  (Perímetro) y  $x_7$  (E. Nivel 1), en el nivel tres se encuentran  $x_{12}$  (E. Nivel 6) y  $x_{13}$  (E. Nivel 7), finalmente en el nivel cuatro están  $x_2$  (Eje Mayor) y  $x_9$  (E. Nivel 3).

#### 4.2.3. Máquinas de Vectores de Soporte (SVM)

Los resultados de los parámetros de evaluación al evaluar las características con SVM se presentan en la Tabla 6.

**Tabla 7:**  
**Porcentaje de los parámetros de evaluación usando SVM tras evaluar las 16 características normalizadas**

| Exactitud | Precisión | Sensibilidad | Especificidad | BER   |
|-----------|-----------|--------------|---------------|-------|
| 84,00%    | 85,42%    | 82,00%       | 86,00%        | 0,16% |

### **4.3. Discriminación de Características**

Tras observar los datos obtenidos con los datos en bruto y normalizados, se aprecia que la normalización provoca una mejora para dos de los clasificadores: KNN y SVM, por lo que se procedió a realizar una discriminación de características basándose en aquellas escogidas por los Árboles de Decisión como las más significativas. Las características se usaron en su forma normalizada y fueron las siguientes:

1. Eje Mayor
2. Perímetro
3. Energía de Nivel 1
4. Energía de Nivel 3
5. Energía de Nivel 5
6. Energía de Nivel 6
7. Energía de Nivel 7
8. Energía de la imagen binarizada

#### **4.3.1. Vecino Más Cercano (KNN)**

En este caso, se realizaron pruebas con un rango de vecinos desde 1 hasta 100, con el fin de determinar con qué número se maximizan todos los parámetros de evaluación del clasificador. Así, los datos obtenidos fueron los siguientes:

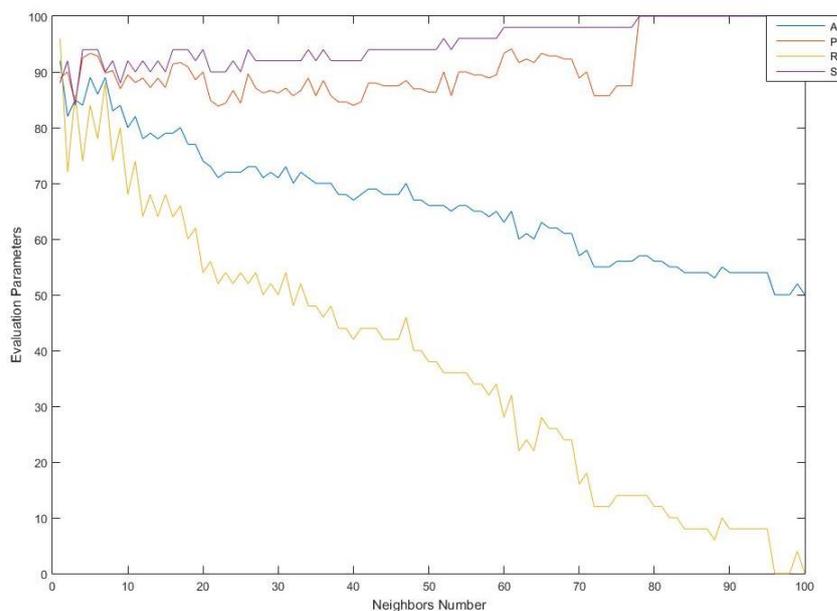


Figura 21: Parámetros de evaluación en función del número de vecinos tras evaluar 8 características normalizadas

**Tabla 8:**  
**Porcentaje de los parámetros de evaluación en función del número de vecinos tras evaluar 8 características normalizadas**

| N. Vecinos | Exactitud | Precisión | Sensibilidad | Especificidad | VER  |
|------------|-----------|-----------|--------------|---------------|------|
| 1          | 92,00%    | 88,89%    | 96,00%       | 88,00%        | 0,08 |
| 2          | 82,00%    | 90,00%    | 72,00%       | 92,00%        | 0,18 |
| 3          | 85,00%    | 84,31%    | 86,00%       | 84,00%        | 0,15 |
| 4          | 84,00%    | 92,50%    | 74,00%       | 94,00%        | 0,16 |
| 5          | 89,00%    | 93,33%    | 84,00%       | 94,00%        | 0,11 |
| 6          | 86,00%    | 92,86%    | 78,00%       | 94,00%        | 0,14 |
| 7          | 89,00%    | 89,80%    | 88,00%       | 90,00%        | 0,11 |
| 8          | 83,00%    | 90,24%    | 74,00%       | 92,00%        | 0,17 |
| 9          | 84,00%    | 86,96%    | 80,00%       | 88,00%        | 0,16 |
| 10         | 80,00%    | 89,47%    | 68,00%       | 92,00%        | 0,20 |
| 11         | 82,00%    | 88,10%    | 74,00%       | 90,00%        | 0,18 |
| 12         | 78,00%    | 88,89%    | 64,00%       | 92,00%        | 0,22 |
| 13         | 79,00%    | 87,18%    | 68,00%       | 90,00%        | 0,21 |
| 14         | 78,00%    | 88,89%    | 64,00%       | 92,00%        | 0,22 |
| 15         | 79,00%    | 87,18%    | 68,00%       | 90,00%        | 0,21 |
| 16         | 79,00%    | 91,43%    | 64,00%       | 94,00%        | 0,21 |
| 17         | 80,00%    | 91,67%    | 66,00%       | 94,00%        | 0,20 |
| 18         | 77,00%    | 90,91%    | 60,00%       | 94,00%        | 0,23 |
| 19         | 77,00%    | 88,57%    | 62,00%       | 92,00%        | 0,23 |
| 20         | 74,00%    | 90,00%    | 54,00%       | 94,00%        | 0,26 |

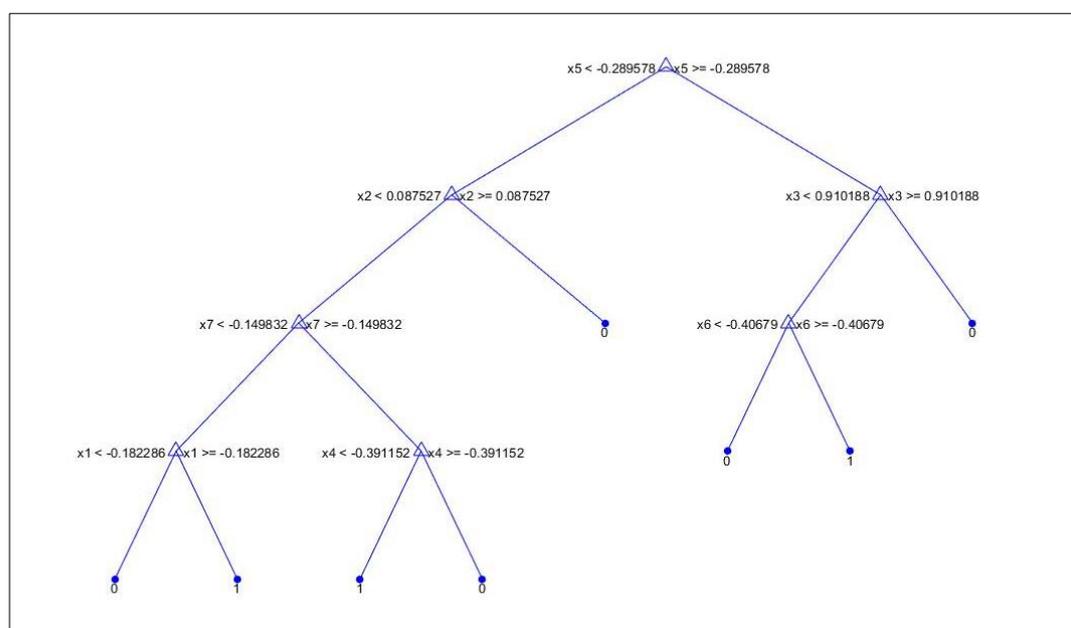
Como se observa en la Figura 21, el número de vecinos que maximiza los parámetros de evaluación es 5, valor que puede corroborarse en la Tabla 8, que muestra de manera más específica los porcentajes obtenidos. El valor de 1 no se toma en cuenta y, aunque el valor de 7 también presente buenos resultados, con 5 se maximizan la mayoría de parámetros de evaluación.

### 4.3.2. Árboles de Decisión

El árbol de decisión constituido se puede observar en la Figura 19, donde se especifican las características escogidas para construir el mismo, y los resultados de los parámetros de evaluación se muestran en la Tabla 9.

**Tabla 9:**  
**Porcentaje de los parámetros de evaluación usando árboles de decisión tras evaluar 8 características normalizadas**

| Exactitud | Precisión | Sensibilidad | Especificidad | BER    |
|-----------|-----------|--------------|---------------|--------|
| 73,00%    | 75,56%    | 68,00%       | 78,00%        | 27,00% |



*Figura 22: Árbol de decisión resultante tras evaluar 8 características normalizadas*

Se observa que la característica x5 (E. Nivel 5) es la preferida por el clasificador, por ende, es la que determina si el evento corresponde a un LP o un VT. En el nivel dos de prioridad del Árbol de decisión se tiene a x2 (Perímetro) y x3 (E. Nivel 1), en el nivel tres se encuentran x6 (E. Nivel 6) y x7 (E. Nivel 7), finalmente en el nivel cuatro están x1 (Eje Mayor) y x4 (E. Nivel 3).

### 4.3.3. Máquinas de Vectores de Soporte (SVM)

Los resultados de los parámetros de evaluación al evaluar las características con SVM se presentan en la Tabla 9.

**Tabla 10:**  
**Porcentaje de los parámetros de evaluación usando SVM tras evaluar 8 características normalizadas**

| Exactitud | Precisión | Sensibilidad | Especificidad | BER  |
|-----------|-----------|--------------|---------------|------|
| 80,00%    | 85,71%    | 72,00%       | 88,00%        | 0,20 |

Cabe recalcar que cada clasificador tiene su respectivo selector de características, por lo que, si se hace una profundización en el aspecto de clasificación, se debe trabajar con el selector respectivo.

**NOTA:** Todos los resultados presentados previamente, se obtuvieron en base al programa desarrollado en Matlab<sup>®</sup>, detallado en el Anexo A.

## CAPÍTULO 5

### 5. CONCLUSIONES Y RECOMENDACIONES

#### 5.1. Conclusiones

- Para obtener los coeficientes de energía de la señal sísmica mediante la transformada Wavelet continua de una dimensión, se usó la Wavelet *Daubechies* con  $N=7$ , puesto que ofrece una mejor localización de frecuencia, y se aplicaron 6 niveles de descomposición, a razón de que las señales sísmicas de la base de datos tenían una frecuencia máxima de 50 Hz, debido a la capacidad de digitalización de los equipos.
- Se comprobó, utilizando el gráfico del escalograma de energías, que las zonas con los colores más claros de la escala, es decir, con mayor porcentaje energético, efectivamente correspondían a un evento sísmico.
- La pérdida significativa de muestras que pudiera generarse a causa del proceso morfológico, se controló de una manera empírica, puesto que se realizó un conteo pixel a pixel de la figura que representaba el evento sísmico en cada etapa de dicho proceso, para establecer los índices de binarización, erosión y dilatación que brinden un número de muestras casi idéntico a las que representaban la duración del evento en la señal original.
- Con el fin de extraer las características del evento sísmico, se definió al grupo de pixeles que lo representaban como una figura geométrica, de manera que pudieron destacarse características como el área, el perímetro, los ejes que la componen, su orientación, entre otras.
- Se observó que los niveles de descomposición Wavelet pueden ser tomados como otra fuente de características, en este caso, se tomó a la energía de cada nivel como una característica diferente.

- Se concluyó que una característica importante, dado que se trabajó con imágenes y el procesamiento digital de las mismas, es calcular la energía de la imagen en sí, y se puede obtener de la imagen original o durante cualquier etapa del proceso morfológico.
- Se evidenció que la normalización de características, representan un factor importante a la hora de someterlas a la evaluación de un clasificador, sin embargo, cabe recalcar que cada clasificador tiene su respectivo selector de características, por lo que, si se hace una profundización en el aspecto de clasificación, se debe trabajar con el selector respectivo. Un ejemplo de esto se corrobora en los resultados favorables obtenidos con Árboles de Decisión y kNN, mas no con SVM, tras la discriminación de características realizada.
- Se constató que el algoritmo propuesto para extracción de características de señales sísmicas mediante el empleo de la transformada *Wavelet*, proporcionó un banco de características capaz de darle las pautas necesarias a un clasificador para determinar el tipo de evento del que se trata, con una baja tasa de error.

## 5.2. Recomendaciones

- Tras realizar la investigación de las funcionalidades y ventajas de la transformada *Wavelet*, así como de los tipos de *Wavelet*, escoger cuidadosamente los niveles de descomposición y el tipo que mejor se ajuste a las características de la señal con la que se va a trabajar, como por ejemplo su frecuencia.
- Usar herramientas que permitan evitar perder un número significativo de muestras de la señal durante el proceso morfológico, en este caso se realizó un coteo manual pixel a pixel, pero su desventaja es que el tiempo requerido para dicha tarea fue muy extenso.

### 5.3. Trabajos Futuros

- Los parámetros de evaluación obtenidos en este trabajo de investigación, fueron resultantes de usar los valores estándar de los clasificadores proporcionados por la plataforma Matlab<sup>®</sup>, dado que el objetivo y alcance del proyecto era la extracción de características y dichos clasificadores fueron usados para comprobar que eran factibles para realizar una clasificación, por lo que, entre los trabajos futuros se encuentra profundizar en el manejo de clasificadores y analizar el impacto que tenga la modificación de sus diferentes variables, así como el manejo de sus respectivos selectores de características, en los resultados de los porcentajes de los parámetros de evaluación, mismos que probablemente, podrían mejorarse.

## Referencias

- Brownlee, J. (8 de Abril de 2016). *Classification And Regression Trees for Machine Learning*. Obtenido de <http://machinelearningmastery.com/classification-and-regression-trees-for-machine-learning/>
- Brownlee, J. (15 de Abril de 2016). *K-Nearest Neighbors for Machine Learning*. Obtenido de <http://machinelearningmastery.com/k-nearest-neighbors-for-machine-learning/>
- Brownlee, J. (20 de Abril de 2016). *Support Vector Machines for Machine Learning*. Obtenido de <http://machinelearningmastery.com/support-vector-machines-for-machine-learning/>
- Cárdenas-Pea, M. O.-A.-D. (2013). Selection of time-variant features for earthquake classification at the Nevado-del-Ruiz volcano. *Computers & Geosciences*.
- Carlson A. Bruce, C. P. (2007). *Sistemas de Comunicaciones*.
- Castro, R. (2002). *Análisis de la teoría de ondículas orientada a las aplicaciones en ingeniería eléctrica: Fundamentos*. Madrid - España.
- Cuevas E., Z. D. (2010). *Procesamiento digital de imágenes con MATLAB y Simulink*. Madrid - España: RA-MA.
- Daubechies, I. (1992). *Ten Lectures on Wavelets*. Philadelphia.
- Hurtado, J. H. (01 de Abril de 2002). Clasificación de Señales Sísmicas por Medio de Onditas y Máquinas de Soporte Vectorial. *PRIMER SIMPOSIO COLOMBIANO DE SISMOLOGÍA*, (págs. 9-11). Obtenido de Procesamiento avanzado de imagenes digitales: <http://ocw.usal.es>
- Ibañez, J. &. (2006). *Sismicidad Volcánica*. Granada - España.
- Körting, T. S. (18 de Febrero de 2014). How kNN algorithm works. Brasil.
- Lara, R. V. (s.f.). Caracterización de un Sistema de Monitoreo del Volcán Cotopaxi empleando Sensores Inalámbricos. *CIRAD*.
- M. Alvarez, R. H. (2007). Clasificación de eventos sísmicos empleando procesos gaussianos. *Scientia et Technica*, 35. Obtenido de Commons Creative CC0: <https://pixabay.com/es/>
- Mistiti M., M. Y. (2011). *Wavelet Toolbox 4 - Getting Started Guide*.

- R. Lara-Cueva, P. B.-A. (February de 2014, 2015). Time and frequency feature selection for seismic events from Cotopaxi volcano. *Asia-Pacific Conference on Computer Aided System Engineering (APCASE)*, 32, págs. 129-134.
- R. P. Duin, M. O.-A.-B. (4 de April de 2010). Classification of volcano events observed by multiple seismic stations. *20th International Conference on Pattern Recognition (ICPR)*, 24, págs. 1052-1055.
- Riera, M., & Tacón, J. C.-P.-A.-D. (2013). Selection of time-variant features for earthquake classification at the Nevado-del-Ruiz volcano. *Computers & Geosciences*. Obtenido de Tlmag: <http://iie.fing.edu.uy>
- Rivera, K. (2013). Mapa de periodos predominantes del suelo del área urbana de la ciudad del Loja (Ecuador), obtenidos a partir de medidas de ruido ambiental. Loja, Loja, Ecuador.
- Sinha, U. (2010). *AI Shack*. Obtenido de AI Shack: <http://aishack.in/tutorials/mathematical-morphology/>
- The MathWorks, Inc. (s.f.). *MathWorks*. Obtenido de Texture Analysis: <https://www.mathworks.com/help/images/texture-analysis.html>
- Viracucha, E. &. (2013). Computer System for Analysis and Seismic Signal Processing Volcanoes in Ecuador, Pyroclastic Flow. *Journal of Geology*, 25-32.
- Y. Peng, R. L. (April de 2008). Design of smart sensing component for volcano monitoring. *IET 4th International Conference on Intelligent Environments*, 14, págs. 1-7.
- Zamorano, M. (2010). *Análisis de Señales mediante STFT y Wavelet. Aplicación a defectología en Rodamientos*. Madrid-España.
- Zobin, V. M. (2011). *Introduction to Volcanic Seismology*.