UC Universidad de Cantabria

Facultad de Ciencias

ELIMINACIÓN DE RUIDO NO ESTACIONARIO EN SEÑALES SÍSMICAS REGISTRADAS EN SISMÓMETROS DE FONDO MARINO UTILIZANDO TÉCNICAS DE UMBRALES Y SEGMENTACIÓN EN LA TRANSFORMADA DE WAVELET CONTINUA

(Denoising in non-stationary seismic signals recorded by ocean-bottom seismometers using thresholding and segmentation techniques in the continuous wavelet transform)

> Trabajo de Fin de Grado para acceder al

GRADO EN FÍSICA

Autor: Miguel Gómez Carral

Director: Alberto Gonzalez Diez Co-Director: Roberto Cabieces Diaz Julio - 2024

Resumen

Los eventos sísmicos detectados en el fondo del océano generalmente están contaminados por ruidos altamente no estacionarios. Estas señales se caracterizan por una baja relación señal-ruido (SNR). Proponemos un nuevo método para mejorar la SNR, basado en la transformada de wavelet continua (CWT) para determinar el plano tiempo-frecuencia y, a través de diferentes técnicas de análisis de señal, eliminar el ruido ambiente y preservar las características importantes de la señal sísmica. Se realizaron pruebas del algoritmo con datos de sismómetros de fondo marino (OBS) de la región del Cabo San Vicente, mostrando mejoras significativas en la claridad y precisión de las señales sísmicas. El método demostró ser eficaz en la eliminación de ruido blanco, ruido de alta frecuencia y ruido en terremotos regionales, manteniendo la integridad de la señal sísmica. Comparaciones entre la señal original y la señal filtrada revelaron una notable reducción del ruido, incluso en niveles bajos de SNR. El algoritmo desarrollado representa una herramienta robusta para la detección e interpretación de eventos sísmicos en diversos contextos de monitoreo sísmico. La metodología basada en CWT y técnicas avanzadas de procesamiento ofrece resultados superiores en comparación con métodos tradicionales, mejorando significativamente la SNR en señales sísmicas no estacionarias.

Palabras clave: Eventos sísmicos, Ruido no estacionario, Transformada de Wavelet Continua (CWT), Análisis de la señal, Sismómetros de Fondo Marino, Ruido Sísmico, Relación Señal-Ruido (SNR), Claridad y precisión, Reducción del ruido.

Abstract

Seismic events detected on the ocean floor are generally contaminated by highly nonstationary noise. These signals are characterised by a low signal-to-noise ratio (SNR). We propose a new method to improve the SNR, based on the continuous wavelet transform (CWT) to determine the time-frequency plane and, through different signal analysis techniques, remove the ambient noise and preserve the important features of the seismic signal. Tests of the algorithm were performed on seabed seismometer (OBS) data from the Cape St. Vincent region, showing significant improvements in the clarity and accuracy of the seismic signals. The method proved to be effective in removing white noise, high-frequency noise and noise in regional earthquakes, while maintaining the integrity of the seismic signal. Comparisons between the original signal and the filtered signal revealed a remarkable noise reduction, even at low SNR levels. The developed algorithm represents a robust tool for the detection and interpretation of seismic events in various seismic monitoring contexts. The methodology based on CWT and advanced processing techniques offers superior results compared to traditional methods, significantly improving the SNR in non-stationary seismic signals.

Keywords: Seismic events, Non-stationary noise, Continuous Wavelet Transform (CWT), Signal analysis, Seafloor seismometers, Seismic noise, Signal-to-Noise Ratio (SNR), Clarity and accuracy, Denoise.

A mis padres y mi familia por su incondicional apoyo.

A mis amigos por sus grandes consejos y en especial, a los chavales, con los que he compartido grandes momentos estos últimos años.

Agradezco profundamente a Alberto, como director de este TFG por todas las horas compartidas durante el trabajo y por su capacidad de transmitir la pasión hacia su trabajo.

A Roberto por su ayuda y orientación durante todo el proceso de este trabajo.

A NEAREST por proporcionar los datos necesarios para llevar a cabo este trabajo.

Índice

	5
2. METODOLOGÍA	7
2.1. Entropía espectral	8
2.2. Transformada de Wavelet continua, CWT	9
2.3. K-means clustering	
2.4. Filtro wiener	14
2.5 Aplicación de la sustracción de ruido	
2.6. Adquisición de datos	
2.7. Zona de estudio	
3. RESULTADOS Y ANALISIS	
3.1 Supresión de Ruido blanco	21
3.1 Supresión de Ruido blanco3.2 Supresión de Ruido en terremoto regional	
3.1 Supresión de Ruido blanco3.2 Supresión de Ruido en terremoto regional3.3 Supresión de Ruido de alta frecuencia	21 23 25
3.1 Supresión de Ruido blanco3.2 Supresión de Ruido en terremoto regional3.3 Supresión de Ruido de alta frecuencia	21 23 25
 3.1 Supresión de Ruido blanco	21 23 25 27
 3.1 Supresión de Ruido blanco	21 23 25 27
 3.1 Supresión de Ruido blanco	21 23 25 27 27
 3.1 Supresión de Ruido blanco	21 23 25 25 27 28

1. INTRODUCCION

El método sísmico es una herramienta fundamental en Física de la Tierra, que permite el estudio de la estructura y dinámica interna del planeta. Se basa en el análisis de las ondas sísmicas generadas por terremotos, así como otras fuentes tanto naturales como artificiales (por ejemplo, las explosiones controladas). Las ondas sísmicas se propagan a través del subsuelo y, al reflejarse o refractarse en los límites geológicos, proporcionan información sobre la estructura interior de la Tierra. Los métodos sísmicos se aplican ampliamente en la detección y prospección de recursos naturales, permitiendo además identificar y analizar las propiedades físicas de los materiales que aparecen dentro de la tierra. Una vez liberada la energía mecánica en el hipocentro del terremoto, se pueden registrar las ondas sísmicas mediante el empleo de sismómetros. Los registros digitalizados o sismogramas nos dan información sobre la Tierra. Mediante estas representaciones se mide la velocidad y el tipo de onda sísmica generadas por la fuente sísmica.

Una de las mayores dificultades derivadas del análisis de sismogramas es la supresión del ruido sísmico (Mousavi et al., 2016; Mousavi y Langston, 2017), ya que puede tener un impacto considerable en la calidad de las interpretaciones realizadas sobre la identificación y análisis de terremotos (Beroza y Jordan 2011). La detección de la señal sísmica es de gran interés en sismología (Mousavi et al., 2016) porque mediante el análisis de sismogramas es posible conocer los tiempos de llegada de las fases sísmicas. Existen muchos trabajos en la literatura enfocados hacia la localización precisa de eventos sísmicos, y la utilización del sismograma para el estudio de la fuente sísmica (Pearson, 1981; Simpson et al., 1988; Mendecki, 1993; Maxwell, 2005; Eisner et al., 2010; Shemeta y Anderson, 2010; Rosca y Maisons, 2012).

La necesidad de conocer mejor el comportamiento dinámico de las placas tectónicas y la exploración de recursos naturales ha propiciado el estudio de la sismicidad en zonas oceánicas mediante el empleo de sismómetros situados en el fondo del océano (por sus siglas en inglés Ocean Bottom Seismometer, OBS). El análisis de los sismogramas obtenidos por estos instrumentos presenta el problema de la eliminación del ruido ambiente oceánico. La señal que detectan los OBS (Figura 1) corresponde tanto a la actividad tectónica del planeta como a otras fuentes no deseadas, como por ejemplo: ruido ambiental del océano (tanto los movimientos en la columna de agua producidos por el viento, o los movimientos de marea, cambios en las corrientes marinas, o la propia dinámica de organismos vivos (Shariat-Panahi 2007); señales electromagnéticas generadas por cables submarinos o equipos de comunicación (Webb 1998; Webb y Crawford 2010). Además, se debe mencionar que las señales registradas por los OBS, a diferencia de las registradas en estaciones en tierra, pueden estar contaminadas por resonancias causadas por el mal acoplamiento del OBS con el suelo e incluso por el efecto de cambios de la presión causados por el oleaje (Webb 1998). Incluso, se han mencionado

otras fuentes de ruido procedentes del tránsito de barcos y cetáceos, etc. Por último, en ciertos escenarios, como áreas volcánicas submarinas, la señal de los OBS puede verse afectada también por el tremor volcánico.



Figura 1.1. Ejemplo de muestra inicial obtenida por un OBS. (NEAREST [Integrated Observations from Near Shore Sources of Tsunamis: Towards an Early Warning System])

A todas las fuentes de emisión mencionadas no deseadas se las conoce como ruido sísmico. Muchos de estos ruidos corresponden a procesos no estacionarios (i.e. varían con el tiempo), lo que complica la determinación precisa del tiempo de llegada de la fase sísmica y sus propiedades (amplitud, frecuencia, etc.), especialmente en entornos submarinos (Webb, 1998). El ruido sísmico es un proceso estocástico que contiene una parte estacionaria y otra no estacionaria (Groos y Ritter, 2009); es decir, una señal que varía continuamente y no posee un patrón que se repita, de manera que su registro no está limitado en el tiempo (Hammond and White, 1996).

La eliminación del ruido sísmico tiene como objetivo aumentar la relación señal-ruido (en inglés Signal Noise Ratio, SNR). Este proceso, realizado a través de diferentes técnicas de análisis de señal, pretende eliminar el ruido ambiente y preservar las características importantes de la señal sísmica. No obstante, dicha eliminación puede distorsionar la señal original y generar artefactos previos a las llegadas del primer impulso de las ondas (Douglas 1997; Scherbaum 2006). Volviendo a las técnicas de análisis de la señal, tal y como indican Mousavi y Langston (2017) en la literatura se han propuesto diferentes métodos para la mejora de la SNR, como por ejemplo: el uso de la transformada S, utilizada en los siguientes trabajos (Ditommaso et al. 2010; Parolai 2009; Pinnegar y Eaton 2003; Schimmel y Gallart 2007; Tselentis et al. 2012); la transformada de radón que emplearon los autores que se citan a continuación (Sabbione, Sacchi, y Velis 2013, 2015; Zhang et al. 2013); la transformada de paquetes de onda (o WPT) presentadas por los siguientes autores (Galiana-Merino et al. 2003; Shuchong y Xun 2014); los filtros f-x o f-k recogidos en los trabajos que se mencionan a continuación (Bekara y Van der Baan 2009; Chen, Ma, y Fomel 2016; Naghizadeh 2012; Naghizadeh y Sacchi 2012); análisis de espectro singular como propone Oropeza y Sacchi (2011), que a su vez están basados en las transformadas dispersas de eliminación de ruido (Chen et al. 2016); asimismo se ha empleado enfoques de eliminación de ruido basado en la morfología matemática (Li et al. 2016); también análisis del espectro singular multicanal amortiguado (Huang et al. 2016); además el uso de algoritmos basados en medias no locales (Bonar y Sacchi 2012); o por último, la transformada de wavelet continua (o CWT) desarrollada por varios autores (Mousavi et al. 2016; Mousavi y Langston 2016; Pazos, y Alguacil 2003; Sobolev y Lyubushin 2006). Es precisamente este último método, el que constituye la hipótesis empleada en el presente trabajo. La CWT aporta una alta capacidad para representar las señales en tiempo-frecuencia; además de flexibilidad para adaptarse a diferentes escalas y frecuencias; es capaz de proporcionar la localización precisa de eventos, y se muestra eficaz para suprimir ruido no estacionario y ofrecer flexibilidad en el diseño del filtro (Li et al. 2018). Además, utilizando la CWT, es posible realizar un filtrado avanzado de la señal aprovechando la propiedad de descomposición en diferentes niveles de resolución del plano tiempo-frecuencia, e identificar la señal sísmica en diferentes bandas de frecuencia. Mediante el análisis del plano tiempo-frecuencia, es posible establecer umbrales de separación SNR para las diferentes bandas de frecuencia o lo que es lo mismo establecer umbrales y segmentar la señal, según los parámetros estadísticos de las componentes espectrales que aparecen en el registro. Por tanto, se puede llevar a cabo un tratamiento de filtrado del ruido no estacionario en señales sísmicas registradas en OBS empleando la CWT.

En línea con el argumento anterior, proponemos como objetivo un método basado en la transformada de wavelet continua que permita mejorar la SNR, con el fin de que se pueda detectar terremotos en ambientes marinos fuertemente contaminados por ruido oceánico. El algoritmo empleado para eliminar ruido (en inglés "denoising") se centra en una técnica que determina con gran precisión la evolución del contenido energético de la señal a diferentes frecuencias y puede separar los componentes que estadísticamente son ruido del resto de la señale, como se explica en el apartado de metodología. El método propuesto se ha probado con datos de una serie de registros OBS de gran apertura desplegados en la región de Cabo San Vicente, como se presenta también en la metodología. Los resultados de dicho filtrado se presentan en el apartado Resultados donde se discutirán. De manera que la presente memoria se ha estructurado en seis capítulos:

• El primero corresponde a esta introducción en donde se explica el contexto general, el estado de las investigaciones previas sobre este tema, la motivación detrás del trabajo y los objetivos de este.

• El segundo capítulo se explica la metodología utilizada para el procesamiento de la señal, el "denoising". Esta se basa en la transformada de wavelet continua y varias técnicas avanzadas de procesamiento de señal.

• El tercer capítulo corresponde a los resultados y análisis de aplicar la metodología, así como una explicación del código empleado.

- El cuarto es donde se exponen las conclusiones de la memoria.
- El quinto capítulo corresponde a las referencias bibliográficas.

• El último capítulo corresponde a los anexos, donde se hace una descripción del código empleado en el presente trabajo y se expone.

2. METODOLOGÍA

El objetivo de la metodología propuesta en este trabajo es eliminar el ruido de señales sísmicas de terremotos regionales y señales de alta frecuencia como las generadas por los cantos de ballenas, detectadas en hidrófonos OBS. Para ello, se ha diseñado un algoritmo de sustracción de ruido o "denoising" en inglés, que emplea varias técnicas avanzadas de procesamiento de señales. Las bases conceptuales de dichas herramientas se presentan a continuación en subapartados. Además, se presenta la estructura del algoritmo de filtrado y los pasos metodológicos que conlleva. Para finalizar se describen los sismómetros empleados y se presenta un breve resumen del contexto geológico en el que se tomaron los datos.

2.1. Entropía espectral

La entropía espectral (que aparece frecuentemente mencionada por sus siglas en inglés Spectral Entropy, SE) es un método numérico procedente de la teoría de la información (rama de la matemática e ingeniería que se ocupa del análisis y la cuantificación de la información, Institute for advances Studies (2024)). La SE cuantifica la complejidad de una señal por medio de la distribución de su potencia espectral (Civera y Surace 2022), o representación que muestra cómo la potencia de una señal se distribuye en función de la frecuencia. Sirve fundamentalmente para segmentar señales, es decir separa lo que es propiamente señal del ruido que contiene. En el algoritmo empleado para limpiar el ruido ("denoising"), se utiliza la SE para poder evaluar el umbral de la señal dominante, aquella que no se ve, en gran medida, afectada por ruido. Así, por ejemplo, una señal x(n), que tiene su transformada de Fourier en X(f), su potencia espectral se define como S(m) = $|X(m)|^2$, mientras que la distribución de probabilidad viene representada por la siguiente ecuación:

$$P(f) = \frac{S(m)}{\int_{-\infty}^{\infty} S(m)dm}$$
(1)

Ahora bien, la SE normalizada viene definida como,

$$H = -\frac{\sum_{m=1}^{N} P(m) \log_2(P(m))}{\log_2(N)}$$
(2)

donde N es el número total de frecuencias en el espectro. Asimismo, hay que tener presente que N representa la máxima entropía para un espectro de ruido blanco (una señal de potencia espectral constante a lo largo de todas las frecuencias). Por otra parte, si en lugar de evaluar el espectro de potencia para toda la señal, tomamos pequeñas ventanas de tiempo solapadas que dividan toda la señal en partes, entonces la potencia es instantánea en el plano tiempo-frecuencia S(t, f), de manera que la distribución de probabilidad para un instante t se puede considerar en función del tiempo como,

$$P(t,m) = \frac{\sum_{t} S(t,m)}{\sum_{t} s(t,f)}$$
(3)

teniendo la entropía espectral en función del tiempo y frecuencia como,

$$H(t) = -\sum_{m=1}^{N} P(t,m) \log_2(P(t,m))$$
(4)

La Figura 2.1.1 muestra la función de SE y su aplicación sobre un terremoto regional. En este ejemplo la SE es capaz de separar (segmentar) la señal del ruido, por encima del umbral previamente establecido.



Figura 2.1.1. Ejemplo de segmentación de señal sísmica utilizando la entropía espectral. En color azul sismograma del terremoto regional y en color verde la función de entropía espectral de la señal.

2.2. Transformada de Wavelet continua, CWT

La transformada wavelet continua (CWT) se define como la convolución de la señal de entrada con una función de wavelet a una escala determinada. Los coeficientes de la convolución a diferentes resoluciones temporales representan la señal en función del tiempo y escala, comúnmente llamado escalograma (Rioul y Flandrin 1992). Esta representación es de gran utilidad ya que permite determinar con gran precisión la evolución de los componentes energéticos de la señal (Figura 2.2.1.)



Figura 2.2.1. Señal sísmica y escalograma asociado. La Figura muestra un sismograma correspondiente a un terremoto regional de magnitud 3.5 en el que se muestra la componente vertical de un OBS: a) sismograma del terremoto; b) escalograma con número de ciclos 6; c) escalograma con número de ciclos 12 (Cabieces et al., 2020).

Estrictamente, la CWT (Daubechies 1992; Mallat 1999) es una convolución de una señal de entrada con una señal de referencia (ondícula o "wavelet"), generada por una wavelet madre" $\psi(t)$, a una escala, a. Esta transformación se puede definir como:

$$W(a,\tau) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \psi^*\left(\frac{t-\tau}{a}\right) dt$$
(5)

Donde * representa el complejo conjugado de la función; τ es el desplazamiento de la wavelet en la convolución y W(a, τ) representa el escalograma.

Por medio de la transformada wavelet inversa, se puede transformar la señal de entrada de vuelta al dominio de tiempo, incluso después de haber manipulado los componentes del escalograma. La CWT es una operación lineal y tiene una transformada inversa exacta dado por la siguiente expresión,

$$f(t) = \frac{1}{c} \int_0^{+\infty} \int_{-\infty}^{+\infty} \frac{1}{\sqrt{a}} W(a,\tau) \psi\left(\frac{t-\tau}{a}\right) \frac{dad\tau}{a^2}$$
(6)

Para implementar la transformada de wavelet, debemos seleccionar una ondícula (*wavelet*) madre que tenga la capacidad de separar los componentes del escalograma con gran precisión. Se debe tener en cuenta que las ondículas generadas deben tener suficiente resolución temporal como para percibir cambios energéticos bruscos de la señal, y poder así detectar señales transitorias enmascaradas dentro del ruido. Además, es conveniente elegir una *wavelet* compleja debido a su capacidad para preservar la información tanto de magnitud y como de fase (Bear y Pavlis 1997). Para este propósito, se ha seleccionado la ondícula denominada *Morlet Wavelet*. Se trata de una ondícula cuasi-analítica, es decir, un tipo específico de wavelet que se diseña para tener propiedades analíticas aproximadas, lo que significa que puede representar señales de manera eficiente, capturando tanto características de frecuencia como de tiempo de manera más precisa que las wavelets estándar. Estas wavelets son particularmente útiles en el análisis y procesamiento de

señales donde se requiere una alta resolución tanto en el dominio del tiempo como en el de la frecuencia. Así, dicha *wavelet* $\psi(t)$, posee una transformada de Fourier $\widehat{\psi}(f) \approx 0$ para f < 0, pudiendose expresar como,

$$\psi(t) = \frac{1}{(\sigma_t^2 \pi)^{1/4}} e^{-\frac{t^2}{2\sigma_t^2}} e^{i2\pi f_c t}$$
(7)

donde,

$$\sigma_{\rm t} = \frac{\omega}{2\pi f_{\rm c}} \tag{8}$$

siendo f_c su frecuencia central, ω es el número de ciclos y σ_t la escala de la wavelet de Morlet. Como se presenta en la ecuación anterior (ec. 7) la wavelet de Morlet está compuesta por el producto de un seno complejo con una función gaussiana que actúa de modulador de resolución de la wavelet y un factor de normalización para asegurar la homogeneidad de la wavelet.

En la Figura 2.2.2 se muestra la Morlet Wavelet en el dominio del tiempo y su descomposición en la parte real y su parte compleja. Por otra parte, en la Figura 2.1.3 se muestra cómo afecta la variación de los parámetros f_c a la generación de la wavelet de Morlet en el dominio del tiempo y de la frecuencia. Volviendo a la Figura 2.2.1, en la misma se presenta cómo se dilata y se contrae la wavelet de Morlet con la elección del número de ciclos ω y su impacto en el ancho de la función gaussiana σ_t . De forma práctica, se suele fijar un numero de ciclos para que wavelet de Morlet tenga una resolución bien equilibrada para las frecuencias bajas, en el caso de sismos regionales f < 0.5 y para las frecuencias altas 0.5 Hz < f < f_s. En este trabajo se ha seleccionado $\omega = 6$, teniendo en cuenta que además esta elección permite una equivalencia directa entre escalas y frecuencias.



Figura 2.2.2. Esquema en el dominio del tiempo de la Morlet Wavelet (Cohen 2014). Parte superior, proyección de la Morlet Wavelet en el plano real (izquierda) y complejo (derecha). Parte inferior, proyección simultánea en el plano real y complejo de la Morlet wavelet (izquierda) y su correspondiente proyección en el dominio del tiempo.



Figura 2.2.3. Efecto de la variación de la frecuencia central en la wavelet de Morlet. A) wavelet de Morlet en el dominio del tiempo para 9 Hz y 10 Hz. B) wavelet de Morlet en el dominio de la frecuencia para las mismas frecuencias que en A, según Cohen (2014).

Por otro lado, la dilatación de la wavelet está controlada por el número de ciclos (ω), y está relacionado con el factor de escala σ_t (ancho de la función gaussiana, como se ha indicado antes), viniendo controlado por la siguiente ecuación (ec. 8). El número de ciclos se establece para controlar el equilibrio entre frecuencia y la resolución temporal definiendo un ancho de la ventana que es de tiempo gaussiana.

2.3. K-means clustering

El algoritmo de "K-means clustering" es una técnica de agrupamiento no supervisado, que permite dividir un conjunto de datos en un número finito de grupos distintos, llamados cúmulos o "clusters" como los representados en la Figura 2.3.1. Las técnicas de agrupamiento o "clustering" se han utilizado ampliamente en el tratamiento de datos sísmicos (Novianti, Setyorini, y Rafflesia 2017). Los datos de entrada provienen del escalograma segmentado en tiempo y frecuencia. El algoritmo de K-means (Zhang et al., 2013) divide los n objetos del análisis en k grupos, de manera que la similitud de los objetos dentro de un grupo sea alta, mientras que la similitud entre grupos sea baja. Este procedimiento requiere de la selección previa del número de grupos. En este caso, para separar el ruido de la señal se emplean dos grupos. El análisis se hace por frecuencias, analizando los agrupamientos en las magnitudes representadas. Se utiliza una distancia mínima euclidiana entre cada objeto y el centroide del grupo al que pertenece para medir la similitud entre objetos dentro de cada grupo (el objeto corresponde al grupo cuvo centroide sea el más cercano). Este paso se desarrolla durante una serie de iteraciones hasta que los centroides no se mueven o se mueven por debajo de una distancia umbral. Por último, se actualiza la posición del centroide tomando el promedio de los grupos. El objetivo del método es minimizar la suma de distancias cuadráticas entre los objetos y sus centroides.

Los objetos se representan como vectores reales de *d* dimensiones $(d_1, d_2, ..., d_n)$. Cada una de las distancias mínimas S={s₁, s₂,...,s_k}para cada centroide de grupo deben cumplir:

$$min_{s}E(\mu_{i}) = min_{s}\sum_{i=1}^{k}\sum_{d_{j}\in S_{i}}\left\|d_{j}-\mu_{i}\right\|^{2}$$

$$\tag{9}$$

La condición a cumplir es que $E(\mu_i)$:

$$\frac{\partial E}{\partial \mu_i} = 0 \Rightarrow \mu_i^{(t+1)} = \frac{1}{|S_i^{(t)}|} \sum_{d_j \in S_i^t} d_j \tag{10}$$

Cada uno de los objetos, se clasifica inicialmente en función del valor medio y del número de puntos vecinos. La similitud se obtiene en función del valor promedio de los objetos pertenecientes al grupo. A cada uno de los objetos analizados se le asigna al grupo más cercano según su distancia con respecto al centro de cada grupo. Luego, se vuelva a calcular el valor promedio de cada grupo de forma iterativa hasta que las variaciones sean mínimas, y la función de criterio converge. Aunque k-means es rápido y sencillo, es crucial elegir el valor de k y considerar la inicialización de los centroides. En el caso del problema tratado en este trabajo k viene definido de entrada (dos grupos: ruido y no ruido). Otro inconveniente es que no siempre converge al mínimo global, sino a un mínimo local.



Figura 2.3.1. Ejemplo de clasificación por medio de *K-means clustering* de una población de objetos considerando dos variables. En el ejemplo se ha seleccionado un k de tres grupos. Pudiéndose comprobar, en las diferentes iteraciones, como se van realizado los ajustes de pertenencia de los objetos a dichos grupos.

2.4. Filtro wiener

El filtro Wiener es un filtro local que está diseñado para localizar artefactos dentro de una señal (Cannistraci, Abbas, y Gao 2015). Su aplicación puede extenderse para el caso de señales en dos dimensiones (escalograma) o dos conjuntos de datos (como por ejemplo tiempo y frecuencia). En este trabajo la aplicación de este filtro se aplica para suprimir artefactos presentes en el escalograma. Básicamente, el filtro Wiener compara el valor medio (μ) y la varianza (σ^2) de los componentes del escalograma (a(n,m)), entre una ventana y su entorno, con el fin de encontrar artefactos, donde:

$$\mu = \frac{1}{NM} \cdot \sum_{n,m} a(n,m)$$
(11)

$$\sigma^{2} = \frac{1}{NM} \cdot \sum_{n,m} [a(n,m) - \mu]^{2}$$
(12)

N es el número de componentes en tiempo y M es el número de componentes en frecuencia.

Una vez aplicado el filtro los nuevos componentes del escalograma estarán determinados por,

$$b_{w}(n,m) = \mu + \frac{\sigma^{2} - \nu^{2}}{\sigma^{2}} [a(n,m) - \mu]$$
(13)

donde v^2 es la variación del ruido. En el caso de que no se proporcione la varianza del ruido gaussiano como entrada, se emplea el promedio de todas las varianzas locales estimadas para cada entorno local.



Figura 2.4.1. Ejemplo de una señal distorsionada a la que se le ha aplicado el filtro Wiener. La primera gráfica la señal original(a), la segunda la señal corrupta (b) y la señal estimada aplicando el filtro (c).

2.5 Aplicación de la sustracción de ruido

En la Figura 2.5.1 se muestra un esquema del algoritmo empleado en el presente trabajo desde un punto de vista metodológico. Dicho algoritmo se describirá posteriormente en el apartado de resultados.



Figura 2.5.1. Esquema del algoritmo de sustracción de ruido sísmico empleado en este trabajo, con los detalles de los procesos implicados en su desarrollo.

La metodología empleada para aplicar el 'denoising' a señales sísmicas y señales de alta frecuencia, detectadas en hidrófonos OBS, se resume de la siguiente forma:

El primer paso es la implementación de la Entropía Espectral (SE), un método de teoría de información que cuantifica la complejidad de la señal mediante la distribución de potencia espectral. La SE analiza la distribución de la señal en términos de probabilidad y se emplea para segmentar señales de ruido. Para esto, se evalúa la señal en pequeñas ventanas de tiempo solapadas, calculando la potencia instantánea en el plano tiempo-frecuencia. La SE se emplea para segmentar la señal sísmica del ruido, estableciendo un umbral que permite diferenciar entre ambos componentes de manera precisa, como se puede observar en la Figura 2.2.1.

El siguiente paso, una vez segmentada la señal y separados los componentes de manera precisa, es la aplicación de la Transformada de Wavelet Continua (CWT). Esta, como se ha desarrollado en el apartado 2.2. produce un escalograma que representa la señal y el ruido en función del tiempo y la frecuencia, determinando con gran resolución la evolución de los componentes energéticos de la señal. Para ello, se seleccionó una wavelet madre adecuada. En este caso, se ha seleccionado la Morlet Wavelet, debido a su capacidad de preservar la información de magnitud como de fase y a que proporciona una resolución equilibrada para frecuencias bajas y altas.

El siguiente paso es aplicar la técnica de clustering en el escalograma segmentado, para determinar el umbral que separa al ruido de la señal en cada escala. Se ha utilizado la técnica de k-means con una inicialización de numero de clusters igual a dos (k=2). Una

vez determinados los umbrales, se asigna un valor próximo a cero, para aquellos componentes del escalograma que están por debajo del umbral.

Finalmente, se aplica un filtro Wiener, que está diseñado para localizar y suprimir artefactos dentro de la señal. Éste funciona comparando la varianza y la media de los componentes del escalograma con los del entorno para así identificarlos y eliminarlos. El filtro, ajusta los nuevos componentes del escalograma para reducir la variación de ruido, mejorando así la calidad de la señal resultante. Este proceso es crucial para eliminar el ruido residual y eliminar componentes espurios, que puedan afectar a la interpretación sísmica.

El algoritmo desarrollado incluye los pasos descritos en la Figura 2.5.1. Ha sido elaborado empleando un código en Python que implementa la metodología presentada anteriormente.

2.6. Adquisición de datos

Los datos analizados con el algoritmo anteriormente presentado se han obtenido a través de sismómetros de fondo marino (OBS). Cada uno de los OBS (Cabieces 2021) empleados está compuesto por cuatro bloques principales: I) Los propios instrumentos (sismómetro e hidrófono), encargados del registro de las señales; II) el ancla que proporciona el peso suficiente para que se hunda el conjunto completo del OBS; III) el sistema de liberación y flotabilidad, compuesto por un receptor de señales acústicas que libera al OBS del ancla al recibir la correspondiente señal de liberación; IV) los elementos de localización (bandera, flashes, y cualquier otro elemento que permita su localización al llegar a la superficie tras ser liberado). El instrumento empleado en este trabajo (Figura 2.6.1) es un sismómetro de la marca KUM-Lobster-6000, que se compone de una fuente de alimentación (baterías de Litio o Alcalinas no recargables), sensores, un reloj interno, un digitalizador y un sistema de almacenamiento de datos. Los sensores utilizados en este trabajo son sismómetros de banda ancha CMG-40T de 60 segundos. En concreto, los componentes del instrumento se muestran en la Figura 2.6.1. La red de sismómetros empleada se compone de 24 OBS cuya distribución se presentará en el apartado siguiente.



Figura 2.6.1. Disposición de los elementos del OBS empleado en este trabajo. Izquierda Lobster-6000, derecha LOBSTER-ultra-deep.

Dicho instrumento se ha instalado en el Océano Atlántico en el margen sur occidental de la península entre septiembre de 2007 y agosto de 2008; un área muy importante como fuente sísmica y tsunamigénica, y de gran interés científico para España y Portugal.

2.7. Zona de estudio

La zona de estudio está ubicada en el golfo de Cádiz, una cuenca marina que se extiende desde el cabo de San Vicente hasta el estrecho de Gibraltar y la costa norte de Marruecos. Desde un punto de vista geomorfológico presenta una plataforma continental somera que va ganando profundidad hacia el oeste, hasta alcanzar una zona abisal que supera los 4500 metros de profundidad. La región incluye importantes cañones submarinos y montes submarinos, como la cordillera de Gorringe y el monte submarino de Coral Patch, que subdividen el área abisal en tres llanuras: Tajo, Herradura y Sena (Figura 2.7.1.).



Figura 2.7.1. La figura muestra la distribución geográfica de la red de sismómetros OBS empleada en el presente trabajo, perteneciente al proyecto de vigilancia sísmica NEAREST. Arriba, se presenta un detalle de la zona de estudio a nivel global. Abajo, se muestra una representación simplificada de la zona en la que se instalaron los OBS. Los triángulos rojos muestran una disposición aproximada de tripletas de instrumentos. a) Cordillera de Gorringe; b) Monte submarino de Coral Patch; c) Llanura de la Herradura; d) Llanura del Tajo; e) Llanura del Sena; f) Prisma de acreción.

Geológicamente, esta área es compleja, con dominios corticales diversos que incluyen corteza continental adelgazada, corteza oceánica jurásica, y corteza de manto exhumado del Cretácico inferior (Claude Shannon, 2017). Está delimitada por el macizo Ibérico y la cuenca del Algarve al norte, y por la cordillera bético-rifeña al este. Sobre esta base heterogénea se deposita una cobertura sedimentaria de varias unidades de edad mesozoica a cuaternaria. La parte más superior está formada por un relleno sedimentario marino. Además, la región presenta numerosos diapiros arcillosos y salinos, así como volcanes de fango.

En concreto, dentro de este entorno geológico la región del suroeste de la Península Ibérica y el norte de África es una zona sísmica de gran complejidad, ubicada entre la porción occidental de la placa Euroasiática y la placa africana (Figura 2.7.2.). Este contacto entre placas conlleva una gran ocurrencia de terremotos significativos en toda la zona. La mayoría, en la región situada entre el Cabo San Vicente y el Golfo de Cádiz. Dichos sismos tienen su epicentro en el mar, lo que dificulta la precisión en la localización de sus epicentros, al carecer de una red sísmica permanente marina. Los únicos instrumentos permanentes están situados en tierra firme a más de 200 km de distancia.



Figura 2.7.2. Mapa de la actividad sísmica y fallas tectónicas ubicadas en la región del golfo de Cádiz. Modelo digital de batimetría del IGN (CC BY 4.0, IGN.es.) y EMODnet Bathymetry (European Marina Observation and Data Network). La información sísmica proviene de la base de datos del Instituto Geográfico Nacional (IGN) (<u>https://doi.org/10.7419/162.03.2022</u>). (<u>https://tiles.emodnet-bathymetry.eu</u>). La figura también muestras las principales fallas activas cuaternarias, extraídas de la base de datos QAFI (García-Mayordomo et al., 2012; <u>IGME, 2022</u>) (De España, s. f.).

Como se ha comentado anteriormente, entre septiembre de 2007 y agosto de 2008 se desplegó una red de 24 OBS frente al suroeste de Portugal, en una zona que abarca el margen suroccidental ibérico (Figura 2.7.1.). Los instrumentos forman parte del proyecto de vigilancia sísmica NEAREST (Integrated Observations from Near Shore Sources of Tsunamis: Towards an Early Warning System) que tiene como objetivo investigar la sismicidad local y la estructura de la Tierra en la región de origen del terremoto y tsunami de Lisboa de 1755 (Silva et al. 2017). Los instrumentos se colocaron en el fondo marino a distintas profundidades, entre 1.993 m y 5.100 m. La extensión del conjunto de instrumentos era de 311.1 km. Para este trabajo se han seleccionado parte de los registros tomados en este proyecto correspondientes a un subconjunto (*subarray*) de OBS (Figura 2.7.1.) del despliegue NEAREST.

Para centrar el debate de la zona estudiada mediante los datos de este trabajo debe destacarse que el array de OBS (Figura 2.7.1.) está situado en el HorseShoe Abbysal Plain y limitada al norte por el Gorringe Bank, al sur por la Siene Abbysal Plain y al este por el Golfo de Cádiz. Concretamente en este entorno la estructura de la corteza de la zona de estudio es compleja y presenta fuertes contrastes y gradientes de velocidad sísmica. La mayoría de las interpretaciones de la cordillera submarina de Gorringe lo consideran un bloque de manto exhumado o un bloque formado por corteza oceánica. Sallarès et al. (2013) modelizaron un perfil sísmico de refracción y reflexión gran angular, y hallaron una gruesa capa de sedimentos en la parte superior del monte, en el HAP (en sismología el término HAP se refiere habitualmente al Harmonic Averege Period que se utiliza para el análisis de señales sísmicas a través de su contenido frecuencial y que se calcula partiendo de la media armónica de los periodos dominantes de la señal, aportando una medida robusta de la frecuencia principal del evento sísmico, Kanamori, H. (1979)). Desde el punto de vista sismológico, la zona de estudio es de gran interés y aún sigue en debate tanto sus principales estructuras geológicas como la geometría del borde de placa Eurasia-Africa. Hasta ahora, no ha sido posible definir inequívocamente la presencia de una frontera convergente entre Eurasia y África (Buforn et al. 2004; Grandin et al. 2007; Pro et al. 2013). Además, se han propuesto varios modelos geodinámicos para explicar la sismicidad de la región (Carminati et al. 1998; Gutscher et al. 2002; Platt et al. 2003), pero las estructuras implicadas en la actividad sísmica siguen siendo objeto de debate. Por otra parte, aunque no se ha identificado de forma convincente ninguna estructura capaz de generar grandes terremotos, se han producido fuertes sismos en la zona. Un ejemplo bien conocido es el terremoto de Lisboa de 1755 (M ~ 8,5, Gutscher 2004; Solares & Arroyo 2004), que generó un tsunami que azotó las costas de Portugal, Marruecos y España. Además, en los últimos 40 años se han producido tres terremotos de Mw superior a 5 al sur oeste del cabo de San Vicente.

3. RESULTADOS Y ANALISIS

A partir de la metodología descrita anteriormente, se ha elaborado un código en Python 3 con el que se han obtenido los resultados del presente Trabajo de Fin de Grado, TFG. El código (ver anexo) está dividido en tres partes. La parte inicial está dedicada a la segmentación mediante el tratamiento de la SE. La segunda parte, esta dedica a la eliminación de ruido propiamente dicha (generación de la CWT; cálculo del espectrograma; determinación de los umbrales por medio del K means clustering, y por último un filtro Wiener para eliminar ruidos en la señal). Finalmente, en el tercer apartado se incluyen toda una serie de herramientas para graficar los resultados.

Más específicamente, la primera parte del código descrito proporciona una clase para el procesamiento de señales sísmicas utilizando varias técnicas de análisis y visualización. Está clase, *SignalProcessing*, incluye métodos para calcular la entropía espectral de una señal sísmica, resaltar regiones de interés basadas en umbrales específicos y graficar los resultados como se ha mostrado en la Figura 2.1.1. La segunda parte del código define una clase que elimina el ruido a partir de la señal segmentada por la primera parte, mediante la combinación de la transformada de wavelet continua (CWT) y las técnicas de filtrado adicionales explicadas anteriormente. El método principal, calcula el espectrograma continuo a partir de los datos segmentados por la entropía y luego emplea esta misma entropía y el K-means clustering para identificar y eliminar frecuencias y

artefactos no deseados. Además, aplica un filtro Wiener, y opcionalmente, algún filtro paso banda, para suavizar la señal, y reconstruye la señal limpia a partir de la CWT. Por último, se ha definido un grupo de herramientas que proporciona ayudas para la visualización, comparación y análisis de las señales empleadas, en el dominio del tiempo-frecuencia. El código se presenta en detalle en los anexos.

El proceso concluye con una señal limpia como la mostrada en la Figura 3.1. En la figura se muestra el plano tiempo-frecuencia resultante, donde se puede observar claramente la efectividad del proceso de denoising, con un aumento significativo de la SNR y sin introducción de artefactos que deterioran la señal de interés.



Figura 3.1. Ejemplo de sustracción de ruido en una señal sísmica mediante la metodología presentada en este trabajo. En la parte superior se muestra la muestra inicial mientras que en la parte inferior se muestra dicha señal, una vez sustraído el ruido.

Con el fin de comprobar la capacidad del algoritmo de filtrado diseñado para mantener alta la relación señal/ruido, se presenta una comparación entre la señal filtrada por el mismo y la filtrada por un filtro paso banda, filtro sencillo y común en procesamiento de señales. Para ello, se ha generado un ruido blanco con el que se ha testado dicha capacidad.

3.1 Supresión de Ruido blanco

Se ha tomado un sismograma de prueba procedente de un registro de un terremoto regional de la misma zona en la que se introducido un ruido blanco. La comparación entre la señal que contiene el ruido blanco y la original nos permite ver la eficiencia del filtrado (Figura 3.1.1). La Figura está compuesta de dos partes, la parte superior (Figura 3.1.1.a.) contiene el sismograma ene l que se ha incluido el ruido blanco, en la parte inferior tenemos el sismograma original (Figura 3.1.1.b.). El ruido agregado está referido en dB respecto al valor máximo de amplitud del sismograma. El paso banda aplicado oscila entre 0.5 y 8 Hz. El panel a) muestra la señal sísmica procesada por dicho filtro de paso

banda procesada en diferentes niveles de relación señal/ruido (SNR) expresados en decibelios (dB). Se puede observar que a diferentes niveles de SNR, la señal muestra una cantidad considerable de ruido residual. Aunque el filtro de paso banda atenúa algunas frecuencias, todavía se observa una mezcla de ruido significativo lo que dificulta la clara identificación de la señal sísmica, sobre todo se ve comprometida a niveles de frecuencias bajos (-20 dB y -15 dB). En el panel b) se muestra la relación señal-ruido aplicando a la señal el 'denoising' usando el algoritmo diseñado en este trabajo. Se puede observar que la metodología de supresión de ruido mejora notablemente la claridad de la señal sísmica a través de los niveles de SNR, lo que facilita la identificación de estos eventos. Incluso en los niveles más bajos (-20 dB y -15 dB), la supresión de ruido muestra una señal mucho más limpia y clara en comparación con el filtro paso banda, lo que destaca la efectividad del método. Esta figura ilustra claramente que la metodología desarrollada es efectiva, bajo la influencia de ruido blanco, en comparación con el filtro de paso banda, que es el comúnmente utilizado en el procesamiento de señales, mejorando la interpretación de la SNR y por tanto el análisis del evento.



Figura 3.1.1. Ejemplo de modificación de la relación señal ruido (SNR) en un sismograma de un terremoto regional, para diferentes frecuencias. a) Señal sísmica en la que se ha introducido un ruido blanco y posteriormente se ha filtrado mediante un filtro de paso banda [0.5 - 8] Hz, b) la misma señal sísmica que en este caso ha sido filtrada por el algoritmo descrito en el presente trabajo. En rojo para todas las señales se presenta la SNR.

3.2 Supresión de Ruido en terremoto regional

En este apartado se presentan los resultados obtenidos al aplicar el algoritmo de desarrollado y descrito en la metodología de 'denoising'. La señal sísmica empleada es la misma que aparece anteriormente en la Figura 3.1., procedente de un terremoto regional obtenida a partir de los sismómetros de fondo marino (OBS). La Figura 3.2.1. ilustra la

efectividad del método desarrollado, mostrando tanto la señal original como la procesada en el dominio tiempo-frecuencia y su espectro de energía. A través de esta comparación, se puede apreciar una notable mejora de la claridad y precisión de la señal sísmica, destacando la reducción del ruido y la mejor definición de las características energéticas de la señal.



Figura 3.2.1. Sismogramas y espectros de energías procedentes de la señal presentada en la Figura 3.1., antes y después de ser procesada mediante la metodología descrita. El gráfico superior corresponde al sismograma de la señal original (a) y su espectro de energías (b), antes de ser procesada. El gráfico inferior corresponde al sismograma de la señal filtrada (c) y su espectro de energías (d), después de ser procesada.

La figura muestra también el plano en tiempo-frecuencia. En la señal original (la parte superior) presenta el dominio del tiempo. En este gráfico se puede observar una gran cantidad de ruido en la señal. La mayor amplitud del ruido se encuentra en baja frecuencia (f<0.5 Hz), que corresponde con el ruido oceánico ambiental. Además de dicho ruido ambiental se encuentran presentes varias bandas de frecuencia saturadas por el ruido, que corresponden a la resonancia del OBS generada probablemente al interactuar el sensor con las corrientes oceánicas. Obsérvese, que este ruido se produce en múltiplos de frecuencia 8 Hz y 16 Hz, constituyendo éste un segundo armónico superior. Por último, se observan pulsos de energía a alta frecuencia, [20-25] Hz, correspondientes con muchísima probabilidad a cantos de ballenas comunes (este aspecto se explorará con más detalle en el apartado 3.3.).

El gráfico de la parte inferior muestra la señal, una vez aplicado el 'denoising'. Ésta es mucho más clara, habiendo eliminado prácticamente todo el ruido. El espectrograma de energías indica una reducción de ruido tanto en frecuencias bajas, como medias y altas, manteniendo la concentración de energía en el evento sísmico principal. También se observa como el ruido monocromático correspondiente a la resonancia del equipo ha sido suprimido en gran medida. La señal procesada aumenta significativamente la relación señal/ruido (SNR) en comparación con el ruido de fondo, como se ha demostrado en el apartado 3.1. Además, este procesamiento no distorsiona la señal original, lo que es crucial para mantener las características del sismo: amplitud, frecuencia, fase y contenido de amplitud espectral. Se puede observar también, que el procesamiento es efectivo en la reducción del ruido de fondo ambiental, a diferentes rangos de frecuencia, y no genera artefactos irregulares en la señal sísmica, separando convenientemente la señal del ruido. Los efectos correspondientes a cantos de cetáceos se describen en el apartado siguiente.

3.3 Supresión de Ruido de alta frecuencia

Para comprobar la versatilidad de la metodología, el trabajo se ha centrado en el rango de las altas frecuencias, lugar en el que suelen aparecer contribuciones debidas a los cantos de las ballenas comunes. Estos sonidos procedentes de las ballenas son muy habituales y se suelen aparecer en los sismogramas marinos dentro del rango de las frecuencias que oscilan entre 20 y 25 Hz como se presentó en la Figura 3.2.1.

La Figura 3.3.1. muestra los resultados de aplicar la metodología de eliminación de ruido a un evento de alta frecuencia registrado en un OBS. La imagen se divide en dos gráficos: el superior que presenta la señal registrada original junto con su entropía espectral y el umbral de ruido. El inferior, muestra la señal registrada una vez ha sido procesada.



Figura 3.3.1. Ejemplo de la supresión de ruido aplicada en una señal sísmica de alta frecuencia, en la que aparecen cantos de ballena. El gráfico superior presenta la señal original con la entropía espectral en verde, en rojo, el umbral de frecuencia. El gráfico inferior muestra la señal una vez aplicada el 'denoising'.

En el gráfico superior se puede observar cómo funciona la entropía espectral y la diferencia entre la señal y el ruido, a partir de la complejidad de la señal y en función del tiempo. Los picos de alta energía (en negro) corresponden a momentos donde la señal contiene eventos significativos. Los valles indican periodos de menor complejidad, generalmente asociados al ruido de fondo. Así mismo, la línea roja define el umbral por debajo del cual se considera o no ruido, y, por lo tanto, es la parte de la señal susceptible de ser eliminada en el proceso de 'denoising'.

La señal después del procesamiento muestra una clara reducción del ruido de fondo, con una amplitud significativamente menor que la original. La reducción de este ruido permite observar el inicio del canto de la ballena y su reflexión en la superficie del mar, facilitando la interpretación (detección, orientación de la señal de llegada y análisis espectral).

En resumen, el resultado de la aplicación del procesamiento sobre señales de alta frecuencia es eficaz, al reducir el ruido en una señal, como se puede observar en la reducción de las oscilaciones que muestra la figura. Además, los picos importantes no solo se han conservado, sino que se han vuelto más claros. Esto asegura que la información crítica de la señal no se pierde, lo cual se debe a la aplicación de la entropía espectral y el umbral de ruido, que permiten identificar de manera efectiva el ruido y, por tanto, las partes relevantes de la señal.

4. CONCLUSIONES

A lo largo de este trabajo, se ha desarrollado y aplicado una metodología para la eliminación de ruido en señales sísmicas a través de un código Pyhton 3. Este algoritmo es capaz de tratar tanto señales sintéticas como otras debidas a sismos regionales. La programación se ha aplicado a señales sísmicas capturadas por sismómetros de fondo marino (OBS) que incorporan señales de alta frecuencia. La metodología combina varias técnicas avanzadas en procesamiento de señales, incluyendo la Entropía Espectral (SE), la Transformada de Wavelet Continua (CWT), el algoritmo de agrupamiento k-means y el filtro Wiener. Las principales conclusiones generales metodológicas extraídas de la aplicación del algoritmo desarrollado en el presente trabajo son: su eficacia para mejorar la SNR de manera que se aporta una mayor claridad y precisión en las señales procesadas. En concreto, las principales conclusiones específicas del método son las siguientes:

- La aplicación de la SE ha permitido una segmentación precisa de la señal sísmica del ruido.
- La CWT se ha constituido como una herramienta fundamental para analizar los componentes energéticos de la señal en el dominio tiempo-frecuencia y proporciona una representación visual precisa y detallada.
- El uso del algoritmo k-means ha permitido llevar a cabo agrupaciones de los componentes de la señal (umbrales de ruido) mejorando la precisión en la sustracción de ruido y garantizando que los componentes relevantes de la señal se mantengan intactos, como se ha visto en los resultados obtenidos.
- El filtro Wiener ha permitido localizar y suprimir los artefactos de la señal mediante la comparación de los valores de la varianza con los de la media de los componentes del escalograma permitiendo identificar el ruido y eliminarlo.

Las principales conclusiones extraídas de la aplicación de este algoritmo a señales registradas por OBS son las siguientes:

- Se ha podido comprobar la eficacia del filtrado y de la mejora de la SNR frente a filtrados tradicionales de pasa banda sin perder las características de la señal.
- Se ha podido procesar una señal sísmica registrada por un sismómetro de fondo marino separando la señal del ruido que va incorporado en la misma.
- Se ha podido identificar cada una de las componentes de la señal, en particular, la de alta frecuencia, procedente con toda probabilidad del canto de cetáceos.
- El método permite su aplicación a cualquier fuente sísmica, lo que implica una gran versatilidad para el tratamiento de diferentes contextos de la monitorización sísmica.

A pesar de los resultados relativamente positivos obtenidos con la aplicación de la metodología descrita, existen áreas en la que esta podría mejorarse:

• La optimización de parámetros iniciales. La selección de parámetros de la CWT y el filtro Wiener podría ser optimizada con técnicas de machine learning, adaptándose a las características de la señal, así como, adaptar automáticamente los umbrales de la entropía espectral en función de las condiciones de ruido.

- También se podrían incluir mejoras mediante el empleo de redes neuronales para desarrollar modelos de aprendizaje que puedan ser entrenados con grandes conjuntos de datos con el din de mejorar aún más la precisión en la identificación de la señal y el ruido.
- Otro aspecto a mejorar es la eficacia computacional. El código desarrollado requiere de un ordenador potente. Optimizar el código para aprovechar mejor el hardware aceleraría el procesamiento de la señal y podría procesarse múltiples señales de forma simultánea.
- Por último, sería conveniente realizar pruebas adicionales con una variedad más amplia de datos sísmicos de diferentes regiones y condiciones de ruido para validar aún más la versatilidad y robustez de la que es capaz la metodología.

5. REFERENCIAS

Bear, Lorie K., y Gary L. Pavlis. 1997. «Estimation of slowness vectors and their uncertainties using multi-wavelet seismic array processing». *Bulletin of the Seismological Society of America* 87(3):755-69.

Cohen, Mike X. 2014. Analyzing neural time series data: theory and practice. MIT press.

Daubechies, Ingrid. 1992. Ten lectures on wavelets. SIAM.

Mallat, Stéphane. 1999. A wavelet tour of signal processing. Elsevier.

Rioul, Olivier, y Patrick Flandrin. 1992. «Time-scale energy distributions: A general class extending wavelet transforms». *IEEE Transactions on signal processing* 40(7):1746-57.

Bekara, Maiza, y Mirko Van der Baan. 2009. «Random and coherent noise attenuation by empirical mode decomposition». *Geophysics* 74(5):V89-98.

Beroza, G. C., y T. H. Jordan. 2011. «Understanding and mitigating the effects of seismic noise on seismic networks». *Annual Review of Earth and Planetary Sciences* 39:93-116.

Bonar, David, y Mauricio Sacchi. 2012. «Denoising seismic data using the nonlocal means algorithm». *Geophysics* 77(1):A5-8.

Cabieces Díaz, Roberto. 2021. «Estudio de la fuente sísmica con estaciones en tierra y mar».

Cabieces, R., Krüger, F., Garcia-Yeguas, A., Villaseñor, A., Buforn, E., Pazos, A., ... & Barco, J. (2020). Slowness vector estimation over large-aperture sparse arrays with the Continuous Wavelet Transform (CWT): application to Ocean Bottom Seismometers. *Geophysical Journal International*, *223*(3), 1919-1934.

Cannistraci, Carlo Vittorio, Ahmed Abbas, y Xin Gao. 2015. «Median Modified Wiener Filter for nonlinear adaptive spatial denoising of protein NMR multidimensional spectra». *Scientific reports* 5(1):8017.

Chen, Yangkang, Jianwei Ma, y Sergey Fomel. 2016. «Double-sparsity dictionary for seismic noise attenuation». *Geophysics* 81(2):V103-16.

Civera, Marco, y Cecilia Surace. 2022. «An application of instantaneous spectral entropy for the condition monitoring of wind turbines». *Applied Sciences* 12(3):1059.

Claude Shannon: The Father of the Information Age. (2017, 28 julio). Institute For Advanced Study. https://www.ias.edu/ideas/2016/claude-shannon

De España, I. G. y. M. (s. f.). *InfoIGME - Catálogo de datos - Mapa Geológico de España* y *Portugal a escala 1:1.000.000 (2015)*. https://info.igme.es/catalogo/resource.aspx?portal=1&catalog=3&ctt=1&lang=spa&dla ng=eng&llt=dropdown&master=infoigme&shdt=false&shfo=false&resource=8833

Ditommaso, Rocco, Marco Mucciarelli, MR Gallipoli, y Felice Carlo Ponzo. 2010. «Effect of a single vibrating building on free-field ground motion: numerical and experimental evidences». *Bulletin of Earthquake Engineering* 8:693-703.

Douglas, A., & Nowlin, M. E. (1997). Terrible honesty: Mongrel Manhattan in the 1920s. University of Toronto Quarterly, 66(3), 576.

Eisner, L., Hulsey, B. J., Duncan, P., Jurick, D., Werner, H., & Keller, W. (2010). Comparison of surface and borehole locations of induced seismicity. *Geophysical Prospecting*, 58(5), 809-820.

Galiana-Merino, JJ, J. Rosa-Herranz, J. Giner, S. Molina, y F. Botella. 2003. «De-noising of short-period seismograms by wavelet packet transform». *Bulletin of the Seismological Society of America* 93(6):2554-62.

García-Mayordomo, J., Insua-Arévalo, J. M., Martínez-Díaz, J. J., Jiménez-Díaz, A., Martín-Banda, R., Martín-Alfageme, S., ... & Linares, R. (2012). The Quaternary active faults database of Iberia (QAFI v. 2.0). *Journal of Iberian Geology*, *38*(1), 285-302.

Hammond, J. K., & White, P. R. (1996). The analysis of non-stationary signals using time-frequency methods. *Journal of Sound and vibration*, *190*(3), 419-447.

Huang, Weilin, Runqiu Wang, Yangkang Chen, Huijian Li, y Shuwei Gan. 2016. «Damped multichannel singular spectrum analysis for 3D random noise attenuation». *Geophysics* 81(4):V261-70.

Li, Huijian, Runqiu Wang, Siyuan Cao, Yangkang Chen, y Weilin Huang. 2016. «A method for low-frequency noise suppression based on mathematical morphology in microseismic monitoring». *Geophysics* 81(3):V159-67.

Li, Juan, Yuan Li, Yue Li, y Zhihong Qian. 2018. «Downhole microseismic signal denoising via empirical wavelet transform and adaptive thresholding». *Journal of Geophysics and Engineering* 15(6):2469-80.

Maxwell, S. C., & Urbancic, T. I. (2005). The potential role of passive seismic monitoring for real-time 4D reservoir characterization. *SPE Reservoir Evaluation & Engineering*, 8(01), 70-76.

Mendecki, A. J. (1993). Keynote address: Real time quantitative seismology in mines. *Rockbursts and Seismicity in Mines*, 287-295.

Mousavi, S. Mostafa, Stephen P. Horton, Charles A. Langston, y Borhan Samei. 2016. «Seismic features and automatic discrimination of deep and shallow inducedmicroearthquakes using neural network and logistic regression». *Geophysical Journal International* 207(1):29-46.

Mousavi, S. Mostafa, y Charles A. Langston. 2016. «Hybrid seismic denoising using higher-order statistics and improved wavelet block thresholding». *Bulletin of the Seismological Society of America* 106(4):1380-93.

Mousavi, S. M., & Langston, C. A. (2017). Automatic noise-removal/signal-removal based on general cross-validation thresholding in synchrosqueezed domain and its application on earthquake data. *Geophysics*, 82(4), V211-V227.

Naghizadeh, Mostafa. 2012. «Seismic data interpolation and denoising in the frequency-wavenumber domain». *Geophysics* 77(2):V71-80.

Naghizadeh, Mostafa, y Mauricio Sacchi. 2012. «Multicomponent f-x seismic random noise attenuation via vector autoregressive operators». *Geophysics* 77(2):V91-99.

Novianti, P., Setyorini, D., & Rafflesia, U. (2017). K-Means cluster analysis in earthquake epicenter clustering. *International Journal of Advances in Intelligent Informatics*, *3*(2), 81-89.

Oropeza, Vicente, y Mauricio Sacchi. 2011. «Simultaneous seismic data denoising and reconstruction via multichannel singular spectrum analysis». *Geophysics* 76(3):V25-32.

Parolai, Stefano. 2009. «Denoising of seismograms using the S transform». Bulletin of the Seismological Society of America 99(1):226-34.

Pazos, A., MJ González, y G. Alguacil. 2003. «Non-linear filter, using the wavelet transform, applied to seismological records». *Journal of Seismology* 7:413-29.

Pearson, C. (1981). The relationship between microseismicity and high pore pressures during hydraulic stimulation experiments in low permeability granitic rocks. *Journal of Geophysical Research: Solid Earth*, 86(B9), 7855-7864.

Pinnegar, C. Robert, y David W. Eaton. 2003. «Application of the S transform to prestack noise attenuation filtering». *Journal of Geophysical Research: Solid Earth* 108(B9).

Kanamori, H. (1979). A semi-empirical approach to prediction of long-period ground motions from great earthquakes. Bulletin of the Seismological Society of America, 69(6), 1645-1670.

Rosca, A., & Maisons, C. (2012, March). Validation of surface and shallow microseismic array for deep reservoir monitoring. In *SPE/EAGE European Unconventional Resources Conference and Exhibition* (pp. SPE-153035). SPE.

Sabbione, Juan I., Mauricio D. Sacchi, y Danilo R. Velis. 2013. «Microseismic data denoising via an apex-shifted hyperbolic Radon transform». P. SEG-2013 en *SEG International Exposition and Annual Meeting*. SEG.

Sabbione, Juan I., Mauricio D. Sacchi, y Danilo R. Velis. 2015. «Radon transform-based microseismic event detection and signal-to-noise ratio enhancement». *Journal of Applied Geophysics* 113:51-63.

Scherbaum, Frank. 2006. *Of poles and zeros: Fundamentals of digital seismology*. Vol. 15. Springer Science & Business Media.

Schimmel, Martin, y J. Gallart. 2007. «Frequency-dependent phase coherence for noise suppression in seismic array data». *Journal of Geophysical Research: Solid Earth* 112(B4).

Shariat-Panahi, Shahram. 2007. Aportaciones a la caracterización y diseño de los sistemas de registro y almacenamiento de datos de los sismómetros de fondo marino (OBS). Universitat Politècnica de Catalunya.

Shemeta, J., & Anderson, P. (2010). It's a matter of size: Magnitude and moment estimates for microseismic data. *The Leading Edge*, 29(3), 296-302.

Shuchong, Liu, y Chen Xun. 2014. «Seismic signals wavelet packet de-noising method based on improved threshold function and adaptive threshold». *Comput. Model. New Tech.* 18.

Silva, PG, PV Gómez-Diego, J. Elez, JL Giner-Robles, MA Rodríguez-Pascua, E. Roquero, A. Martínez-Graña, T. Bardají, y B. Bautista. 2017. «Earthquake environmental effects of the ad 1755 Lisbon-earthquake-tsunami in Spain». *Actas IX Reunión Cuaternario Ibérico, Faro* 53-57.

Simpson, D. W., Leith, W. S., & Scholz, C. H. (1988). Two types of reservoir-induced seismicity. *Bulletin of the Seismological Society of America*, 78(6), 2025-2040.

Sobolev, GA, y AA Lyubushin. 2006. «Microseismic impulses as earthquake precursors». *Izvestiya, Physics of the Solid Earth* 42:721-33.

Tselentis, G.-Akis, Nikolaos Martakis, Paraskevas Paraskevopoulos, Athanasios Lois, y Efthimios Sokos. 2012. «Strategy for automated analysis of passive microseismic data based on S-transform, Otsu's thresholding, and higher order statistics». *Geophysics* 77(6):KS43-54.

Webb, Spahr C. 1998. «Broadband seismology and noise under the ocean». *Reviews of Geophysics* 36(1):105-42.

Webb, Spahr C., y Wayne C. Crawford. 2010. «Shallow-water broadband OBS seismology». *Bulletin of the Seismological Society of America* 100(4):1770-78.

Zhang, Yongqiang, Xudong Zhao, Yi Sun, Min Liu, y Darning Shi. 2013. «Waveform classification based on wavelet transform and k-means clustering». Pp. 1527-31 en 2013 *International Conference on Machine Learning and Cybernetics*. Vol. 4. IEEE.

6. ANEXO

A continuación, se presenta el código empleado para el desarrollo detallado en el apartado de metodología y explicado en el de resultados.

Para realizar el procesamiento y análisis de señales sísmicas, se importan diversas bibliotecas de Python que proporcionan funcionalidades esenciales. Estas incluyen *obspy* para el manejo de datos sísmicos, *numpy* para operaciones numéricas, *scipy.signal* para análisis espectral, y *matplotlib* para la visualización de datos. Adicionalmente, se utilizan *ssqueezepy* para transformadas wavelets y *kmeans1d* para clustering.

Clase SignalProcessing

Esta clase encapsula métodos para el procesamiento de señales sísmicas, incluyendo cálculos de entropía espectral y visualización de datos. Los métodos privados ayudan a encontrar índices y graficar resultados, mientras que los métodos públicos se centran en el cálculo de la entropía y la conversión de escalas a frecuencias.

```
# Importamos las bibliotecas necesarias
from obspy import Trace
import numpy as np
from scipy.signal import periodogram
import matplotlib.pyplot as plt
import warnings
from ssqueezepy.utils import cwt scalebounds
from ssqueezepy import Wavelet, center frequency
# Definimos una clase para el procesamiento de señales
class SignalProcessing:
    # Método privado para encontrar índices que cumplan una condición
en una lista
    def __find_indices(selt, 1st, condition,.
    """ Encuentra los índices de los elementos de la lista que
cumplen la condición"""
        return [i for i, elem in enumerate(lst) if condition(elem)]
    # Método privado para graficar la entropía
    def __plot_entropy(self, tr, data_entropy_trace, thresholds):
    """Función que ggráfica el sismigroma y la entropía espectral,
con diferentes umbrales,
        para resaltar las regiones de interés"""
         fig, ax = plt.subplots(figsize=(12, 8))
        ax.plot(tr.times(), tr.data, linewidth=0.75,
label='Seismogram')
        ax entropy = ax.twinx()
        ax entropy.plot(data entropy trace.times(),
data entropy trace.data, color='green', linewidth=0.75,
                          alpha=0.75, label='Spectral Entropy')
         # Señal binaria para resaltar áreas bajo ciertos umbrales
        binary signal = np.where(data entropy trace.data <=</pre>
thresholds[0], 1, 0)
        ax entropy.fill between(data entropy trace.times(),
binary signal, color='red', alpha=0.3)
```

```
binary signal = np.where(data entropy trace.data >=
thresholds[1], 1, 0)
        ax entropy.fill between(data entropy trace.times(),
binary signal, color='red', alpha=0.3)
        # Líneas horizontales para los umbrales
        ax entropy.axhline(y=thresholds[1], color='black',
linestyle='--', label='Regional')
        ax entropy.axhline(y=thresholds[0], color='red', linestyle='--
', label='Teleseism')
        # Configuración de límites y etiquetas del gráfico
        ax entropy.set ylim(0, 1)
        ax entropy.set xlim(data_entropy_trace.times()[0],
data entropy trace.times()[-1])
        ax.set ylabel('Amplitude')
        ax entropy.set xlabel('Time [s]')
        ax entropy.set ylabel('Entropy')
        ax entropy.legend()
        plt.show()
    # Método para calcular la entropía de un trazo
    def entropy(self, tr: Trace, win, thresholds=(0.2, 0.4),
plot=True):
        """Calcula la entropía espectral de una señal de sismigroma y
puede graficarla opcionalmente"""
        tr.detrend(type="linear")
        data = tr.data
        dt = tr.stats.delta
        # Ajuste de la ventana para ser una potencia de 2
        N = int(win / dt)
        win = 2 ** np.math.ceil(np.math.log2(N))
        t = np.arange(0, len(data), 1)
        Entropy = np.zeros([1, len(t)])
        # Cálculo de la entropía para cada segmento de la señal
        j = 0
        for n in t:
            n = int(n)
            data1 = data[n:win + n]
            Entropy1 = self. spectral entropy(data1, fs=1 / dt)
            Entropy[:, j] = Entropy1
            j = j + 1
        # Procesamiento del resultado de la entropía
        data entropy = Entropy[0]
        data entropy = data entropy[~np.isnan(data entropy)]
        data entropy = np.roll(data entropy, win)
        data_entropy_trace = Trace(data=data entropy,
header={'starttime': tr.stats.starttime, 'sampling rate': 1 / dt})
        data entropy trace.taper(max percentage=0.05)
        data entropy trace.filter('lowpass', freq=0.01, corners=4,
zerophase=True)
        # Encontrar índices que cumplan los umbrales
        thresholds index = []
        for i in range(2):
            th = thresholds[i]
```

```
if i == 0:
                data selected =
self. find indices(data entropy trace.data, lambda e: e <= th)</pre>
            else:
                data_selected =
self. find indices(data entropy trace.data, lambda e: e >= th)
            thresholds index.append(data selected)
            thresholds index.sort()
        thresholds values =
np.unique(np.concatenate(thresholds index))
        # Graficar si es necesario
        if plot:
            self. plot entropy(tr, data entropy trace, thresholds)
        return data entropy trace, thresholds values
    # Método privado para calcular la entropía espectral
        spectral entropy(self, x, fs):
    def
        """Calcula la entropía espectral de una señal dada"""
        x = np.asarray(x)
        # Calcular y normalizar el espectro de potencia
        , psd = periodogram(x, fs, window='hamming', axis=-1)
        psd_norm = psd / psd.sum(axis=-1, keepdims=True)
        se = -(psd_norm * np.log2(psd_norm)).sum(axis=-1)
        se /= np.log2(len(psd norm))
        return se
    # Método para convertir escalas a frecuencias
    def scale to freq(self, scales, wavelet, N, fs=1, kind='peak'):
        """Convierte las escalas de frecuencias usando una wavelet
especifica"""
       if isinstance(scales, float):
            scales = np.array([scales])
        wavelet = Wavelet._init_if_not_isinstance(wavelet)
        # Encontrar límites
        smin, smax = cwt scalebounds(wavelet, N, preset='maximal')
        # Convertir
        freqs = np.array([center frequency(wavelet, s, N, kind=kind)
                          for s in scales])
        # Convertir de radianes a unidades lineales
        freqs /= (2 * np.pi)
        assert freqs.min() >= 0, freqs.min()
       assert freqs.max() <= 0.5, freqs.max()</pre>
        # Unidades físicas (de lo contrario, el resultado es de 0 a
0.5)
        if fs is not None:
            freqs *= fs
        return freqs
```

Clase Denoise

Esta clase se centra en la eliminación de ruido en señales sísmicas. Utiliza la Transformada Wavelet Continua (CWT) y técnicas de filtrado avanzadas para mejorar la calidad de las señales registradas.

```
# Importamos las bibliotecas necesarias
import numpy as np
from ssqueezepy import Wavelet, cwt, icwt
from scipy.signal import wiener
import kmeans1d
from plot tools import Plot tools
from processing tools import SignalProcessing
# Definimos una clase para el procesamiento de ruido en señales
class denoise:
    # Método de clase para denoising de trazas
    @classmethod
    def denoise trace(cls, tr, clean factor=1E-3, win entropy=3,
entropy_threshold=0.3, entropy plot=False,
                      filter=False, plot=False, time freq=False):
        """Elimina el ruido de una traza de señal utilizando la
trasnformada wavelet continua y
        técnicas de filtrado adicionales"""
        # Elimina la tendencia de la traza
        tr.detrend(type="simple")
        print("Estimating Entropy to data segmentation")
        # Estima la entropía para la segmentación de datos
        sp = SignalProcessing()
        data_entropy_trace, thresholds_values = sp.entropy(tr,
win=win entropy, thresholds=(0.10, entropy threshold),
plot=entropy plot)
        tr new = tr.copy()
        # Calcula el espectrograma continuo (CWT) de la señal
        scalogram, scales, * = cwt(tr.data, wavelet="morlet",
scales='log', fs=tr.stats.sampling rate)
        wavelet morlet = Wavelet(('morlet', {'mu': 6}))
        freqs_cwt = sp.scale_to_freq(scales, wavelet_morlet,
len(tr.data), fs=tr.stats.sampling_rate)
        W12 new = scalogram.copy()
        # Elimina las frecuencias no deseadas basadas en la entropía
        wave clean entropy = np.delete(scalogram, thresholds values,
axis=1)
        # Inicializa arrays para almacenar los valores promedio y
mínimos
        a, b = scalogram.shape
        mean = np.zeros([a])
        min values = np.zeros([a])
        # Calcula el umbral usando K-means
        for j in range(a):
            data sort = np.sort(np.abs(wave clean entropy[j, :]))
            clusters, centroids = kmeans1d.cluster(data sort, 2)
            threshold = max(centroids)
            mean[j] = threshold
        kmeans vector = mean
        # Calcula el percentil 97.5 de la señal limpiada
        percentile = np.percentile(np.abs(wave clean entropy), 97.5,
axis=1)
```

```
k = 0
        for i, j in zip(kmeans vector, percentile):
            min values[k] = min(i, j)
            k = k + 1
        # Crea un array de umbrales basados en los valores mínimos
        mean = np.tile(min values, (b, 1))
        mean = np.transpose(mean)
        # Denoising de la señal
        print("Denoising")
        a = np.abs(scalogram)
        theshold = mean
        W12 index = np.where(a < theshold)
        W12 new[W12 index] = W12 new[W12 index] * clean factor
        # Filtro de Wiener para suavizar la señal
        1 = 20
        p = 20
        print("Smoothing stage")
        # Elimina picos y suaviza la señal
        angle = np.angle(W12 new)
        wave wiener = wiener(np.abs(W12_new), (l, p))
        W12 new = wave_wiener * np.exp(1j * angle)
        # Reconstruye la señal a partir del CWT
        data clean = icwt(W12 new, wavelet='morlet', scales='log',
nv=32)
        tr new.data = np.real(data clean)
        # Ajusta la amplitud de la señal limpiada
        k = np.max(tr.data) / np.max(tr new.data)
        tr new.data = k * tr new.data
        # Aplica un filtro de paso de banda si se especifica
        if filter:
            print("Filtering trace")
            tr.detrend(type="simple")
            tr.taper(max percentage=0.05)
            tr.filter(type='bandpass', freqmin=0.5, freqmax=8)
            tr.detrend(type="simple")
            tr new.taper(max percentage=0.05)
            tr new.filter(type='bandpass', freqmin=0.5, freqmax=8)
        # Grafica la comparación entre la señal original y la limpiada
si se especifica
        if plot:
            Plot tools.time compare(tr, tr new)
        # Grafica la representación tiempo-frecuencia si se especifica
        if time freq:
            Plot tools.time freq(tr, scalogram, W12 new, freqs cwt,
water level=-80)
        # Devuelve la señal limpiada
        return tr new
```

Clase Plot_tools

Esta clase proporciona herramientas para la visualización de señales sísmicas. Los métodos incluidos permiten comparar trazas en el dominio del tiempo y visualizar la representación tiempo-frecuencia de las señales.

```
# Importamos las bibliotecas necesarias
import matplotlib.pyplot as plt
import numpy as np
# Definimos una clase para las herramientas de graficado
class Plot tools:
    # Método de clase para comparar trazas en el dominio del tiempo
    @classmethod
    def time compare(cls, tr, tr new):
        """Compara visualmente la traza original y la traza limpiada
en el dominio del tiempo"""
        # Crea una figura con dos subgráficos que comparten el eje x
        fig, axs = plt.subplots(2, 1, sharex=True)
        # Grafica la traza original en el primer subgráfico
        axs[0].plot(tr.times(), tr.data, color='black',
linewidth=0.75, label='Raw Seismogram')
        # Grafica la traza limpiada en el segundo subgráfico
        axs[1].plot(tr.times(), tr new.data, color='blue',
linewidth=0.75, label='Clean Seismogram')
        # Muestra la gráfica
        plt.show()
    # Método de clase para graficar la representación tiempo-
frecuencia
    @classmethod
    def time freq(cls, tr, scalogram, W12 new, freqs cwt,
water level=-80):
        """Visualiza la representación tiempo-frecuencia de la señal
original y la señal limpia"""
       print("Plotting Time-Frequency")
        # Crea una figura con dos subgráficos que comparten el eje x
        fig, axs = plt.subplots(2, 1, sharex=True)
        t = tr.times()
        # Calcula la potencia del escalograma original y la convierte
a dB
        power1 = ((np.abs(scalogram)) ** 2)
        db power1 = 10 * np.log10(power1 / power1.max())
        # Calcula la potencia del escalograma limpiado y la convierte
a dB
        power2 = ((np.abs(W12 new)) ** 2)
        db power2 = 10 * np.log10(power2 / power2.max())
        # Define los límites para la potencia en dB
        a_min = water level
        a_max = 0
```

```
# Recorta los valores de potencia a los límites definidos
        db power1 = np.clip(db power1, a min=a min, a max=a max)
        # Grafica el contorno del escalograma original en el primer
subgráfico
       cs1 = axs[0].contourf(t, freqs cwt, db power1, 50,
cmap=plt.cm.jet)
       vmin = water level
       vmax = a max
       cs1.set_clim(vmin, vmax)
        db power2 = np.clip(db power2, a min=a min, a max=a max)
        # Grafica el contorno del escalograma limpiado en el segundo
subgráfico
       cs2 = axs[1].contourf(t, freqs cwt, db power2, 50,
cmap=plt.cm.jet)
        # Etiquetas para los ejes
        axs[1].set xlabel("Time [s]")
        axs[0].set ylabel("Frequency [Hz]")
        axs[1].set ylabel("Frequency [Hz]")
        # Añade una barra de color al gráfico
        cbar ax = fig.add axes([0.92, 0.15, 0.025, 0.7])
        fig.colorbar(cs2, cax=cbar ax)
        cbar ax.set ylabel("Power [dB]")
       cs2.set clim(vmin, vmax)
        # Muestra la gráfica
       plt.show()
```

Ejemplo de uso

En este apartado del código se proporciona un ejemplo práctico de cómo utilizar las clases definidas para procesar y limpiar una traza sísmica. Se leen datos de una señal sísmica, se aplica el método de eliminación de ruido y se grafican los resultados para comparar la señal original con la limpiada.

```
# Importamos las bibliotecas necesarias
from obspy import read
from obspy import UTCDateTime
from denoise import denoise
# Verificamos si este archivo es el archivo principal ejecutado
if ______mame___ == "____main___":
    # Leemos el archivo de datos de la señal sísmica
    st1 = read('c:/datos TFG/ES.EALB..HHZ.D.2015.260')
    # Seleccionamos la primera traza del Stream
    tr = st1[0]
    # Aplicamos el proceso de eliminación de ruido a la traza
    tr_new = denoise.denoise_trace(tr, clean_factor=1E-6,
entropy plot=True, plot=True, time freq=True)
```