



**Universidad  
Zaragoza**



Trabajo Fin de Máster  
Ingeniería Biomédica  
Curso 2010-2011

## **Análisis de Estimulación Eléctrica Funcional en Señales de EEG**

Ana Isabel Cerrada Baena

Septiembre de 2011

Director: Javier Mínguez Zafra

Departamento de Informática e Ingeniería de Sistemas  
Centro Politécnico Superior  
Universidad de Zaragoza



*A mis padres, por la dedicación, generosidad y apoyo incondicional que siempre me han prestado, por los consejos pronunciados con sabiduría, por transmitirnos fortaleza y esperanza.*

*Mi camino siempre irá junto al vuestro, incluso cuando parezca alejarse, os reencontraré. Gracias por haber hecho de mi la mujer que ahora soy. Por supuesto, esto también es para mis hermanos y mi hermana, que por muchas diferencias que hayamos tenido, han sabido escucharme y apoyarme en los momentos difíciles, así como hacerme sonreír y conseguir que los momentos buenos sean los inolvidables. También me gustaría dedicar este trabajo al resto de mi familia, en especial, a mis abuelos, por los jazmines en flor y las tizas de colores en los escalones, por la música, las excursiones con caracoles y setas, las historias, los despertares...*

*Por estar siempre con nosotros.*

*Unas palabras muy especiales van dirigidas a tí Michael, por tu apoyo siempre incondicional, por escucharme, entenderme y aconsejarme, por enseñarme que hay otra forma de percibir lo que nos rodea y de afrontar los problemas. Tus ánimos de las últimas semanas y la ilusión de empezar nuestra nueva etapa han contribuido mucho en la finalización de este trabajo. Por último, a los que me habéis acompañado este año en Zaragoza, haciendo el año un poco...  
“má fasi”.*



# Resumen

---

En los sistemas gobernados por interfaces cerebro-ordenador (*Brain Computer Interfaces* o BCI) se requiere un alto nivel de procesamiento de señal para extraer la información que resulta de interés, por lo que es muy importante el filtrado de artefactos, es decir, de todas aquellas señales que se registran junto con las señales electroencefalográficas (EEG o electroencefalograma), pero que no resultan de interés para el investigador.

En este trabajo se estudia un artefacto muy concreto, la estimulación eléctrica funcional (*Functional Electrical Stimulation* o FES), ya que actualmente la Universidad de Zaragoza coordina un proyecto de investigación CYCIT en el que se intenta controlar una órtesis robotizada con una BCI haciendo uso de la electroestimulación. El objetivo de este proyecto es, por tanto, conocer cómo afecta una señal de FES a las señales cerebrales y conseguir eliminarla de la señal EEG.

Este proyecto consta fundamentalmente de cuatro fases además de la parte práctica. La primera de ellas consistió en la búsqueda de bibliografía relacionada con las señales de EEG ([1]) y artefactos ([2]), fundamentos de las BCI y técnicas de separación ciega de fuentes, como son los análisis de componentes principales (*Principal Components Analysis* o PCA) y de componentes independientes (*Independent Component Analysis* o ICA).

Posteriormente se procedió a un estudio frecuencial de las señales de EEG contaminadas con FES que fueron proporcionadas por la empresa Fatronik. Posteriormente se aplicaron a esas señales las dos técnicas de separación de fuentes estudiadas para tratar de extraer la señal de artefacto FES del EEG. Ni PCA ni la técnica estudiada inicialmente de ICA consiguieron resultados satisfactorios, por lo que se volvió a la fase de documentación.

En la tercera parte del proyecto se aplicaron nuevos algoritmos de ICA, recurriendo finalmente a la utilización de transformadas wavelets y algoritmos de ICA mejorados con esta transformada para tratar de conseguir el objetivo. Todas las técnicas y algoritmos estudiados se han aplicado a tres conjuntos de datos adquiridos bajo condiciones diferentes en distintos individuos, obteniendo la misma falta de resultados positivos en todos ellos.

Por último, y ante la imposibilidad de encontrar un algoritmo que extrayese el artefacto FES de forma eficiente, no se aplicaron de forma práctica los algoritmos utilizados.

La parte práctica de este proyecto se ha realizado en la *spin-off* Bit&Brain Technologies, donde se ha contribuido de forma activa en experimentos de BCI. Se ha participado en la preparación del equipo y material necesario para proceder a la adquisición de señales de EEG, procediendo a la colocación de los electrodos y visualización de las señales de EEG en un orde-

nador personal. Así mismo, he participado como sujeto en un experimento de BCI siguiendo un protocolo cuya finalidad es extraer características de la señal EEG que permita el reconocimiento de las emociones de un individuo.

# Abstract

---

Electroencephalographic (EEG) recordings usually contain a lot of artifacts besides the signal representing the neural activity of the brain. Especially when using the EEG signal as an input for brain-computer interfaces (BCI) the removal of those artifacts is crucial.

This project had a focus on finding methods in order to remove artifacts generated by functional electrical stimulation (FES) from EEG recordings. Information gathered during this project will serve for a research project with the objective of controlling a robotic prosthesis by a BCI using FES at the University of Zaragoza.

This project basically consisted of four parts. The first step was a literature research regarding the following topics: EEG ([1]) and artifacts ([2]), BCI basics and Blind Source Separation (BSS) such as Principal Component Analysis (PCA) and Independent Component Analysis (ICA). In the second part frequency analysis of several EEG recordings containing FES artifacts were performed. Several BSS methods were applied in order to extract and remove the FES artifacts from the EEG signals. Neither PCA nor ICA achieved satisfying results, so new methods had to be searched. In the third part of the project new ICA algorithms as well as their combination with wavelet transformation ([3]) were investigated. Every method was applied for three different EEG datasets without obtaining any satisfying results. Due to the fact that no satisfying algorithm was found to remove the FES artifact from the EEG recording the practical part of the project consisted of doing experiments with brain-computer interfaces at Bit&Brain Technologies, a spin-off company of the University of Zaragoza. In order to do BCI experiments the electrodes had to be placed on the scalp of the subject as well as the preparation of the EEG acquisition equipment had to be done for monitoring the EEG signal in real time. Further I took part as one of the subjects in an experiment concerning emotion recognition.

New ICA algorithms and wavelet transforms, as well as ICA algorithms enhanced with wavelet transforms ([3]) were applied at this part of the project in order to achieve the main goal. Every technique was applied over three different EEG datasets and any successful result was obtained.

# Índice general

---

<b>1. Introducción</b>	<b>1</b>
1.1. Motivación . . . . .	1
1.2. Planteamiento del Problema . . . . .	2
1.3. Alcance del Trabajo . . . . .	4
<b>2. La Señal de Estimulación Eléctrica Funcional</b>	<b>5</b>
2.1. Registros de EEG . . . . .	5
2.2. Análisis en el Dominio de la Frecuencia . . . . .	7
2.2.1. Métodos . . . . .	7
2.2.2. Resultados . . . . .	8
<b>3. Pre-procesado de la Señal EEG</b>	<b>10</b>
3.1. Transformada Wavelet . . . . .	10
3.1.1. Métodos . . . . .	10
3.1.2. Resultados . . . . .	11
3.2. Análisis de Componentes Principales . . . . .	13
3.2.1. Métodos . . . . .	13
3.2.2. Resultados . . . . .	14
<b>4. Procesado de Señales EEG con Análisis de Componentes Independientes</b>	<b>16</b>
4.1. Métodos . . . . .	16
4.1.1. FastIca e Icaso . . . . .	17
4.1.2. ICA para Distribuciones Supergaussianas . . . . .	18



4.1.3.	ICA para Señales con Estructura Temporal . . . . .	18
4.1.4.	Wavelet ICA . . . . .	19
4.2.	Resultados . . . . .	20
4.2.1.	Aplicación de Fastica e Icasso . . . . .	20
4.2.2.	Aplicación de <i>runica</i> . . . . .	23
4.2.3.	Aplicación de <i>amuse</i> . . . . .	25
4.2.4.	Aplicación de wavelet-ICA . . . . .	25
<b>5.</b>	<b>Conclusiones y Trabajo Futuro</b>	<b>26</b>
	<b>Bibliografía</b>	<b>27</b>

# Índice de figuras

---

1.1. Tren de pulsos y señal resultante . . . . .	2
1.2. Espectro de la señal resultante . . . . .	3
1.3. Señal de EEG con artefacto FES . . . . .	3
2.1. Posicionamiento de los electrodos . . . . .	6
2.2. Estructura de un trial . . . . .	6
2.4. PSD de los canales C2 y C4 . . . . .	9
2.3. PSD de los canales C1 y C2 . . . . .	9
3.1. Esquema de descomposición Wavelet . . . . .	11
3.2. Eliminación de ruido en la señal EEG con FES . . . . .	12
3.3. Eliminación de FES de pequeña amplitud . . . . .	12
3.4. Señal de EEG con FES y Componentes Principales . . . . .	14
3.5. Componentes Principales 1 y 2 . . . . .	15
4.1. Algoritmo del análisis wavelet-ICA . . . . .	19
4.2. ICs estimadas por Icaso - Prueba 1 . . . . .	20
4.3. Índice de calidad y similaridades . . . . .	21
4.4. Clusters de las ICs estimadas . . . . .	21
4.5. ICs estimadas por Icaso - Prueba 2 . . . . .	22
4.6. Índice de calidad y clusters de las ICs estimadas . . . . .	23
4.7. EEG generado por las ICs - <i>runica</i> . . . . .	24
4.8. EEG generado por las ICs - <i>runica-extended</i> . . . . .	24

4.9. EEG generado por las ICs - <i>amuse</i> . . . . .	25
--	----





# 1. Introducción

---

## 1.1. Motivación

La estimulación eléctrica funcional o FES (*Functional Electrical Stimulation*) es una importante herramienta que se utiliza con frecuencia en el ámbito terapéutico y de la rehabilitación. El tipo de tratamiento que se aplica al paciente depende de su patología, encontrándose entre las aplicaciones de esta terapia el tratamiento del dolor (estimulación de fibras nerviosas aferentes sensitivas) o la excitación de las vías eferentes motoras (estimulación de unidades motoras para su recuperación). El Estimulador Nervioso Eléctrico Transcutáneo (*Transcutaneous Electrical Nerve Stimulation* o TENS, [4]) es un equipo de electroterapia muy empleado en la primera de las aplicaciones.

Es la aplicación de estimulación de la vía motora la que genera interés dentro del proyecto de investigación CYCIT coordinado por la Univeridad de Zaragoza. En éste se investiga la posibilidad de controlar una órtesis robotizada mediante una interfaz cerebro-ordenador (BCI), para lo cual será necesaria la adquisición de las señales de EEG. Mediante la BCI se dará la orden de movimiento a la órtesis, que aplicará FES a las fibras motoras que deben estimularse para conseguir la contracción-ralajación muscular.

En la estimulación de la vía motora se emplean pulsos cuyas características de amplitud, anchura o frecuencia dependen del número y tipo de fibras que quieran reclutarse y de la fuerza requerida de la contracción. De acuerdo con los objetivos del FES, deberán configurarse esos parámetros sabiendo que a mayor amplitud del pulso, mayor es la fuerza de la contracción muscular, dado que el número de fibras musculares excitadas es mayor. La frecuencia de los pulsos también es importante, ya que en la electroestimulación no se dan las propiedades de sumación temporal y espacial por las que se caracteriza la estimulación natural de las fibras. La duración de los pulsos puede ser variable, y pueden aplicarse de forma individual o como trenes de pulsos, modalidad utilizada normalmente ([4]).

Cuando se realiza esta estimulación eléctrica, no sólo afecta a las fibras musculares que se pretenden excitar, sino que también son capaces de generar un potencial de acción en las vías aferentes; trasladando el impulso eléctrico hasta el sistema nervioso central. Por tanto, durante la adquisición de la señal de EEG quedará también registrada la señal de FES, que al no ser una señal de nuestro interés consideraremos como un artefacto.

Dado que la BCI controlará la órtesis mediante las señales EEG, es muy importante evitar alteraciones en el comportamiento de la actividad neuronal que puedan provocar un mal funcio-

namiento del dispositivo. El artefacto FES supone precisamente una modificación de ese estado, por lo que es importante caracterizarlo para proceder a su extracción de los registros de EEG, o al menos minimizar en la medida de lo posible sus efectos.

## 1.2. Planteamiento del Problema

En el presente trabajo se aborda el estudio de un problema de mezcla de señales de distintas frecuencias, que se explica a continuación con un ejemplo sencillo. Se cuenta con dos señales  $x_1(t)$  y  $x_2(t)$ , definidas en las ecuaciones (1.1) y (1.2). Como se observa, la señal  $x_2(t)$  es un tren de pulsos cuadrados periódicos en el tiempo, siendo  $\tau$  el ancho del pulso, y  $T$  el periodo del tren de pulsos como se muestra en la Figura 1.1.

$$x_1(t) = \text{sen}(2\pi f_0 t), \quad f_0 = 100 \text{ Hz} \quad (1.1)$$

$$x_2(t) = \sum_n \text{rect}\left(\frac{t - \tau/2 - nT}{\tau}\right) \quad (1.2)$$

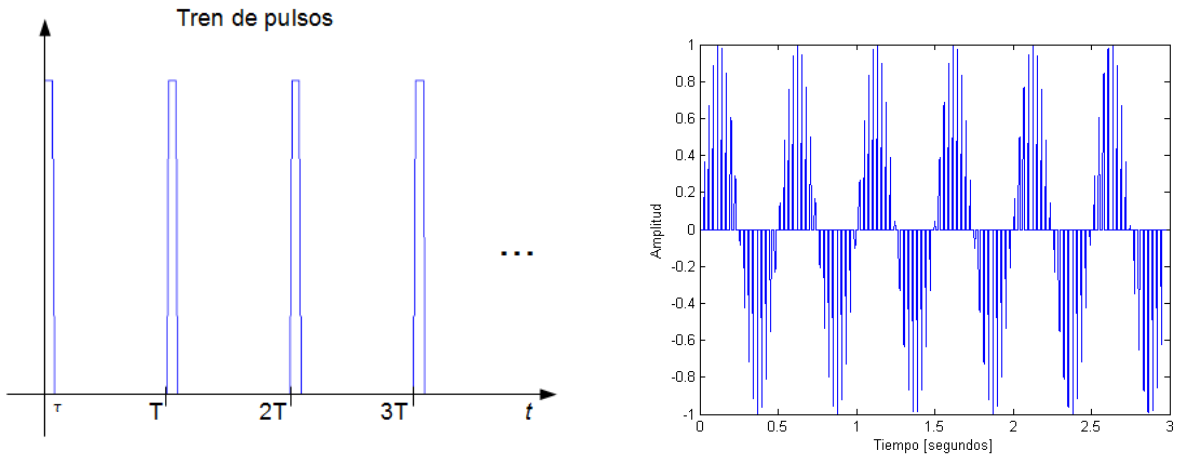


Figura 1.1: A la izquierda se muestra el tren de pulsos cuadrados de frecuencia 35 Hz. A la derecha se observa la señal senoidal multiplicada por el tren de pulsos.

A la derecha de la Figura 1.1 se puede observar la señal  $x(t)$  resultante de multiplicar  $x_1(t)$  y  $x_2(t)$ . En frecuencia esta operación se traduce en la convolución del espectro de las dos señales, por lo que no sólo se mezclan en el tiempo, sino que están mezcladas frecuencialmente. La señal  $x_1(t)$  en frecuencia resulta en una componente situada en -100 Hz y otra en 100 Hz. La señal  $x_2(t)$  es una señal periódica en el tiempo cuya transformada de Fourier también es periódica debido a los armónicos que aparecen en las frecuencias múltiplos de la frecuencia del tren de pulsos (35 Hz). La potencia de la señal está repartida entre todos esos armónicos.




Figura 1.2: A la izquierda se muestra el espectro en frecuencia de la señal  $x(t)$ . A la derecha, dicho espectro en bajas frecuencias, donde se observan los armónicos de la señal

La Figura 1.2 muestra el espectro de frecuencias de la señal  $x(t)$ , con más detalle en la gráfica derecha, donde se observa que existen componentes a baja frecuencia (en 6 Hz) a pesar de que la señal senoidal tiene una frecuencia de 100 Hz y el tren de pulsos de 35 Hz. Esto demuestra la mezcla de frecuencias que se produce en bajas frecuencias.

En este proyecto se analiza la señal de FES, señal periódica a una frecuencia de 35 Hz y que utiliza un pulso bifásico de muy corta duración. Esta situación es, por tanto, análoga a la situación descrita. En los registros de EEG puede apreciarse que las señales de EEG y FES se encuentran mezcladas, como muestra la Figura 1.3. Se observan los 16 canales de EEG registrados en un trial, donde son fácilmente reconocibles a simple vista los picos de FES entre  $t = 3$  y  $t = 6$  segundos. La escala de amplitud está fijada en esta gráfica a  $50\mu V$ , y puede comprobarse también mediante inspección visual que la frecuencia del FES es 35 Hz. Además puede decirse que la transmisión del FES resulta no lineal, puesto que las amplitudes de los picos no son constantes.




Figura 1.3: A la izquierda se muestran los 16 canales de un trial, donde se aprecia el artefacto de FES. A la derecha se observa un detalle del canal C1, uno de los situados más cerca de la corteza motora.



En el análisis frecuencial de la señal EEG se distinguen distintas bandas de frecuencias asociadas a las distintas actividades neuronales, y todas ellas se ven afectadas por la convolución con el espectro del FES. Las principales son las bandas Delta (1-4 Hz), Theta (4-8 Hz), Alpha (8-12 Hz) y Beta (12-30 Hz) ([1]). Los ritmos Mu aparecen en torno a 10 Hz y está relacionado con el área motora, disminuyendo su potencia cuando existe movimiento en las extremidades. En las bajas frecuencias de la banda Beta, entre (12-15) Hz, también se registra actividad de la corteza motora cerebral ([5]). Cuando las áreas motoras cerebrales se activan, la potencia de esta banda disminuye respecto al nivel que tiene cuando no hay movimiento.

Para que la información neurológica de interés de la señal EEG que reside en estas bandas de frecuencias no se vea alterada, es necesario eliminar los artefactos de FES. Esta tarea no resulta eficaz empleando únicamente técnicas de filtrado convencionales, sino que es necesario aplicar técnicas que nos permitan separar las señales de distinta naturaleza. Es por ello que se ha orientado la realización del trabajo a la conocimiento y utilización de técnicas de separación de fuentes como PCA e ICA.

### 1.3. Alcance del Trabajo

El presente Trabajo Fin de Máster requiere profundos conocimientos acerca de señales de electroencefalografía, de interfaces cerebro-ordenador, así como de estadística; por lo que una parte muy importante en el desarrollo de este proyecto ha sido la documentación. Los pasos seguidos en la consecución del objetivo de este proyecto han sido los siguientes:

- **Búsqueda y estudio de documentación** que me permitiera obtener el conocimiento suficiente sobre señales EEG ([1]), interfaces cerebro-ordenador y técnicas de separación ciega de fuentes.
- **Aplicación de las técnicas** estudiadas a diferentes conjuntos de datos de EEG con FES para lograr la extracción del artefacto.
- Estudio y **aplicación de técnicas diferentes** a las ya utilizadas para tratar de conseguir separar ambas señales.
- Participación en experimentos de BCI realizados en la empresa Bit&Brain Technologies, con la finalidad de completar los conocimientos teóricos aprendidos con los conceptos que requiere el uso práctico de esta tecnología

La propuesta del Trabajo Fin de Máster incluía un último apartado en el que se estudia la viabilidad de la aplicación de este proyecto a nivel comercial. Aunque no se hayan obtenido resultados satisfactorios en la extracción de la señal de FES, se han sembrado las bases para la consecución de este objetivo.

## 2. La Señal de Estimulación Eléctrica Funcional

---

En este capítulo se presentan los diferentes registros de EEG con artefactos FES con los que se cuenta. Se extraerán las características de las señales EEG en el dominio temporal, procediéndose posteriormente al análisis frecuencial de las señales.

### 2.1. Registros de EEG

La adquisición de señales de EEG se realiza mediante un gorro en el cual se encuentran situados los electrodos. Dependiendo de la actividad cerebral que quiera registrarse, los sensores deberán estar situados en distintas localizaciones sobre el cuero cabelludo. De las bandas frecuenciales citadas anteriormente, resultarán de interés aquellas que reflejan la actividad de la corteza motora, es decir, los ritmos Mu y las bajas frecuencias de la banda Beta.

Las señales de EEG con artefactos FES utilizadas fueron adquiridas por Fatronik, empresa participante en el proyecto CYCIT. Todos los datos proporcionados se han adquirido con un amplificador comercial g.USBamp de g.Tec, al que se habían conectado 16 electrodos situados sobre el cuero cabelludo en el área de la corteza motora, ya que es ahí donde deben aparecer los efectos neuronales de la electroestimulación motora. Los electrodos fueron colocados en: FC3, FC1, FCz, FC2, FC4, C3, C1, Cz, C2, C4, CP3, CP1, CPz, CP2, CP4 and Pz, y su disposición se observa en la Figura 2.1. Los electrodos de tierra y referencia estaban en los mastoides izquierdo y derecho.

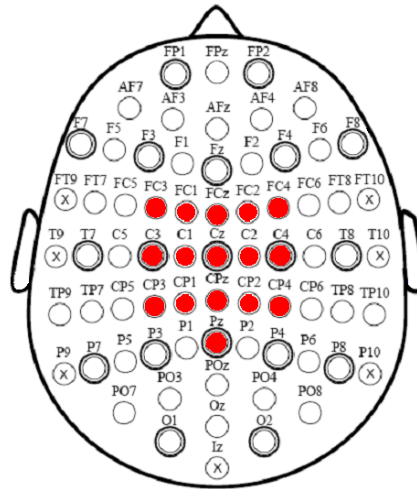


Figura 2.1: Localización de los electrodos sobre el cuero cabelludo.

En la realización de este trabajo se ha contado con dos conjuntos de datos que fueron adquiridos en experimentos configurados con distintos parámetros. En ambos experimentos se situó al sujeto frente a una pantalla que le indicaba lo que debía hacer en cada momento, utilizando protocolos de actuación similares y teniendo ambos la misma estructura de *trials* que se muestra en la Figura 2.2. En ella se observa que tanto al principio como al final del trial se mostraba la pantalla completamente negra para que el sujeto tratase de no pensar en nada, mientras que entre los segundos 3 y 6 de cada trial se le indicó al sujeto la tarea a realizar, que también varió dependiendo del experimento.




Figura 2.2: Estructura temporal de un *trial* correspondiente al registro de EEG

En el primero de ellos, las tareas a realizar fueron imaginar movimiento en el antebrazo izquierdo, en el derecho o la aplicación de FES mediante unos electrodos situados en la muñeca derecha. Estas tres tareas se realizaron el mismo número de veces en una secuencia totalmente aleatorizada hasta registrar 120 trials. La señal fue adquirida con una frecuencia de muestreo de 19.2 KHz, siendo la frecuencia del FES de 25 Hz. En el segundo experimento, se registraron 40 trials donde la única tarea existente entre los segundos 3 y 6 fue la aplicación de FES. En este caso, la señal se muestreó a una frecuencia de 2.4 KHz y el FES se aplicó con una frecuencia de 35 Hz. En ninguno de los dos experimentos se filtró durante la adquisición el ruido de la red eléctrica, por lo que se ha eliminado mediante software con un filtro notch a 50 Hz.

El primer experimento proporcionó dos conjuntos de registros de EEG con artefactos, ya que se realizó el experimento con amplitudes de FES pequeñas y posteriormente con amplitudes de artefacto muy grandes. Aunque todos los análisis presentes en este proyecto se han realizado con los tres conjuntos de datos de EEG proporcionados, se presentan sólo las gráficas y conclusiones alcanzadas para las señales EEG registradas en el experimento 2, ya que con todos los datos se obtuvieron resultados similares.

Normalmente las señales de EEG se muestrean a una frecuencia de 256 ó 512 Hz, por lo que en esta ocasión contamos con una frecuencia de muestreo muy elevada, lo que provoca que en esta señal haya bastante ruido de alta frecuencia. Este ruido resulta ser menor que en el caso de las señales muestreadas a 19.2 KHz.

## 2.2. Análisis en el Dominio de la Frecuencia

En esta sección se presentan las distintas técnicas empleadas para realizar el análisis espectral de las señales de EEG. Este análisis nos permitirá alcanzar un conocimiento más profundo de la señal de FES, puesto que el comportamiento frecuencial de las señales EEG es ya conocido.

Dada la periodicidad de la señal de FES, y según lo visto en el ejemplo de la introducción, su espectro en frecuencia no mostrará únicamente una componente en 35 Hz y el resto de armónicos en todas las frecuencias múltiplos de la frecuencia del FES. Dado que el FES estimulará las fibras motoras, y mediante ésta la corteza motora cerebral, debería producirse un descenso de la potencia en torno a 10 Hz (ritmo Mu) y en la banda baja de Beta. Resulta entonces de importancia conocer cómo se distribuye la potencia de la señal EEG con y sin FES en las distintas bandas de frecuencias, para determinar cuáles son los efectos de este artefacto.

### 2.2.1. Métodos

Para calcular la densidad espectral de potencia o PSD (*Power Spectral Density*) de la señal EEG se utilizará el Método de Welch, que consiste en una mejora del Método de Bartlett. Ambos están basados en la estimación de la PSD de la señal,  $\hat{S}_x(e^{j\omega})$ , mediante el periodograma, definido como la transformada de Fourier de la estimación de la función autocorrelación de la señal (Ecuación 2.1).

Calculando la PSD con el periodograma se obtiene un estimador sesgado, aunque el sesgo disminuye al incrementar el número de muestras que tenga la señal. Sin embargo, resulta un estimador inconsistente ya que su valor no tiende al valor real conforme aumenta el número de muestras, es decir, su varianza no disminuye cuando lo hace el sesgo [6]. La resolución frecuencial que se obtiene con el periodograma está limitada por el número de muestras

$$\hat{S}_x(e^{j\omega}) = \sum_{k=-N+1}^{N-1} \hat{r}_x(k) e^{-j\omega k} \quad (2.1)$$

El método de Bartlett consiste en un promediado de periodogramas eventanados, es decir, se divide la señal original de N muestras en L segmentos de M muestras, y se realiza el periodograma

a cada segmento de  $M$  muestras para promediarlos todos después. De esta forma se consigue disminuir la varianza a cambio de una disminución de la resolución frecuencial. En el método de Welch, la señal se divide en segmentos no consecutivos, es decir, existe solapamiento entre las muestras de dos segmentos.

El método de Welch se ha aplicado a diferentes secciones de la señal EEG dependiendo de si ésta está contaminada o no por el artefacto de FES. De esta forma se obtendrán representaciones frecuenciales en ambas situaciones y podrán compararse los resultados. Es importante decir que el cálculo de la PSD se realiza para cada uno de los canales que registran el EEG, es decir, se calcularán 16 PSDs. Dado que los segmentos sin FES de cada trial van de  $t = 0$  a  $t = 3\text{segundos}$  y de  $t = 6$  a  $t = 10\text{segundos}$ , se han concatenado los segmentos de  $t = 0$  a  $t = 3\text{segundos}$  de varios trials hasta formar otro de 9 segundos de duración. De igual forma, se han formado segmentos de 9 segundos de EEG con artefacto FES, realizando esta tarea para cada uno de los canales. A cada uno de esos segmentos de 9 segundos nos referiremos a partir de ahora como *segmentos artificiales*

La ventana empleada ha sido una Hanning con una longitud de un segundo, con un 50% de muestras solapadas en los segmentos. Además había que seleccionar los puntos con lo que se realizará la FFT, siendo éste un parámetro importante para obtener la resolución frecuencial ( $\Delta f$ ) adecuada. El número de puntos con los que realizar la FFT debe ser al menos el número de puntos de la señal, aunque se ha elegido un mayor número de puntos para *sobremuestrear* la señal y evitar la pérdida de información. La ecuación ( 2.2) indica la resolución frecuencial obtenida.

$$\Delta f = \frac{f_s}{N_{FFT}} = \frac{2400Hz}{2^{14}} \quad (2.2)$$

Tras el cálculo de la densidad espectral de potencia con los segmentos artificiales de cada canal, se realizó la misma estimación para otros segmentos artificiales que se calcularon para poder promediar los resultados por canales.

### 2.2.2. Resultados

Tras la estimación de la PSD para cada canal promediando varios segmentos artificiales, solo se muestran aquí los resultados de aquellos sensores colocados en posiciones más cercanas a la corteza motora cerebral. Esto es, se muestran los resultados obtenidos para los canales C1, C2, C3 y C4. La Figura 2.3 muestra el resultado de aplicar el método de Welch a cuatro segmentos artificiales y promediarlos después. A la izquierda se muestra la PSD estimada para el canal C1 hasta 120 Hz de frecuencia, donde la línea roja representa el EEG sin artefactos FES, y la línea azul el EEG con FES. Es en el espectro de esta última señal donde se observan tres componentes de potencia importante situados en 35, 70 y 105 Hz. La primera componente se debe, como se dijo anteriormente, al artefacto de FES que se aplica al paciente con esa frecuencia. Las componentes presentes en 70 y 105 Hz son los dos primeros armónicos del artefacto FES, es decir, el FES no aparece en una única frecuencia como se esperaba al inicio, sino que en todos los múltiplos de su frecuencia aparecen los armónicos. De esta forma, la potencia de la señal de FES está repartida entre todas estas frecuencias.

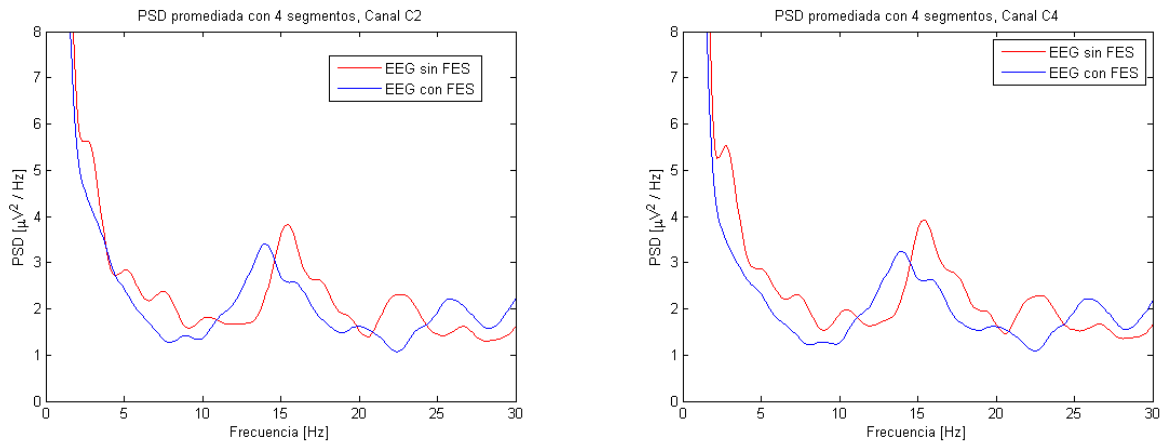


Figura 2.4: Detalle de la distribución de potencia en el promedio realizado en los canales C2 (izquierda) y C4 (derecha).

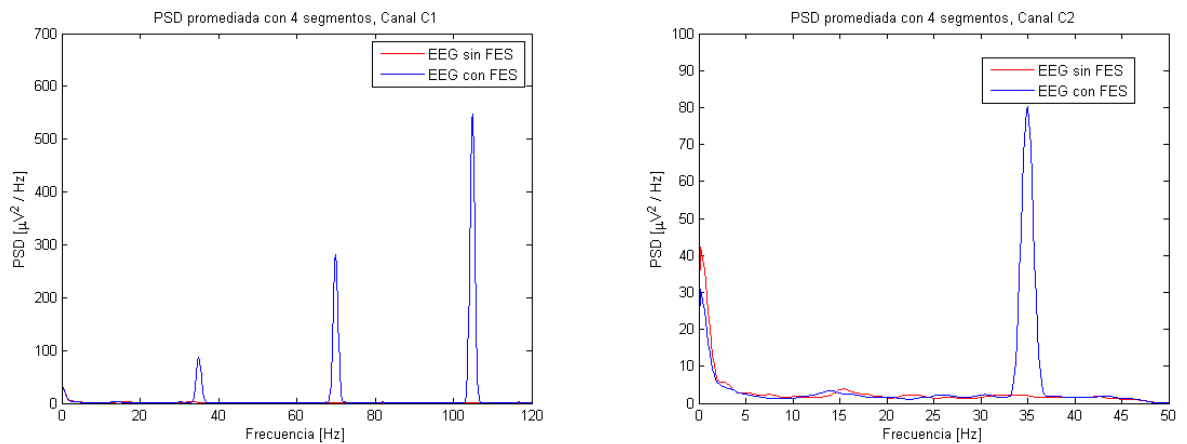


Figura 2.3: Densidad espectral de potencia de los canales C1 (izquierda) y C2 (derecha) tras promediar cuatro segmentos artificiales.

La Figura 2.4 muestra la distribución de potencias en el rango de interés de las señales de EEG. Ante esta gráfica cabe destacar dos resultados importantes relacionados con las bandas frecuenciales alpha y beta. Como se dijo anteriormente, los ritmos Mu tienen lugar en la banda alpha (8-12 Hz), y su actividad se ve atenuada en entorno a una frecuencia de 10 Hz cuando existe movimiento muscular ([5]). Dado que se está produciendo la contracción del músculo, este es el efecto que se observa en ambas gráficas. Además se observa que hay mayor actividad en la parte inferior de la banda beta, comportamiento que se corresponde con la contracción sostenida de los músculos. Recordemos que esta distribución de potencia se ha realizado sobre el segmento artificial. En la realidad, este pico podría ser menos acusado, ya que el FES se aplica sólo durante 3 segundos, no durante los 9 segundos analizados.

Vemos por tanto, que el FES no estimula únicamente las unidades motoras sobre las que se está aplicando, si no que estos efectos también se ven reflejados sobre la corteza motora.

## 3. Pre-procesado de la Señal EEG

---

En este capítulo se expone la teoría en que se fundamentan dos procedimientos aplicados a la señal de EEG con FES. Ambos se utilizan como paso previo en los análisis realizados a las señales en el siguiente capítulo.

### 3.1. Transformada Wavelet

#### 3.1.1. Métodos

La transformada Wavelet es una potente herramienta matemática con la que pueden analizarse señales no estacionarias, es decir, señales cuyas propiedades estadísticas varían de forma considerable con el tiempo ([7], [8]). En el ámbito del procesamiento de señal, la transformada wavelet tiene muchas aplicaciones, como puede ser la eliminación de señales de electromiografía superficial ([9]), eliminación de artefactos oculares ([10]), preprocesado de señal para el reconocimiento de artefactos ([11]), eliminación de ruido ([12]) o junto con ICA ([3], [12], [13]).

La utilización de la transformada Wavelet viene motivada por la insuficiente información que proporciona el análisis de Fourier en determinadas condiciones. Cuando queremos realizar un análisis espectral de señales estacionarias, el análisis de Fourier proporciona resultados satisfactorios. Sin embargo, cuando la señal no es estacionaria, su espectro en frecuencia cambia con el tiempo, por lo que el análisis de Fourier resulta insuficiente. Dada esta situación se recurre al enventanado de la señal para estudiar el espectro en frecuencia de estas señales.

Sin embargo, el análisis Wavelet es el que permite realizar mejor esta tarea, ya que utiliza ventanas temporales cuya duración depende de las características de la señal. Esto quiere decir, cuando se requiere una mayor resolución a bajas frecuencias, la ventana temporal es más amplia; mientras que cuando se requiere una mayor resolución de alta frecuencia se toman ventanas más estrechas. Por todo ello se conoce este análisis como *multiresolución* [7].

Por lo tanto, puede entenderse este análisis como una serie de filtros paso-bajo y paso-alto que separan la señal en diferentes bandas de frecuencias. De esta forma, se separa la parte de señal de más baja frecuencia de la de más alta frecuencia, repitiéndose este proceso sobre las diferentes partes de la señal. La Figura 3.1 muestra un esquema donde pueden verse los pasos sucesivos en este proceso, en el cual el ancho de banda de la señal resultante se va viendo disminuido a la mitad en cada iteración debido a que la señal se va subsampleando.




Figura 3.1: Esquema de la descomposición wavelet

El resultado de la descomposición wavelet se resume en los dos coeficientes que aparecen en este gráfico:  $c_A$  y  $c_D$ . El primero de ellos recibe el nombre de *Aproximación* y contiene la parte de la señal con frecuencias más bajas; mientras que el segundo coeficiente,  $c_D$ , se denomina *Detalle* y contiene la información de más alta frecuencia [7]. Cuando se quiere realizar la descomposición wavelet de una señal de ancho de banda  $B$  Hz, si se emplea un único nivel de descomposición, ésta quedará dividida en dos señales con ancho de banda de  $B/2$  Hz cada una. En tal caso,  $c_A$  abarcaría un rango de  $(0-B/2)$  Hz; mientras que  $c_D$  sería del rango  $(B/2 - B)$  Hz. La gráfica 3.1 muestra más niveles de descomposición, donde son siempre los coeficientes  $c_A$  los que vuelven a ser divididos en niveles superiores.

Esta técnica es utilizada con asiduidad en la eliminación de ruido en señales EEG. Para ello, se descompone la señal con las transformadas wavelets en un número determinado de niveles, según el ancho de banda de señal y cuánto ruido de alta frecuencia queramos eliminar. En este apartado se procedió a la descomposición de la señal en cinco niveles para reconstruir sólo hasta el nivel 3 posteriormente. De esta forma se han descartado los coeficientes  $c_{D4}$  y  $c_{D5}$  que contienen las componentes de más alta frecuencia de la señal. En el siguiente apartado se muestran los resultados obtenidos.

### 3.1.2. Resultados

Tras la reconstrucción de la señal, la Figura 3.2 muestra la comparación de las señales original (EEG con artefacto FES, línea roja) y la señal tras la eliminación del ruido mediante la descomposición y reconstrucción wavelet (EEG sin ruido de alta frecuencia, línea azul). En la gráfica de la izquierda se observa perfectamente que el artefacto FES no consigue ser eliminado completamente. A la derecha, al observar en mayor detalle las dos señales, puede apreciarse que además la aproximación de la transformada wavelet no es buena en los instantes donde tienen lugar los artefactos de FES.

Sin embargo, este resultado no es el mejor de los obtenidos con esta técnica en este proyecto. Al aplicar la transformada wavelet para la eliminación de ruido, se ha constatado a través de los diferentes conjuntos de datos, que la amplitud del artefacto de FES puede resultar determinante para lograr una mejor eliminación. Aplicando este procedimiento al primer conjunto de datos,



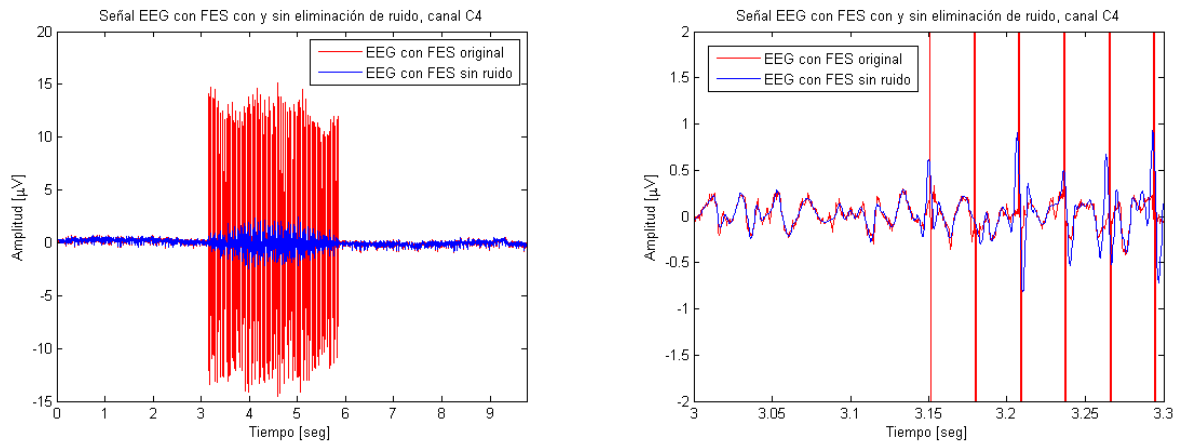


Figura 3.2: Eliminación de ruido en la señal EEG con FES. A la izquierda se observa un trial completo, y a la derecha un detalle de éste, donde se aprecia mejor la eliminación de ruido de alta frecuencia.

en el cual la amplitud de los artefactos de FES es del mismo orden que la señal de EEG, los resultados obtenidos fueron mejores.

El resultado de aplicar el algoritmo a este subconjunto de datos se muestra en la Figura 3.3, donde a la señal de EEG con artefactos de FES de pequeña amplitud (línea roja) está superpuesta la señal filtrada con wavelets. Al calcular el coeficiente de correlación entre ambas, se obtuvo un valor de 0'862, confirmando con este dato el buen resultado que se observa gráficamente.

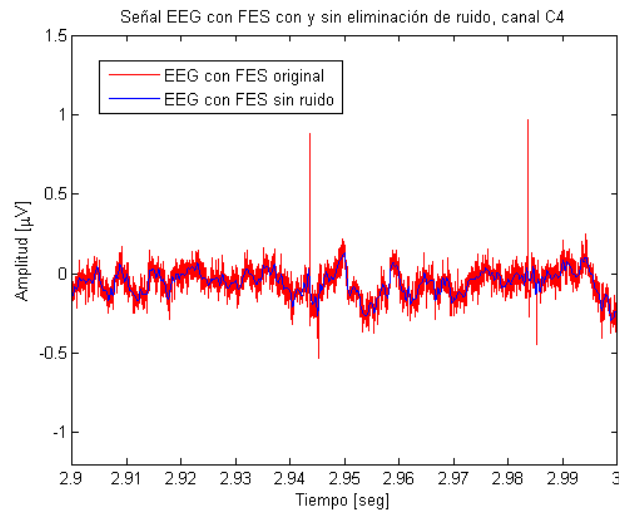


Figura 3.3: Eliminación de FES de pequeña amplitud.

## 3.2. Análisis de Componentes Principales

### 3.2.1. Métodos

El Análisis de Componentes Principales o PCA es una técnica muy empleada en el estudio de datos estadísticos de distinta naturaleza y otro tipo de aplicaciones como puede ser la compresión de datos [14]. Este análisis conforma además uno de los pasos en el Análisis de Componentes Independientes, por lo que también se ha aplicado a los registros de señales de EEG con artefactos de FES con los que se ha trabajado en este proyecto.

Dado el conjunto de señales adquiridas de EEG, denotado por  $\mathbf{x}$ , el análisis se realiza bajo la asunción de que las señales registradas en los distintos canales están correladas entre sí. Utilizando precisamente esa información, se tratará de encontrar una descomposición de las mismas. Para lograr esta descomposición habrá que encontrar un nuevo sistema de coordenadas en el cual las proyecciones de las señales originales queden decorreladas. En este proceso se sigue el orden que se dispone a continuación.

El primer paso en este análisis es extraer la media de las señales EEG bajo estudio,

$$\mathbf{x} \leftarrow \mathbf{x} - \mathbf{E}\{\mathbf{x}\} \quad (3.1)$$

Tras extraer la media debe encontrarse el nuevo sistema de coordenadas, que deberá verificar dos aspectos importantes. El primero de ellos es que las señales de EEG, más concretamente los canales de EEG, queden decorrelados al proyectarse sobre el nuevo sistema de coordenadas. En segundo lugar debe cumplirse que, precisamente esas proyecciones sean las de máxima varianza posible. De esta forma, el primer eje de ese nuevo sistema de coordenadas será la proyección de mayor varianza; el segundo eje será la proyección de segunda mayor varianza; y así sucesivamente.

Para alcanzar la solución del nuevo sistema de coordenadas se sigue el desarrollo matemático que se explica a continuación, en el que la primera componente principal queda expresada según la ecuación (3.2), donde los  $x_k$  son los elementos de  $\mathbf{x}$  (señal de EEG de media nula), y los  $\omega_{k1}$  son los coeficientes o pesos que maximizan la varianza de la primera componente  $y_1$ .

$$y_1 = \sum_{k=1}^n \omega_{k1} x_k = \omega_1^T \mathbf{x} \quad (3.2)$$

Dado que la varianza de  $y_1$  depende tanto de la norma como de la orientación del vector de pesos  $\mathbf{w}_1$ , y crece ilimitadamente con la norma de  $\mathbf{w}_1$ , se impone como restricción que la norma de  $\mathbf{w}_1$  sea constante e igual a la unidad. Se busca entonces un vector de pesos  $\mathbf{w}_1$  que maximice el criterio dado por la ecuación (3.3), que representa la varianza de la proyección del vector de media nula  $\mathbf{x}$  en el vector director  $\mathbf{w}_1$ .

$$J_1^{PCA}(\mathbf{w}_1) = E\{y_1^2\} = E\{(\mathbf{w}_1^T \mathbf{x})^2\} = \mathbf{w}_1^T E\{\mathbf{x}\mathbf{x}^T\} \mathbf{w}_1 = \mathbf{w}_1^T \mathbf{C}_x \mathbf{w}_1 \quad (3.3)$$

La matriz  $\mathbf{C}_x$  no es más que la matriz de covarianzas de la señal  $\mathbf{x}$ , que al ser  $\mathbf{x}$  de media

nula, se reduce al cálculo de la matriz de correlación  $\mathbf{C}_x = E \{ \mathbf{x}\mathbf{x}^T \}$ . Para encontrar los valores que maximizan dicha función, la solución consiste en calcular los vectores y valores propios de la matriz de correlación  $\mathbf{C}_x$ . De esta forma, ordenados los vectores propios  $\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_n$  en orden decreciente de los valores propios  $d_1 \geq d_2 \geq \dots \geq d_n$ , la solución  $\mathbf{w}_1 = \mathbf{e}_1$  maximiza la ecuación (3.2). De este modo, la primera componente principal viene determinada por la expresión  $y_1 = \mathbf{e}_1^T \mathbf{x}$ .

Para hallar el resto de componentes se añade la condición de que la componente principal a calcular debe estar incorrelada con las encontradas anteriormente. En [14] y [15] puede encontrarse información más detallada respecto a la obtención del resto de componentes principales, que pueden escribirse según la Ecuación 3.4.

$$y_k = \mathbf{e}_k^T \mathbf{x} \quad (3.4)$$

Dada la naturaleza del problema a analizar en este trabajo, esta técnica de separación ciega de fuentes resulta apropiada para tratar de separar la componente de FES del EEG. Por ello, se aplica PCA a los registros de EEG con los que se cuenta.

### 3.2.2. Resultados

En esta sección se muestran los resultados obtenidos tras realizar PCA con varios trials, de los que sólo se consideraron los segundos donde el EEG estaba contaminado con FES, tal como muestra la gráfica izquierda de la Figura 3.4. En este caso se cuenta con 16 señales, cada una registrada por un sensor del casco, con una duración de 10 segundos. El primer paso a realizar es la extracción de la media de cada uno de los canales, para calcular posteriormente la matriz de correlación  $\mathbf{C}_x$  y sus correspondientes valores y vectores propios. Tras ordenar éstos, se obtienen las componentes principales según la expresión de la Ecuación 3.4.

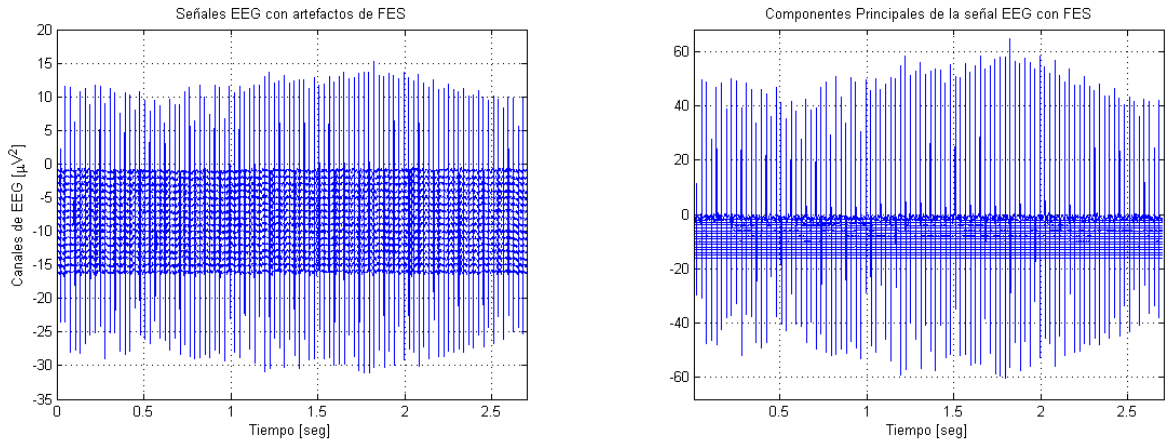


Figura 3.4: A la izquierda se muestra la señal de EEG con FES de uno de los trials del conjunto de datos. A la derecha se observan las componentes principales obtenidas tras aplicarle PCA.

Tras aplicar PCA a las señales de EEG con FES que muestra la gráfica izquierda de la

Figura 3.4, se obtuvieron las componentes principales que se observan en la gráfica izquierda de la misma figura. Para analizar si este resultado es correcto y la señal de FES se ha separado del EEG, ha de prestarse mayor atención a la señal existente entre los picos de FES. Cabe esperar, si las señales de EEG y FES han quedado completamente decorreladas, que la componente de FES contenga los picos y algo de ruido entre ellos, pero no sería aceptable encontrar amplitudes del orden de amplitudes EEG entre picos de FES.

Esto se observa en mayor detalle en la Figura 3.5, donde la escala es de  $50 \mu V$ , que muestra a la izquierda la primera de las componentes principales calculadas mediante PCA, y a la derecha, la segunda de ellas. La diferencia entre la amplitud de ambas era de esperar, ya que la primera componente es la que tiene mayor varianza. Según lo descrito anteriormente, podría considerarse que la señal que se observa entre los picos de FES es señal EEG.

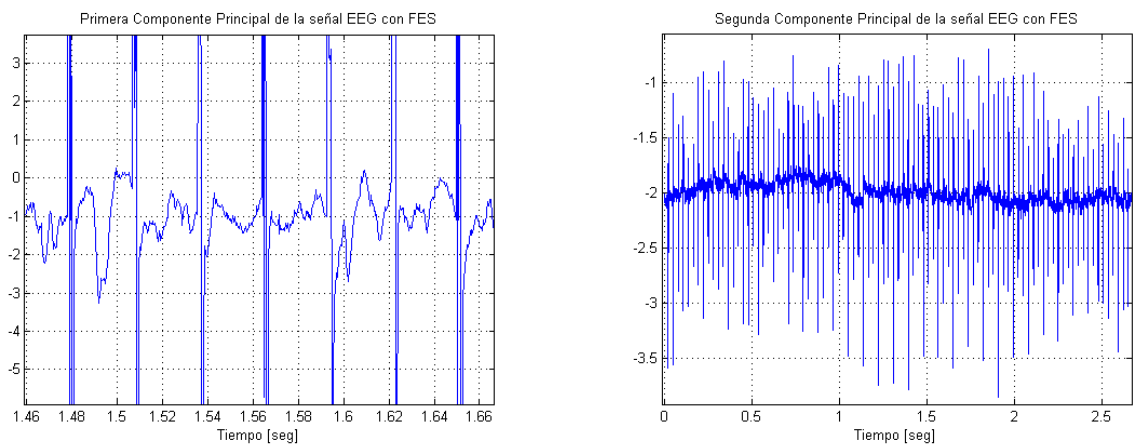


Figura 3.5: A la izquierda se muestra la primera componentes principal hallada, mientras que a la derecha se muestra la segunda de ellas.

Por tanto, al considerar que existe actividad neuronal en la componente de máxima varianza, que es el FES, puede concluirse que la técnica PCA no ha logrado separar ambas señales. La razón por la cual esta técnica no ha resultado efectiva es que, a pesar de haber decorrelado los datos, existen infinitas decorrelaciones posibles. Al resultar las señales de EEG y FES estadísticamente independientes, la técnica PCA no es suficiente para resolver este problema.

## 4. Procesado de Señales EEG con Análisis de Componentes Independientes

---

El Análisis de Componentes Independientes o ICA es una herramienta estadística muy empleada en investigación en el ámbito de señales EEG, ya que pertenece al grupo de técnicas de separación ciega de fuentes. Con este análisis se consigue la separación de componentes independientes, por lo que es muy empleado en el reconocimiento y extracción de artefactos en la señal EEG. En este capítulo se presentan los diferentes ICAs con los que se ha trabajado en este proyecto.

### 4.1. Métodos

Durante la adquisición de señales de cualquier naturaleza, los registros no reflejan la información que en un principio contenían las señales por sí mismas, aisladas, sino que se produce una superposición de las mismas que impide reconocer en los registros las señales que fueron originales, siendo éstas además desconocidas.

El problema conocido como *cocktail-party* es un claro ejemplo de mezcla de señales que se analiza con este método ([14], [15]), y que aquí sirve de referente por su analogía con la problemática que surge en los registros de señales EEG. Al llevar a cabo esta adquisición, las señales se registran de forma no invasiva sobre el cuero cabelludo, es decir, los sensores miden la actividad eléctrica cerebral que hay en esta superficie, a este nivel. Es por ello que la actividad eléctrica registrada no coincide con la actividad eléctrica original, ya que desde las fuentes que han originado las señales hasta el punto en el que se han registrado, la señal eléctrica se ha transmitido y ha atravesado diferentes medios. Es aquí donde resulta de utilidad la técnica que nos ocupa, ya que a partir de las señales de EEG grabadas, ICA es capaz de estimar las componentes independientes que las han originado.

La diferencia principal con PCA es que ésta se basa en la correlación existente entre las señales de EEG para estimar las componentes principales, mientras que ICA exige una condición más restrictiva: la independencia estadística. Matemáticamente podemos expresar el problema a resolver como sigue

$$\mathbf{x} = \mathbf{W} \mathbf{s} \tag{4.1}$$

donde la matriz  $\mathbf{W}$  es la matriz de mezcla o de pesos que combina las fuentes independientes

para dar lugar a las señales medidas,  $\mathbf{x} = \{x_1(t), x_2(t), \dots, x_n(t)\}$  son los registros de EEG,  $\mathbf{s} = \{s_1(t), s_2(t), \dots, s_n(t)\}$  son las fuentes que han originado la actividad cerebral recogida. Es suficiente asumir que las componentes  $s_1(t), s_2(t), \dots, s_n(t)$  son estadísticamente independientes para cada instante  $t$  [14].

Otra restricción que se impone para realizar ICA es que las componentes independientes deben seguir distribuciones no gaussianas. La razón de esta exigencia viene dictada por el Teorema Central del Límite, que dice que la distribución estadística que sigue la combinación lineal de variables aleatorias independientes tiende a una distribución gaussiana. Por lo tanto, cuanto menos gaussiana resulte la distribución, más se acercará la variable a ser una componente independiente [14]. Considerando  $\mathbf{y}$  como una combinación lineal de las fuentes independientes  $s_i$  (4.2) debe maximizarse su no gaussianidad.

Considerando las señales de EEG que nos ocupan, cuantificaremos cuán gaussiana es su distribución estadística a partir de la neguentropía. Existen otros indicadores para realizar este cálculo, como por ejemplo la *kurtosis*, que es una medida del apuntamiento o forma de la distribución. Sin embargo, esta medida es muy sensible a *outliers*, por lo que dada la elevada amplitud de los picos de FES, no emplearemos esta medida.

La neguentropía puede definirse como la información que proporciona la observación de la variable,  $\mathbf{y}$ , considerando que su media es nula y su varianza la unidad ([14]). La ecuación (4.2) define este concepto, siendo  $H(\mathbf{y})$  la entropía de la variable. Como se observa, está definida a partir de la entropía de una variable gaussiana, ya que son este tipo de distribuciones las que tienen el mayor valor posible de entropía. Por lo tanto, la neguentropía es una medida óptima de no gaussianidad, ya que maximizar este parámetro implica que la variable  $\mathbf{y}$  es lo menos gaussiana posible.

$$J(\mathbf{y}) = H(\mathbf{y}_{\text{gauss}}) - H(\mathbf{y}) \quad (4.2)$$

Para calcular la neguentropía se aproximará (4.2) mediante funciones de coste o funciones objetivo,  $G$ , expresando la neguentropía según (4.3); proceso que puede verse con mayor detalle en [16].

$$J(\mathbf{y}) \approx c [E \{G(y_i)\} - E \{G(\nu)\}]^2 \quad (4.3)$$

Existen diversos algoritmos para lograr maximizar esta expresión, algunos de ellos utilizados en este trabajo y que se exponen a continuación. Resulta relevante remarcar que ICA es un proceso estadístico, y como tal, su fiabilidad no es absoluta ([17], [18]).

#### 4.1.1. FastIca e Icasto

Esta versión de ICA está basada en el algoritmo de punto fijo de Hyvärinen, y debe su nombre a que el algoritmo es entre 10 y 100 veces más rápido que el de descenso por el gradiente [19] (también utilizado para realizar ICA). Como se explica de forma más detallada en [16], este algoritmo trata de maximizar las funciones de coste para maximizar la neguentropía. Entre estas funciones están las que se encuentran detalladas en las ecuaciones (4.4) y (4.5),

$$G_1(u) = \frac{1}{a_1} \log \cosh(a_1 u), \quad g_1(u) = \tanh(a_1 u) \quad (4.4)$$

$$G_2(u) = \frac{-1}{a_2} \exp\left(\frac{-a_2 u^2}{2}\right), \quad g_2(u) = u \exp\left(\frac{-a_2 u^2}{2}\right) \quad (4.5)$$

La primera de ellas es una función de coste de propósito general, mientras que la segunda suele emplearse cuando las componentes independientes siguen una distribución estadística supergaussiana. Dado que ICA es un proceso estadístico, la ejecución del análisis del mismo conjunto de señales EEG no siempre proporciona las mismas soluciones.

Por ello se hace uso del software de investigación *Icasso*, que permite estudiar la fiabilidad de los resultados de ICA [17, 18]. Para ello se ejecuta el algoritmo *fastica* un número determinado de veces, obteniendo tras cada ejecución unas componentes independientes distintas. Se procede entonces al agrupamiento de los resultados en *clusters* para determinar las componentes independientes medias, que serán los centrotipos de cada cluster [17].

#### 4.1.2. ICA para Distribuciones Supergaussianas

Aceptando la teoría expuesta sobre ICA, cuando las distribuciones de los datos son supergaussianas, el algoritmo *fastica* no proporciona resultados satisfactorios, es decir, no es capaz de recuperar la componentes independientes si éstas se distribuyen estadísticamente de esa forma. Sin embargo, existen algoritmos de ICA que permiten el tratamiento de distribuciones supergaussianas, como puede ser *runica*, que está basado en el algoritmo Infomax ([20]) y su algoritmo extendido ([21]).

Este algoritmo también se aplicará sobre los datos de EEG con FES, y en él pueden controlarse parámetros como número de componentes independientes a estimar, el error mínimo que debe alcanzar la función de convergencia (condición de parada del algoritmo) o el parámetro *extended*, que permite especificar si las distribuciones son supergaussianas.

#### 4.1.3. ICA para Señales con Estructura Temporal

Normalmente las señales temporales cuentan con mucha más estructura que una simple variable aleatoria. Esta característica se tiene en cuenta en este tipo de ICA basado en el cálculo de autocovarianzas. Éstas no son más que el cálculo de la covarianza sobre distintos intervalos de tiempo. Para aplicar este ICA se asume que las autocovarianzas de las componentes independientes son todas distintas de cero y sus varianzas son no estacionarias, es decir, varían dependiendo del intervalo donde se calculen ([14]).

El algoritmo de ICA *amuse* funciona bajo estas premisas, y utiliza el concepto de la autocovarianza como medida alternativa a la no-gaussianidad cuando se trabaja con señales correladas en el tiempo ([14]). Este ICA también se ha aplicado a los datos de EEG con artefactos FES.

#### 4.1.4. Wavelet ICA

La transformada wavelet se utiliza en el tratamiento de señales biológicas con distintas finalidades como ya se ha comentado anteriormente. En esta sección se utiliza la transformada wavelet para descomponer la señal en diferentes rangos de frecuencia. De esta forma, cuando se conoce la frecuencia a la que afecta el artefacto (en este caso el FES), se puede realizar el análisis de ICA sólo sobre aquellos rangos de frecuencia en los que afectan los artefactos [13]. Una vez estimadas las componentes independientes, se identifican aquellas que representan al artefacto para poder eliminarlo. Al utilizar ICA sólo en aquellas frecuencias contaminadas por el artefacto, se minimizan las pérdidas de la señal EEG que reside en la componente independiente del artefacto que debe eliminarse para suprimirlo de la señal. En la parte izquierda de la Figura 4.1 se observa el diagrama del algoritmo propuesto en [13], y que aplicaremos al conjunto de señales de EEG con artefactos de FES. El procedimiento es el siguiente:

- Realizar la transformada wavelet con el número de niveles adecuado para separar la señal en los rangos de frecuencia que resultan de nuestro interés.
- Seleccionar, mediante inspección visual, las componentes wavelets (rangos de frecuencia) que están afectadas por el artefacto y realizar ICA con esas componentes.
- Seleccionar las componentes independientes correspondientes al artefacto y eliminarlas, para deshacer posteriormente ICA y obtener las componentes wavelets modificadas, sin artefacto.
- Por último, reconstruir las componentes wavelets para recuperar las señales de EEG en el dominio temporal, esta vez ya sin FES.

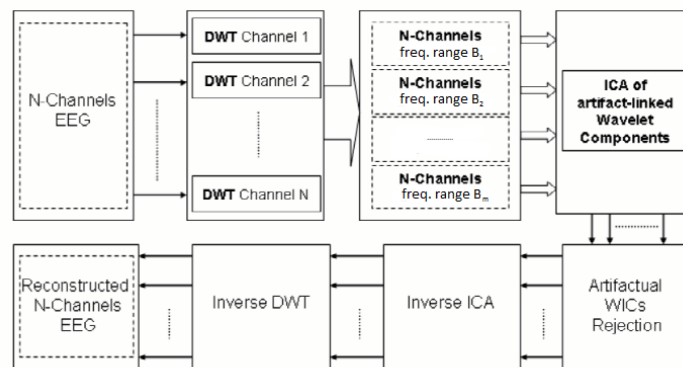


Figura 4.1: Algoritmo del análisis wavelet-ICA.

Dado que el espectro en frecuencia de las señales EEG que nos ocupan están en el rango de frecuencias de 0 a 1200 Hz, y el FES tiene una frecuencia de 35 Hz, la descomposición wavelet necesaria, si se quisiera aislar el artefacto, es de 5 niveles. Sin embargo, la tarea de aislar el artefacto FES no resulta trivial, ya que como se ha explicado, se encuentra mezclado con la señal de EEG. Aun así, se procede a la descomposición para tratar de aplicar el algoritmo descrito en las bandas frecuenciales donde se detecten artefactos.



## 4.2. Resultados

### 4.2.1. Aplicación de Fastica e Icasto

En este apartado se muestran los resultados obtenidos al aplicar el software Icasto con determinados parámetros de entrada. Se han realizado dos baterías de pruebas con Icasto, cada una de ellas con una de las funciones objetivo (derivadas de las funciones de contraste  $G$ ) definidas en (4.4) y (4.5). Se ha configurado Icasto para ejecutar 20 veces el algoritmo fastica con la intención de estudiar la convergencia del mismo en cada prueba y determinar las componentes independientes. Así mismo, se ha configurado el número máximo de iteraciones para alcanzar la convergencia en 500 iteraciones.

La Figura 4.2 muestra los resultados obtenidos al ejecutar Icasto con la función definida en la Ecuación (4.4). A la izquierda se observa el origen de cada una de las componentes, es decir, en qué sensores se han registrado. Esta gráfica, también conocida como *topoplot*, permite hacer una primera aproximación acerca de qué componentes son artefactos y qué componentes no lo son. Observando únicamente estos mapas podría decirse que las componentes 1 y 5 son las que representan el FES. Esta suposición se explica al observarse que la actividad eléctrica es muy similar en todos los electrodos. Sin embargo, también podría decirse lo mismo de las componentes 7 y 11, aunque éstas se descartan al observar la gráfica que aparece a la derecha en esa misma figura.

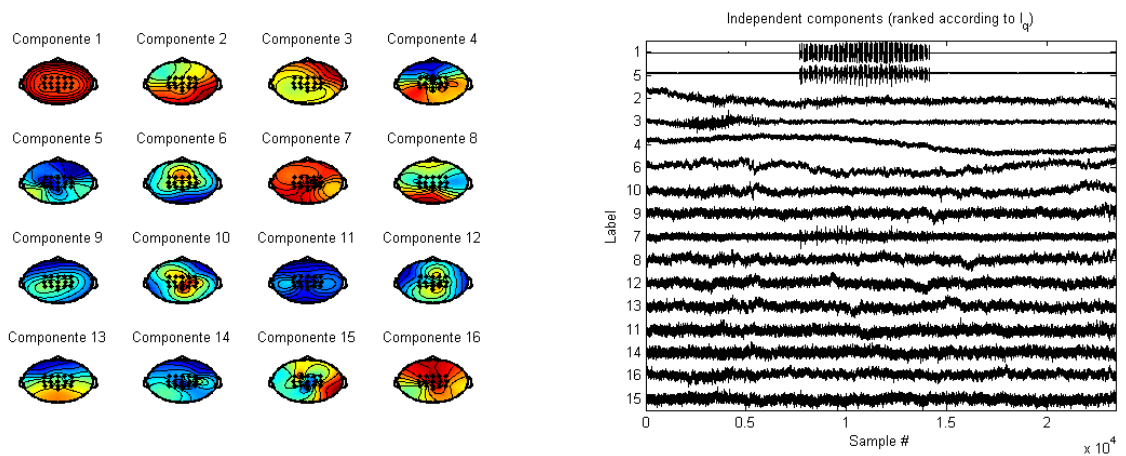


Figura 4.2: Componentes Independientes estimadas por *Icasto* con la función definida en la Ecuación (4.4)

Al observar la gráfica situada a la derecha se observa que las componentes están ordenadas según el índice  $I_q$  o índice de similitud del cluster. Tras obtener las componentes independientes (ICs) en cada ejecución del algoritmo fastica, ésta son proyectadas en un espacio 2D para hacer posible su visualización. Una vez que se han proyectado las 20 soluciones de ICs, se procede a agruparlas en clusters, siendo el índice  $I_q$  el que evalúa cómo de compacto y aislado es cada cluster. Es decir, es una forma cuantitativa de medir el parecido de las ICs estimadas y agrupadas en el mismo cluster, e interesa que sea lo más cercano posible a la unidad. Esto significará, que las estimaciones agrupadas en un determinado conjunto representan la misma componente independiente.

Como se observa en la parte izquierda de la Figura 4.3, comienza a haber más dispersión en el clúster a partir de cluster número 6, ya que el índice de calidad comienza a disminuir notablemente a partir de dicho cluster. En la parte derecha se contabiliza el número de veces que se ha estimado cada componente tras la ejecución completa de *icasso*, habiéndose estimado las componentes pertenecientes a los clusters más compactos en cada ejecución del algoritmo *fastica*.

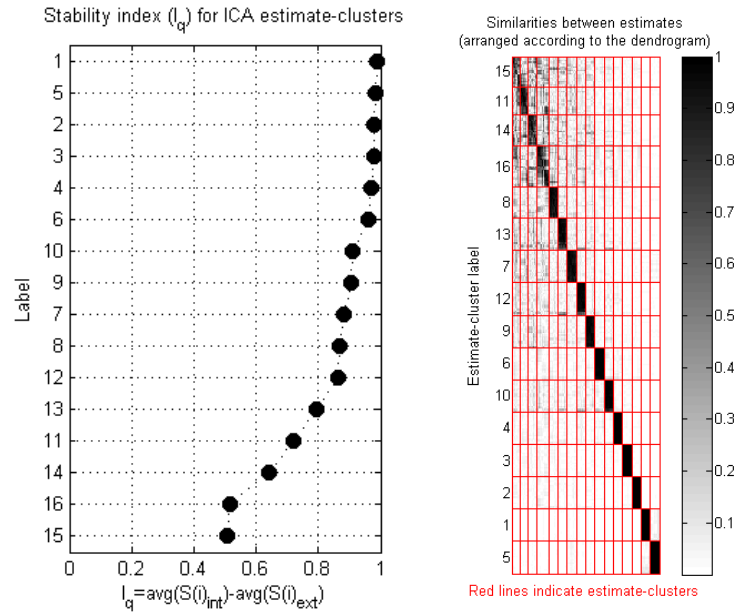


Figura 4.3: Índice de calidad de los clusters (izquierda) y similitudes entre las estimaciones de cada cluster (derecha).

A la derecha de esa misma figura se observan las similitudes entre las estimaciones de cada cluster, siendo las componentes 1 a la componente 6 las que mayor índice de similitud alcanzan. Este concepto se aprecia con mayor facilidad en la Figura 4.4, donde se observa la proyección de las componentes al espacio 2D y los clusters realizados.

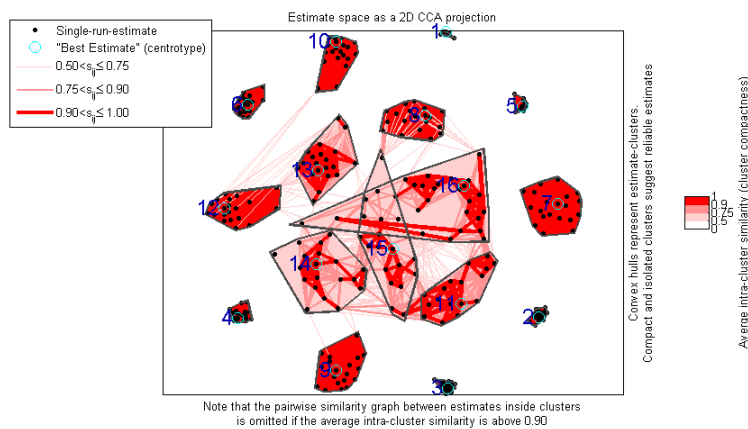


Figura 4.4: Clusters de las ICs estimadas por *icasso*.

Analizando los resultados del análisis ICA, podemos decir que la componente de FES está representada por las ICs 1 y 5, que además siempre son estimadas y con un alto índice  $I_q$ , aunque no se ha conseguido separar completamente el FES de la señal de EEG en una única IC. La explicación de este comportamiento es que el algoritmo, cuando converge, no lo hace a un mínimo global, sino que converge a mínimos locales ([17]). Cuando se tienen funciones no cuadráticas, como es este caso, existen muchos mínimos y máximos, por lo que encontrar el mínimo global tiene mayor dificultad. En estas situaciones es importante el punto inicial donde fastica comienza a iterar para lograr encontrar el mínimo global.

La segunda batería de pruebas se ha realizado con la función de coste definida en la Ecuación (4.5). En esta ocasión, el topoplot mostrado a la izquierda en la Figura 4.5, indica que las ICs que representan el FES son las de las componentes 4 y 5, suposición que se confirma al observar la gráfica derecha de la misma figura.

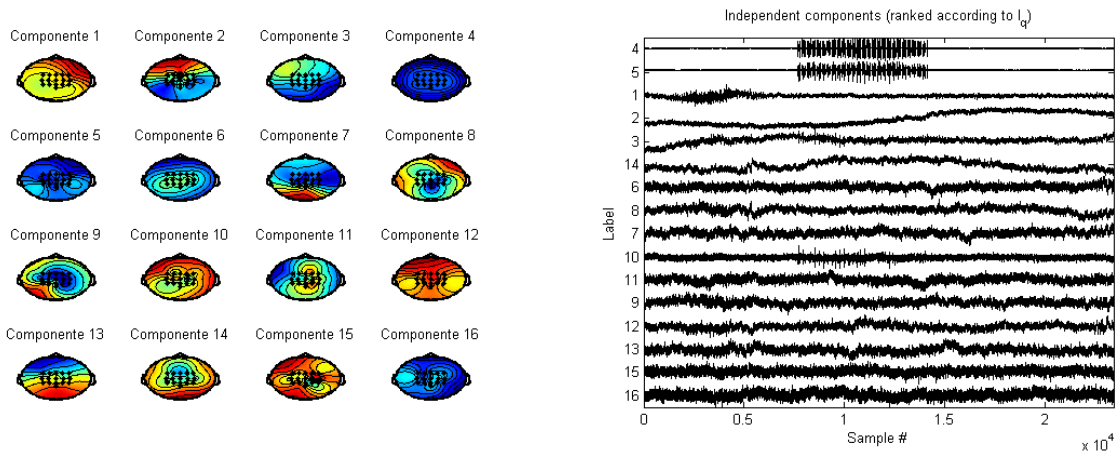


Figura 4.5: Componentes Independientes estimadas por ICA con la función definida en la Ecuación (4.5)

Observando los resultados referentes al índice de calidad en la Figura 4.6, en esta ocasión la dispersión dentro de cada cluster resulta más evidente a partir de la quinta agrupación, es decir, que el valor de  $I_q$  disminuye antes. Se observa también a la derecha en esta figura los clusters formados, siendo en este caso más dispersos, es decir, con menor índice de calidad, que en el caso anterior.

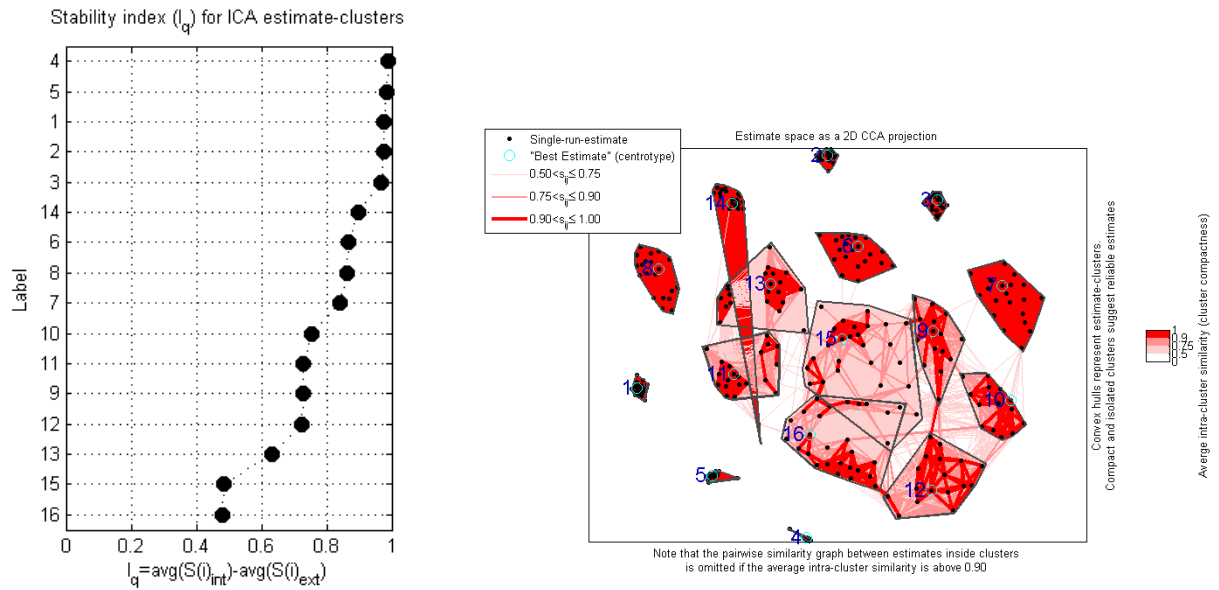


Figura 4.6: Índice de calidad (izquierda) y agrupamiento realizado por Icasso con la función definida en la Ecuación (4.5)

Tras la realización de esta prueba y por lo que se observa en el gráfico de ICs estimadas, Icasso tampoco ha conseguido en esta ocasión recuperar la componente de FES en una señal única, sino que también la estima en dos componentes. Sin embargo, en esta ocasión las ICs estimadas están ordenadas de distinta forma, ahora se encuentran en las componentes 4 y 5 en lugar de 1 y 4 como ocurría en la primera prueba de Icasso. Esto se debe a que las componentes están ordenadas según el  $I_q$ , distinto a lo que ocurría en PCA, donde las componentes estaban ordenadas de mayor a menor varianza.

#### 4.2.2. Aplicación de *runica*

Esta sección muestra los resultados obtenidos al aplicar el algoritmo *runica* sobre uno de los trials en su formato original. Se han realizado varias ejecuciones del algoritmo, que se ha realizado con una condición de parada de  $1 \cdot 10^{-5}$  en lugar de la condición establecida por defecto ( $1 \cdot 10^{-6}$ ). Este cambio ha venido motivado por la falta de convergencia con la condición configurada por defecto.

Tras aplicar este algoritmo sobre uno de los trial en su formato original de EEG contaminado con FES, tampoco se logró una recuperación de la señal de FES en una única componente, quedando dividida de nuevo en dos componentes. La Figura 4.7 muestra el EEG generado por las componentes 1 y 11. Con este algoritmo consigue eliminarse mejor el FES de una de las componentes, ya que en la gráfica de la derecha se ve que no afecta a todos los canales. Además la componente 1 tiene una amplitud mucho mayor que la componente 11.




Figura 4.7: EEG generado por las Componentes Independientes 1 y 11 con el algoritmo *runica*.

Realizando una nueva prueba en la que, ahora sí, se configura el parámetro *extended* para que considere distribuciones supergaussianas de las ICs, se obtienen los resultados se muestran en la Figura 4.8. En ella se observa el EEG generado por dos de las componentes estimadas, que como puede apreciarse, ambas contienen parte del FES a pesar de haber considerado la supergaussianidad. En esta ocasión las componentes de FES estimadas resultan ser las componentes 1 y 3.




Figura 4.8: EEG generado por las Componentes Independientes 1 y 3 con el algoritmo *runica-extended*.

El motivo por el cual este algoritmo no ha funcionado es porque la señal de FES resulta ser una señal super supergaussiana y con una desviación estándar muy pequeña, lo que hace muy difícil la estimación de la componente.

### 4.2.3. Aplicación de *amuse*

La aplicación del algoritmo *amuse* requiere la elección del tamaño de la ventana a considerar en las autocovarianzas. En este caso se han estudiado distintos tamaños de ventana, habiéndose elegido finalmente una ventana de 87'5 ms, lo suficientemente grande como para considerar 2-3 picos de FES.

Los resultados de aplicar este algoritmo se muestran en la Figura 4.9, que refleja las señales de EEG generadas por dos de las componentes estimadas. Existe también una tercera componente donde quedan residuos de la señal de FES. De nuevo la técnica empleada no separa en una única componente independiente la señal de FES.




Figura 4.9: EEG generado por las ICs estimadas por el algoritmo *amuse*. A la izquierda el producido por la componente 15, de mayor amplitud; y a la derecha el generado por la componente 16.

### 4.2.4. Aplicación de wavelet-ICA

Tras haber aplicado el algoritmo explicado con un nivel de descomposición 5, los resultados obtenidos fueron muy similares a los obtenidos con *fastica* y *runica*. Con esta técnica, el artefacto tampoco puede recuperarse ya que no se identifican todas las bandas de frecuencias que están afectadas por el artefacto.

## 5. Conclusiones y Trabajo Futuro

---

En este proyecto se han empleado diversas técnicas de eliminación de artefactos con las que anteriormente se habían obtenido buenos resultados en la extracción o eliminación de este tipo de señales; aunque en el presente trabajo no se han alcanzado resultados completamente satisfactorios. Sin embargo, las diferencias existentes entre aquéllos y los artefactos de FES que han ocupado este estudio son relevantes. Los artefactos causados por la señal de electroestimulación tienen una frecuencia más elevada y con cierta periodicidad temporal que imposibilita el filtrado debido a la mezcla frecuencia de señales.

Respecto al análisis de componentes se ha llegado a la conclusión de que PCA es una técnica insuficiente para resolver el problema aquí planteado. Así mismo hay que destacar que el estudio de las técnicas aquí empleadas ha permitido conocer la carencia de los algoritmos ICA actuales con respecto a la estimación de componentes independientes cuyas distribución sea super supergaussiana. Con respecto a la convergencia de los algoritmos, para minimizar el problema de los mínimos locales, se propone iniciar la búsqueda del mínimo global en un punto cercano a éste, para evitar que el algoritmo se quede en uno de los mínimos locales y no se alcance la convergencia en el mínimo global.

La utilización de transformadas wavelet ha permitido, mediante la eliminación de ruido de alta frecuencia, atenuar los efectos del FES. Sin embargo, debido al problema de mezclado existente, un filtrado convencional resulta ineficiente en la eliminación de la señal de FES.

Se propone continuar la documentación sobre algoritmos ICA que permitan estimar las componentes independientes de distribuciones supergaussianas y super supergaussianas, así como profundizar en la herramienta que supone *runica* en este sentido.

Además se ha comprobado que la actividad neuronal responde ante estos estímulos de forma similar a como lo haría cuando la corteza motora se estimula de forma fisiológicamente natural.

## Bibliografía

---

- [1] Paul L. Nunez and Ramesh Srinivasan. *Electric Fields of the Brain*. Oxford University Press, 2006.
- [2] D. Corydon Hammond and Jay Gunkelman. *The Art of Artifacting*. International Society for Neurofeedback & Research, 2001.
- [3] Valeri A. Makarov Nazareth P. Castellanos. Recovering eeg brain signals: Artifact suppression with wavelet enhanced independent component analysis. In *Journal of Neuroscience Methods*, pages 300–312. Elsevier, 2006.
- [4] SALUD CENETEC. Estimulador nervioso eléctrico transcutáneo (tens), Septiembre 2005.
- [5] A. James Rowan and Eugene Tolunsky. *Conceptos básicos de EEG*. Elsevier, 2004.
- [6] Luis Vicente Borrueal. Estimación espectral en aplicaciones biomédicas. <http://www.masterib.es/>, Marzo 2008.
- [7] Samir Kouro R. and Rodrigo Musalem M. Tutorial introductorio a la teoría de wavelet. *Técnicas Modernas en Automática*, Julio 2002.
- [8] Introducción a la transformada wavelet. descomposición de señales. <http://www.exa.unicen.edu.ar/escuelapav/cursos/wavelets/apunte.pdf>, 2006.
- [9] E La Foresta B. Azzerboni, M. Carpentien and E C. Morabito. Neural-ica and wavelet transform for artifacts removal in surface emg. *IEEE*, pages 3223–3228, 2004.
- [10] K. Sivakumar P. Senthil Kumar, R. Arumuganathan and C. Vimal. Removal of ocular artifacts in the eeg through wavelet transform without using an eeg reference channel. *Int. J. Open Problems Compt. Math.*, 1(3):188–200, December 2008.
- [11] Piotr Durka W. Szelenberger Rafal Ksiezzyk, Katarzyna Blinowska and W. Androsiuk. Neural networks with wavelet preprocessing in eeg artifact recognition.
- [12] Janett Walters-Williams and Yan Li. A new approach to denoising eeg signals - merger of translation invariant wavelet and ica. *International Journal of Biometrics and Bioinformatics*, 5:130–148, 2011.
- [13] Nadia Mammone Giuseppina Inuso, Fabio La Foresta and Francesco Carlo Morabito. Wavelet-ica methodology for efficient artifact removal from electroencephalographic recordings. In *Proceedings of International Joint Conference on Neural Networks*, pages 12–17. IEEE, 2007.



- [14] Juha Karhunen Aapo Hyvärinen and Erkki Oja. *Independent Component Analysis*. Wiley Interscience, 2001.
- [15] Luis Vicente Borrueal. Separación ciega de fuentes: Pca e ica. <http://www.masterib.es/>, Marzo 2011.
- [16] Aapo Hyvärinen. Fast and robust fixed-point algorithms for independent component analysis. In *IEEE Trans. on Neural Networks*, pages 626–634, 1999.
- [17] Johan Himberg and Aapo Hyvärinen. Icasto: Software for investigating the reliability of ica estimates by clustering and visualization. In *IEEE Workshop on Neural Networks for Signal Processing*, pages 259–268, 2003.
- [18] Aapo Hyvärinen Johan Himberg and Fabrizio Esposito. Validating the independent components of neuroimaging time-series via clustering and visualization. *NeuroImage*, 2004.
- [19] Aapo Hyvärinen. <http://www.cis.hut.fi/projects/ica/fastica/>.
- [20] Anthony J. Bell and Terrence J. Sejnowski. Blind separation and blind deconvolution: An information-theoretic approach. In *IEEE International Conference on Acoustics, Speech and Signal Processing*, pages 3415–3418, 1995.
- [21] Mark Girolami Te-Won Lee and Terrence J. Sejnowski. Independent component analysis using an extended infomax algorithm for mixed subgaussian and supergaussian sources. In *Neural Computation. Massachusetts Institute of Technology*, pages 417–441, 1999.