

Trabajo Fin de Grado

Grado en Ingeniería de las Tecnologías de  
Telecomunicación

# IDENTIFICACIÓN BIOMÉTRICA BASADA EN EL ELECTROENCEFALOGRAMA

Autor: Víctor González Gil

Tutor: Rubén Martín Clemente

Dep. Teoría de la Señal y Comunicaciones  
Escuela Técnica Superior de Ingeniería  
Universidad de Sevilla

Sevilla, 2017





Proyecto Fin de Carrera  
Ingeniería de Telecomunicación

# **IDENTIFICACIÓN BIOMÉTRICA BASADA EN EL ELECTROENCEFALOGRAMA**

Autor:

Víctor González Gil

Tutor:

Rubén Martín Clemente

Profesor titular

Dep. de Teoría de la Señal y Comunicaciones

Escuela Técnica Superior de Ingeniería

Universidad de Sevilla

Sevilla, 2017



Proyecto Fin de Carrera: IDENTIFICACIÓN BIOMÉTRICA BASADA EN EL  
ELECTROENCEFALOGRAMA

Autor: Víctor González Gil

Tutor: Rubén Martín Clemente

El tribunal nombrado para juzgar el Proyecto arriba indicado, compuesto por los siguientes miembros:

Presidente:

Vocales:

Secretario:

Acuerdan otorgarle la calificación de:

Sevilla, 2017

El Secretario del Tribunal

*A mi familia*

*A mis maestros*





# Agradecimientos

---

En primer lugar, agradecer a mis padres todo lo que han hecho por mi, y por su apoyo incondicional durante todos estos años.

Además, me gustaría darle las gracias a todos los que me han acompañado desde que entre en la Escuela, con los que he pasado buenos y malos momentos.

Para finalizar, agradecer a mi tutor y profesor Rubén Martín Clemente toda la ayuda recibida durante el transcurso de este proyecto.

Víctor González Gil

Sevilla, 2017



# Resumen

---

Se pretende investigar si es posible establecer la identidad de una persona a partir de las características biofísicas de su electroencefalograma (EEG). El EEG es un registro no invasivo de las corrientes eléctricas generadas por el cerebro. Sus características (forma de onda, potencia y otras) dependen de la personalidad y el aprendizaje, por lo que potencialmente puede ser empleado para distinguir a un sujeto del resto.

Estas características conformarán los llamados “vectores de características”. Estos serán introducidos como entrenamiento a una Máquina de Soporte Vectorial, que aprenderá del conjunto de datos. Esta se alimentará, posteriormente, con nuevos vectores de características y se determinará si es capaz de identificar correctamente de que sujeto se trata.

Se realiza un estudio con diferentes sujetos y tipos de ondas cerebrales, calculando la tasa de éxito aproximada para cada uno de ellos.

Debido a que el estudio ha sido realizado para una pequeña cantidad de individuos, las tasas de error y los resultados a los que se llega, no serán concluyentes. Pero sí demostrarán el potencial del electroencefalograma para establecer la identidad de una persona.



# Abstract

---

The aim is to investigate if it is possible to establish the identity of a person based on the biophysical characteristics of their electroencephalogram (EEG). The EEG is a noninvasive record of the electrical currents generated by the brain. Their characteristics (waveform, power...) depend on personality and learning, so they can potentially be used to distinguish a subject from the rest.

These characteristics make up the so-called "feature vectors". These will be introduced as training to a Vector Support Machine, which they learn from the data set introduced. This will be fed later with new vectors of characteristics and will determine if it is able to correctly identify which subject is involved.

A study was done with different subjects and types of brain waves, calculating the approximate success rate for each of them.

Because the study has been performed for a small number of individuals, error rates and results to what is reached, are not conclusive. But it does demonstrate the potential of the electroencephalogram to establish the identity of a person.



|   |             |
|---|-------------|
| <b>Agradecimientos</b>  | <b>ix</b>   |
| <b>Resumen</b>  | <b>xi</b>   |
| <b>Abstract</b>   | <b>xiii</b> |
| <b>Índice</b>   | <b>xv</b>   |
| <b>Índice de Tablas</b>   | <b>xvii</b> |
| <b>Índice de Figuras</b>  | <b>xix</b>  |
| <b>Notación</b>   | <b>i</b>    |
| <b>1 Introducción</b>   | <b>1</b>    |
| 1.1 <i>Objetivos y alcance</i>                                    | 1           |
| 1.2 <i>Metodología</i>  | 1           |
| 1.3 <i>Estructura de la memoria</i>                               | 1           |
| <b>2 Electroencefalografía</b>                                    | <b>3</b>    |
| 2.1 <i>Introducción</i>   | 3           |
| 2.3 <i>Anatomía del encéfalo</i>                                  | 3           |
| 2.2.2. <i>Electrogénesis cortical</i>                             | 5           |
| 2.4 <i>Captación del EEG</i>                                      | 5           |
| 2.4.1. <i>Colocación de los electrodos superficiales</i>          | 7           |
| 2.4.2. <i>Montaje de un EEG</i>                                   | 7           |
| 2.5 <i>Las ondas cerebrales</i>                                   | 10          |
| 2.6 <i>Potenciales evocados</i>                                   | 11          |
| 2.6.1. <i>Características de los PEs</i>                          | 11          |
| 2.6.2. <i>Clasificación de los PEs</i>                            | 12          |
| <b>3 Pre-procesado y extracción de características de los EEG</b> | <b>13</b>   |
| 3.1 <i>Introducción</i>   | 13          |
| 3.2 <i>Captación de los EEG</i>                                   | 13          |
| 3.3 <i>Pre-procesado</i>  | 13          |
| 3.3.1 <i>Análisis SSP</i>   | 13          |
| 3.3.2 <i>Filtrado</i>   | 18          |
| 3.3.3 <i>Segmentación</i>   | 21          |
| 3.4 <i>Extracción de características</i>                          | 21          |
| 3.4.1 <i>Potencia</i>   | 21          |
| <b>4 Clasificación</b>  | <b>23</b>   |
| 4.1 <i>Máquinas de Soporte Vectorial</i>                          | 23          |
| 4.1.1 <i>Descripción del clasificador lineal óptimo</i>           | 24          |
| 4.1.2 <i>Descripción del problema de optimización lineal</i>      | 25          |
| 4.1.3 <i>Margen blando</i>  | 27          |
| 4.1.4 <i>Clasificador no lineal</i>                               | 28          |
| 4.2 <i>Implementación en el trabajo</i>                           | 30          |
| <b>5 RESULTADOS</b>   | <b>31</b>   |
| 5.1 <i>Base de datos</i>  | 31          |

|          |   |           |
|----------|---|-----------|
| 5.2      | <i>Demostración del principio</i>             | 31        |
| 5.3      | <i>Resultados de la clasificación. Caso 1</i> | 36        |
| 5.3.1    | Sujeto A                                      | 36        |
| 5.3.2    | Sujeto B                                      | 41        |
| 5.3.3    | Sujeto C                                      | 46        |
| 5.4      | <i>Resultados de la clasificación. Caso 2</i> | 51        |
| 5.4.1    | Sujeto A                                      | 51        |
| 5.4.2    | Sujeto B                                      | 56        |
| 5.4.3    | Sujeto C                                      | 61        |
| <b>6</b> | <b>Conclusión</b>                             | <b>67</b> |
|          | <b>Referencias</b>                            | <b>69</b> |
|          | <b>Anexos</b>                                 | <b>71</b> |



# ÍNDICE DE TABLAS

---

|   |    |
|---|----|
| Tabla 5-1 Base de datos.                      | 31 |
| Tabla 5-2 Tasas de acierto. Caso 1. Sujeto A. | 36 |
| Tabla 5-3 Tasas de acierto. Caso 1. Sujeto B. | 41 |
| Tabla 5-4 Tasas de acierto. Caso 1. Sujeto C. | 46 |
| Tabla 5-5 Tasas de acierto. Caso 2. Sujeto A. | 51 |
| Tabla 5-6 Tasas de acierto. Caso 2. Sujeto B. | 56 |
| Tabla 5-7 Tasas de acierto. Caso 2. Sujeto C  | 61 |



# ÍNDICE DE FIGURAS

---

|   |    |
|---|----|
| Figura 2-1 Partes principales del cerebro   | 3  |
| Figura 2-2 Lóbulos del cerebro  | 4  |
| Figura 2-3 Colocación de los electrodos de contacto.  | 6  |
| Figura 2-4 Colocación de los electrodos en casco de malla.  | 6  |
| Figura 2-5 Colocación de los electrodos.  | 7  |
| Figura 2-6 Montaje de un registro Monopolar.  | 8  |
| Figura 2-7 Esquema del sistema Wilson.  | 8  |
| Figura 2-8 Montaje de un registro Bipolar.  | 9  |
| Figura 2-9 Esquema de un Montaje Longitudinal (A) y uno Transversal (B).  | 10 |
| Figura 2-10 Tipos de Ondas Cerebrales.  | 10 |
| Figura 3-1 Señal sin procesar del EEG de A-1  | 16 |
| Figura 3-2 Señal, tras aplicar el algoritmo SSP , del EEG de A-1  | 17 |
| Figura 3-3 Ejemplo de uso de la función designfilt para el diseño del filtro Alpha.   | 18 |
| Figura 3-4 Señal de EEG tras el filtro Delta  | 19 |
| Figura 3-5 Señal de EEG tras el filtro Theta  | 19 |
| Figura 3-6 Señal de EEG tras el filtro Alpha  | 20 |
| Figura 3-7 Señal de EEG tras el filtro Beta.  | 20 |
| Figura 4-1 Funcionamiento SVM   | 23 |
| Figura 4-2 Representación del hiperplano óptimo junto con sus vectores de soporte asociados   | 24 |
| Figura 4-3 Separación lineal: margen blando.  | 27 |
| Figura 4-4 Clasificador no lineal   | 29 |
| Figura 5-1 Representación de los vectores de características para el sujeto “A” correspondientes a la onda cerebral Delta. Para la representación se han tomado únicamente las características de los electrodos Fp1 y F7.          | 32 |
| Figura 5-2 Representación de los vectores de características para el sujeto “B” correspondientes a la onda cerebral Alpha. Para la representación se han tomado únicamente las características de los electrodos Fp1 y F7.          | 33 |
| Figura 5-3 Representación de los vectores de características para el sujeto “A-2” y “B-1” correspondientes a la onda cerebral Beta. Para la representación se han tomado únicamente las características de los electrodos Fp1 y F7. | 34 |
| Figura 5-4 Representación de los vectores de características para el sujeto “A-1” y “C-1” correspondientes a la onda cerebral Beta. Para la representación se han tomado únicamente las características de los electrodos Fp1 y F7. | 35 |
| Figura 5-5 Representación de los vectores de características para el sujeto “A-1” y “B-1” para la onda cerebral Beta, correspondientes a los sensores Fp1 y F7.   | 37 |
| Figura 5-6 Representación de los vectores de características para el sujeto “A-1” y “B-2” para la onda cerebral Alpha, correspondientes a los sensores Fp1 y F7.  | 38 |

|   |    |
|---|----|
| Figura 5-7 Representación de los vectores de características para el sujeto “A-1” y “C-1” para la onda cerebral Theta, correspondientes a los sensores Fp1 y F7.  | 39 |
| Figura 5-8 Representación de los vectores de características para el sujeto “A-1” y “C-2” para la onda cerebral Delta, correspondientes a los sensores Fp1 y F7.  | 40 |
| Figura 5-9 Representación de los vectores de características para el sujeto “B-1” y “A-1” para la onda cerebral Beta, correspondientes a los sensores Fp1 y F7.   | 42 |
| Figura 5-10 Representación de los vectores de características para el sujeto “B-1” y “A-2” para la onda cerebral Alpha, correspondientes a los sensores Fp1 y F7.   | 43 |
| Figura 5-11 Representación de los vectores de características para el sujeto “B-1” y “C-1” para la onda cerebral Theta, correspondientes a los sensores Fp1 y F7.   | 44 |
| Figura 5-12 Representación de los vectores de características para el sujeto “B-1” y “C-2” para la onda cerebral Delta, correspondientes a los sensores Fp1 y F7.   | 45 |
| Figura 5-13 Representación de los vectores de características para el sujeto “C-1” y “A-1” para la onda cerebral Beta, correspondientes a los sensores Fp1 y F7.  | 47 |
| Figura 5-14 Representación de los vectores de características para el sujeto “C-1” y “A-2” para la onda cerebral Alpha, correspondientes a los sensores Fp1 y F7.   | 48 |
| Figura 5-15 Representación de los vectores de características para el sujeto “C-1” y “B-1” para la onda cerebral Theta, correspondientes a los sensores Fp1 y F7.   | 49 |
| Figura 5-16 Representación de los vectores de características para el sujeto “C-1” y “B-2” para la onda cerebral Delta, correspondientes a los sensores Fp1 y F7.   | 50 |
| Figura 5-17 Representación de los vectores de características para el sujeto “A-1” y “B-1” para la onda cerebral Beta, correspondientes a los sensores Fp2 y F8. Los círculos verdes corresponden al vector de prueba de “A-2”.   | 52 |
| Figura 5-18 Representación de los vectores de características para el sujeto “A-1” y “B-2” para la onda cerebral Alpha, correspondientes a los sensores Fp2 y AF4. Los círculos verdes corresponden al vector de prueba de “A-2”. | 53 |
| Figura 5-19 Representación de los vectores de características para el sujeto “A-1” y “C-1” para la onda cerebral Theta, correspondientes a los sensores Fp1 y F7. Los círculos verdes corresponden al vector de prueba de “A-2”.  | 54 |
| Figura 5-20 Representación de los vectores de características para el sujeto “A-1” y “C-2” para la onda cerebral Delta, correspondientes a los sensores Fp1 y F7. Los círculos verdes corresponden al vector de prueba de “A-2”.  | 55 |
| Figura 5-21 Representación de los vectores de características para el sujeto “B-1” y “A-1” para la onda cerebral Beta, correspondientes a los sensores Fp2 y F8. Los círculos verdes corresponden al vector de prueba de “B-2”.   | 57 |
| Figura 5-22 Representación de los vectores de características para el sujeto “B-1” y “A-2” para la onda cerebral Alpha, correspondientes a los sensores Fp2 y AF4. Los círculos verdes corresponden al vector de prueba de “B-2”. | 58 |
| Figura 5-23 Representación de los vectores de características para el sujeto “B-1” y “C-1” para la onda cerebral Theta, correspondientes a los sensores Fp1 y F7. Los círculos verdes corresponden al vector de prueba de “B-2”.  | 59 |
| Figura 5-24 Representación de los vectores de características para el sujeto “B-1” y “C-2” para la onda cerebral Delta, correspondientes a los sensores Fp1 y Fpz. Los círculos verdes corresponden al vector de prueba de “B-2”. | 60 |
| Figura 5-25 Representación de los vectores de características para el sujeto “C-1” y “A-1” para la onda cerebral Beta, correspondientes a los sensores Fp1 y F7. Los círculos verdes corresponden al vector de prueba de “C-2”.   | 62 |
| Figura 5-26 Representación de los vectores de características para el sujeto “C-1” y “A-2” para la onda cerebral  |    |

Alpha, correspondientes a los sensores Fp1 y F7. Los círculos verdes corresponden al vector de prueba de “C-2”.

63

Figura 5-27 Representación de los vectores de características para el sujeto “C-1” y “B-1” para la onda cerebral Theta, correspondientes a los sensores Fp1 y F7. Los círculos verdes corresponden al vector de prueba de “C-2”.

64

Figura 5-28 Representación de los vectores de características para el sujeto “C-1” y “B-2” para la onda cerebral Delta, correspondientes a los sensores Fp1 y F7. Los círculos verdes corresponden al vector de prueba de “C-2”.

65



# Notación

---

|                         |                              |
|-------------------------|------------------------------|
| SVM                     | Máquina de Soporte Vectorial |
| EEG                     | Electroencefalograma         |
| var                     | Varianza                     |
| $H_0$                   | Hiperplano óptimo            |
| L                       | Multiplicadores de Lagrange  |
| $\epsilon$              | Existe                       |
| P                       | Potencia                     |
| $\partial y \partial x$ | Derivada parcial             |
| :                       | Tal que                      |
| <                       | Menor o igual                |
| >                       | Mayor o igual                |
| $\Leftrightarrow$       | Si y sólo si                 |





# 1 INTRODUCCIÓN

---

Existen diferentes formas de identificación biométrica que se pueden utilizar como métodos de identificación y autenticación de sujetos, pudiendo reemplazar a las contraseñas. Algunas de estas ya se encuentran en nuestra vida cotidiana, como es la lectura de huellas dactilares en los smartphones. También otras menos comunes como son el escáner de retina o el reconocimiento facial.

En este trabajo se investigará la identificación biométrica de personas por su electroencefalograma.

## 1.1 Objetivos y alcance

El objetivo de este trabajo será investigar si es posible establecer la identidad de un sujeto utilizando las características biofísicas de su electroencefalograma. Así como realizar diferentes pruebas, siendo el propósito final establecer una base metodológica para futuras líneas de investigación.

Se realizará el estudio con diferentes sujetos y tipos de ondas cerebrales, calculando la tasa de acierto aproximada para cada uno de ellos. Debido a que el estudio ha sido realizado para una pequeña cantidad de sujetos, las tasas de acierto y los resultados obtenidos no serán concluyentes. Pero si demostrarán el potencial del electroencefalograma para establecer la identidad de una persona.

## 1.2 Metodología

Poder llegar a este objetivo implica el siguiente programa de tareas:

- Revisión de todos los contenidos implicados en este estudio. Como es la electroencefalografía, las máquinas de soporte vectorial y el análisis de los resultados.
- El pre-procesado de los EEGs, así como la extracción de características de los mismos. Con las que se llevará a cabo el objetivo de este trabajo, introduciéndolas en la máquina de soporte vectorial.
- Análisis de los resultados en los que se comparará la tasa de acierto en función de proceso utilizado.

## 1.3 Estructura de la memoria

Para explicar el desarrollo de este trabajo se ha decidido utilizar la estructura organizada por capítulos que se describe a continuación:

- Capítulo 2: “Electroencefalografía”. Se lleva a cabo una explicación de los conocimientos básicos relacionados con la encefalografía. Como es la anatomía del encefalo o la captación de los EEGs.
- Capítulo 3: “Pre-procesado y extracción de características de los EEGs”. En este capítulo se describen las diferentes etapas que se llevan a cabo para el procesamiento de las señales EEG y la extracción de características que serán usadas en la máquina de soporte vectorial.
- Capítulo 4: “Clasificación”. Se exponen los conceptos básicos para poder entender el funcionamiento de las máquinas de soporte vectorial (SVM).

- Capitulo 5: “Resultados”. En este capítulo se exponen los resultados obtenidos tras las pruebas que se han realizado. Mostrando ejemplos y las tasas de acierto obtenidas.
- Capitulo 6: “Conclusiones”. Se describen las conclusiones a las que se ha llegado tras la finalización del estudio.

# 2 ELECTROENCEFALOGRAFÍA

## 2.1 Introducción

La electroencefalografía es el registro y evaluación de las diferencias de potencial eléctrico generadas por el cerebro. Para realizar este examen es necesario adherir electrodos sobre la superficie del cuero cabelludo.

Dicho registro varía con la localización de los electrodos y entre individuos. Esto es debido al gran número de interconexiones que presentan las neuronas y por la estructura no uniforme del encéfalo.

## 2.3. Anatomía del encéfalo

El cerebro forma, junto con la médula espinal, el Sistema Nervioso Central. El cerebro esta rodeado por el cráneo, en su interior se encuentran tres membranas llamadas meninges. Para protegerlo de lesiones o golpes, este se encuentra flotando en el llamado líquido cefalorraquídeo. [3]

El cerebro puede dividirse en varias partes principales: cerebro, tronco encefálico y cerebelo.




Figura 2-1 Partes principales del cerebro

El tronco cerebral conecta el córtex cerebral, la médula espinal y el cerebelo. Es el encargado de controlar el ritmo cardíaco y respiratorio.

El cerebelo es el encargado de los movimientos voluntarios, así como de mantener el equilibrio. Procesa información proveniente de otras áreas del cerebro, de la médula espinal y de los receptores sensoriales.

El cerebro es la parte más voluminosa del encéfalo y en él están localizadas las funciones conscientes del sistema nervioso. Está situado en la parte anterior y superior de la cavidad craneal. Posee dos partes llamadas hemisferios que se relacionan con las partes opuestas del cuerpo. La superficie externa del hemisferio se conoce por córtex y en ella se recibe la información sensorial.

El cerebro esta dividido en diferentes lóbulos:




Figura 2-2 Lóbulos del cerebro

El lóbulo frontal es el más grande en el encéfalo humano. Sus funciones son todas aquellas que únicamente llevan a cabo los seres racionales. La capacidad de pensar en abstracto, denominado meta-pensamiento, imaginar planes y estrategias futuras y controlar nuestras emociones, son algunas de ellas.

El lóbulo parietal, situado entre el lóbulo frontal y el occipital, es una de las partes más importantes tanto por su tamaño como por los procesos en los que participa. Una de sus funciones principales es que la información proveniente de todas las partes del cuerpo se combina en esta zona. Gracias a la cual somos capaces de generar, por ejemplo, la idea de lo que es un perro, con su movimiento, su tacto y su olor.

El lóbulo occipital es uno de los más pequeños, se sitúa entre el cerebelo, el lóbulo temporal y el lóbulo parietal. Tiene como función principal, obtener la información proveniente de las retinas.

El lóbulo temporal está situado en el lateral inferior del encéfalo. Se trata del lóbulo con mayor conexión con el sistema límbico, teniendo gran influencia en las emociones y estados de ánimo, así como con la memoria.

### 2.3.1. Electrogénesis cerebral

Una de las funciones básicas de tejido nervioso es la capacidad de generar potenciales eléctricos, es decir, posee capacidad electrogénica. Sin embargo, para los propósitos del EEG bastará con considerar la corteza cerebral y las regiones directamente relacionadas con ella.

La corteza cerebral está formada por seis capas celulares:

- Capa superficial plexiforme de pequeñas células.
- Capa de células granulares.
- Capa de células piramidales.
- Capa de células granulares.
- Capa de células piramidales.
- Capa profunda polimorfa.

### 2.2.2. Electrogénesis cortical

La actividad eléctrica del tejido cortical se caracteriza por conjuntos de ondas lentas sobre las que se superponen ritmos rápidos. Entre un grupo de ondas lentas y otro aparecen períodos de silencio eléctrico. Estas señales son producidas como consecuencia de la actividad sináptica.

Se han puesto de manifiesto tres generadores corticales:

Generador A: Situado a unas 500 micras de la superficie, produce ondas negativas en la superficie de la corteza.

Generador B: Situado a 900 micras de profundidad, produce ondas positivas en la superficie cortical y su actividad coincide con la aparición de potenciales de acción en las células.

Generador C: Está situado también a 900 micras, pero su actividad determina ondas negativas en la superficie cortical. Su actividad coincide con una interrupción de la descarga de potenciales de acción en las células piramidales.

## 2.4. Captación del EEG

Hay cuatro formas de captar la actividad cerebral:

- Sobre el cuero cabelludo, donde se utilizan electrodos superficiales.
- En la base del cráneo, mediante electrodos basales.
- En cerebro expuesto. Para esta forma se utilizan electrodos quirúrgicos corticales.
- Localización cerebral profunda, usando electrodos quirúrgicos intracraneales.

Según el método de captación, hay tres tipos de registros:

- Electroencefalograma (EEG): Para este registro se utilizan electrodos de superficie o basales.
- Electroencefalograma (ECoG): Usando electrodos quirúrgicos en la superficie.
- Estereo Electroencefalograma (E-EEG): Cuando se utilizan electrodos quirúrgicos de aplicación profunda.

Existen varios tipos de electrodos superficiales:

1. Adheridos: Son pequeños discos metálicos de 5 mm de diametro que se adhieren con una pasta conductora.
2. De contacto: Consisten en tubos de plata clorurada roscados a soportes de plástico. En el extremo se coloca una almohadilla que se humedece con una solución conductor.




Figura 2-3 Colocación de los electrodos de contacto.

3. En casco de malla: Los electrodos están incluidos en un casco elástico. Su característica principal es la comodidad de colocación, lo que conlleva una mayor comodidad para el paciente en registros de larga duración.



Figura 2-4 Colocación de los electrodos en casco de malla.

### 2.4.1. Colocación de los electrodos superficiales

El sistema internacional “Diez-Veinte” es el más utilizado para la colocación de los electrodos. Se procede de la siguiente forma:

- Se mide la distancia entre el nasion y el inion, pasando por el vertex. El punto Fp se sitúa un 10% por encima de nasion y el punto O un 10% sobre el inion.
- Entre Fp y O se sitúan otros tres puntos separados por intervalos iguales del 20%. Estos son: Fz (Frontal), Cz (Central o Vertex) y Pz (Parietal).
- Se mide la distancia entre los puntos preauriculares, pasando por el punto Cz (vertex). El 10% sobre el punto preauricular marca la posición de los puntos temporales mediales T3 (izquierdo) y T4 (derecho).

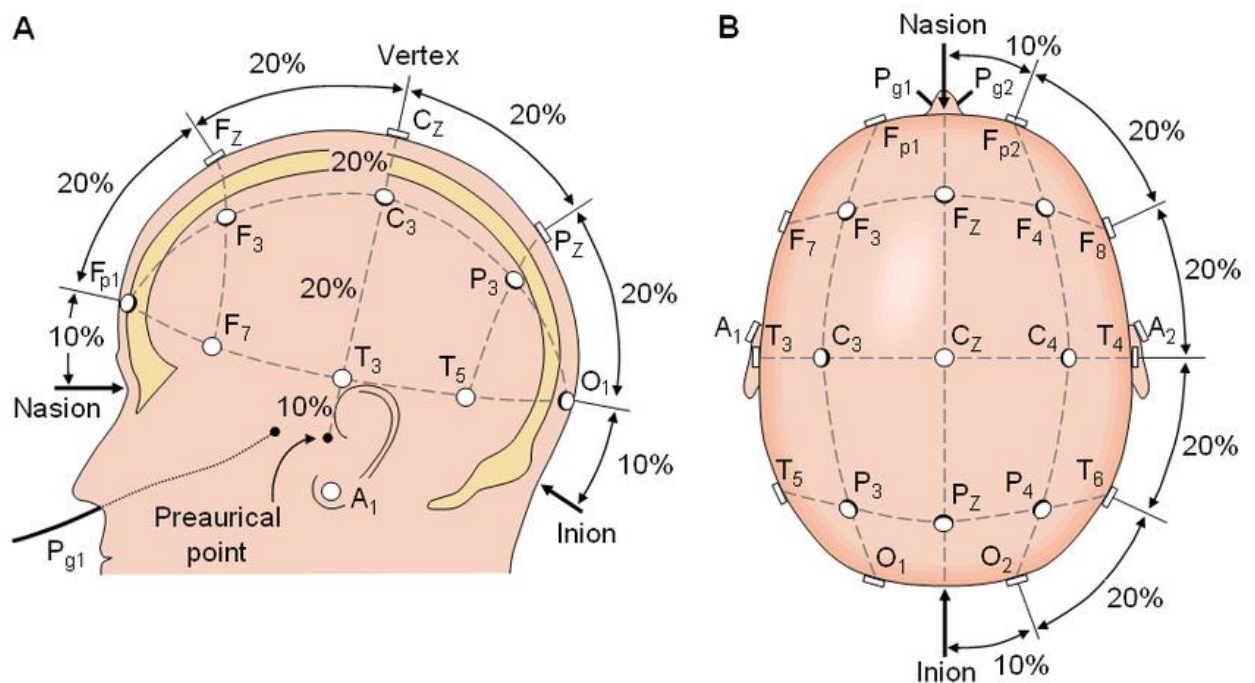


Figura 2-5 Colocación de los electrodos.

### 2.4.2. Montaje de un EEG

Para registrar el EEG se utilizan una serie de electrodos que situamos sobre la superficie del cuero cabelludo en situaciones concretas, como ya se ha explicado. Para poder realizar este registro es preciso disponer de dos terminales. Por esto habrá que seleccionar cuáles de los electrodos deben ser la fuente de señal registrada en el electroencefalógrafo, dependiendo del número de canales disponibles y del propósito específico del registro a realizar. Por tanto, la primera decisión que se deberá tomar será el seleccionar entre Registros Monopares y Registros Bipolares.

En los Registros Monopares se toma la señal de cada uno de los electrodos independientemente de la de los demás. En esta situación el electrodo de registro se llama electrodo activo y el segundo cable de entrada al equipo se toma de un electrodo llamado de Referencia.




Figura 2-6 Montaje de un registro Monopolar.

Teóricamente este electrodo debe estar situado a potencial cero, aunque ésto en la práctica es muy difícil de conseguir. Por eso se emplean referencias como el uso de electrodos en el lóbulo de la oreja o en el mentón.

Con ésto, solo se podría registrar la actividad de un electrodo, ya que todos los demás estarían cortocircuitados entre sí. Para poder solucionar este problema, la interconexión entre todos se realiza por medio de resistencias (entre 1 y 1.5 Mohmios). Este es el llamado sistema Wilson y con él se pueden tomar tantos pares referencial-activo como se desee.

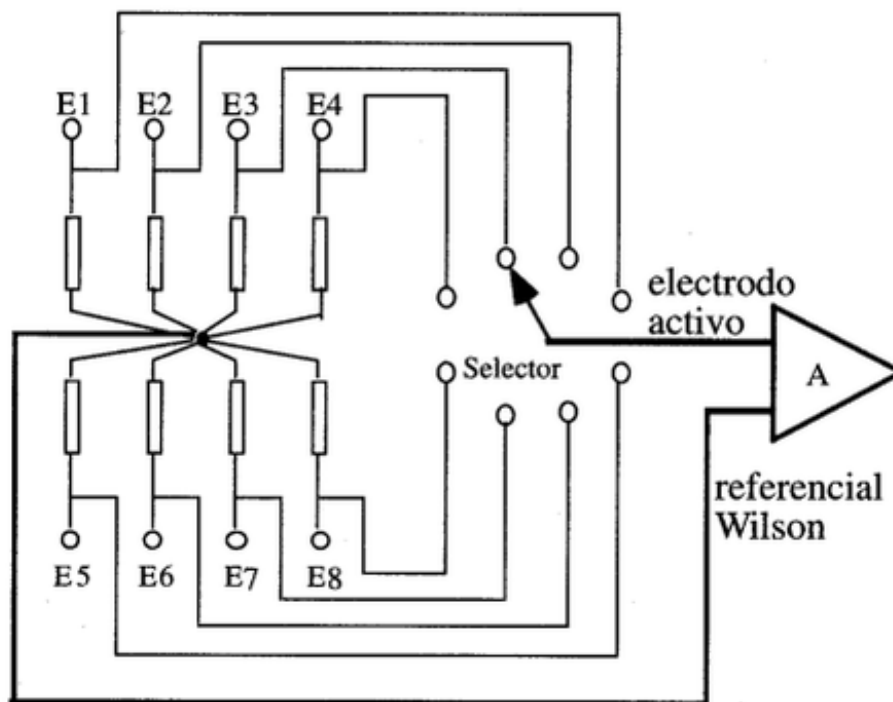


Figura 2-7 Esquema del sistema Wilson.



En los Registros Bipolares se toman parejas de electrodos, y se registran las diferencias de tensión entre cada par de puntos. Los dos electrodos de cada pareja son activos.




Figura 2-8 Montaje de un registro Bipolar.

Utilizando este método es posible realizar un número enorme de registros bipolares diferentes, tantos como parejas diferentes de electrodo, tomadas en grupos de 8, de 12, de 16 ... (según el número de canales disponibles para registro simultáneo). Hay muchas combinaciones que no ofrecerían información importante, por esta razón es preciso seleccionar, de entre todas las posibles, las combinaciones más interesantes. Cada una de las combinaciones seleccionadas se llama un Montaje.

Distinguimos entre dos tipos de Montajes:

- Montajes a Largas Distancias: cuando se registra entre electrodos no contiguos.
- Montajes a Distancias Cortas: cuando se hacen registros entre electrodos vecinos.

Por otra parte, los montajes también han sido clasificados por la Federación Internacional de EEG y Neurofisiología en:

- En Montajes Longitudinales: se registra la actividad de pares de electrodos dispuestos en sentido anteroposterior de cada mitad del cráneo.
- En Montajes Transversales: se realizan registros de pares de electrodos dispuestos transversalmente según los planos sagitales anterior, medio o posterior.




Figura 2-9 Esquema de un Montaje Longitudinal (A) y uno Transversal (B).

## 2.5. Las ondas cerebrales

Nuestro cerebro produce impulsos eléctricos que viajan a través de nuestras neuronas. Estos impulsos eléctricos producen ritmos que son conocidos como ondas cerebrales.

Sabemos que los diferentes patrones de ondas cerebrales se relacionan con diferentes estados de consciencia, tales como concentración intensa, estado de alerta (despierto), sueño profundo, sueños vívidos, somnolencia, relajación, hipnosis, estados alterados de consciencia, etc.

Existen cuatro tipos principales de ondas cerebrales: [4]





|   |  |
|---|--|
| <p><b>Beta (14 - 30 Hz)</b></p>    | <p><b>Alfa (8-13.99 Hz)</b></p>      |
| <p><b>Theta (4 - 7.99 Hz)</b></p>  | <p><b>Delta (0.1 - 3.99 Hz)</b></p>  |

Figura 2-10 Tipos de Ondas Cerebrales.

- Ondas Beta: Se producen cuando el cerebro está despierto e implicado en actividades mentales. Son ondas amplias y las de mayor velocidad de transmisión de las cuatro. Denotan una actividad mental intensa.
- Ondas Alfa: Alfa representa un estado de escasa actividad cerebral y relajación. Estas ondas son más lentas y de mayor amplitud que las Beta.
- Ondas Theta: Son ondas de mayor amplitud y menor frecuencia. Se alcanzan bajo un estado de calma profunda.
- Ondas Delta: Son las ondas de mayor amplitud y menor frecuencia. Nunca llegan a cero, pues eso significaría la muerte cerebral. Se generan ante un estado de 'sueño profundo'. Cuando nos vamos a dormir, las ondas cerebrales van pasando sucesivamente de beta a alfa, theta y finalmente, delta. Durante el sueño se producen ciclos que duran unos 90 minutos.

## 2.6. Potenciales evocados

Los potenciales evocados (PEs) son indicadores de procesos o subprocesos cognitivos o perceptivos.

Coles y Rugg (1995) definen los PEs como variaciones en el voltaje del EEG provocadas por sucesos sensoriales, motores o cognitivos. Estos cambios son capaces de informar sobre los procesos cognitivos asociados a diferentes sucesos. Pero para que estos potenciales se manifiesten en una señal de EEG, el sujeto que produce la señal debe de estar realizando una tarea que los evoque.

Una de las principales diferencias entre un PE y un EEG, es su voltaje. La amplitud de un PE se encuentre entre  $0.5\mu\text{V}$  y  $20\mu\text{V}$ , mientras que la de un EEG es de  $50\mu\text{V}$  a  $10\text{mV}$ .

Esta diferencia de amplitud hace que un potencial evocado sea imperceptible dentro de un EEG. Para poder solucionar esto, calculamos un potencial promedio. La actividad que se encuentre al margen de dicha excitación aparecerá de forma aleatoria, mientras que las de un PE será constante.

### 2.6.1. Características de los PEs

Un potencial evocado se define como una combinación de su polaridad, latencia, sensibilidad y topografía.

- Respecto a la polaridad, los PEs pueden ser positivos o negativos.
- La latencia suele medirse en milisegundos desde la presentación del estímulo hasta la aparición del pico o del valle, siendo este el punto de máxima amplitud.
- La topografía es la distribución sobre el cuero cabelludo.
- Como última característica tenemos la sensibilidad respecto a una determinada manipulación experimental. Es difícil de establecer, pues existen componentes bastante específicos.
- Potencial de disparidad (MMN): Se obtiene al presentar un estímulo discrepante dentro de una secuencia de estímulos auditivos.
- N400: Onda negativa que tiene topografía centroparietal y una latencia de 400ms.

### 2.6.2. Clasificación de los PEs

Los potenciales evocados se agrupan en dos clases: los que son previos a la ocurrencia del suceso y los posteriores a esta. A continuación, se describen algunos de ellos.

- LPR: Se trata de un potencial negativo que se produce cuando se prepara paraa realizar un movimiento con una mano. Presenta la máxima amplitud en las localizaciones precentrales.
- CNV: Es una onda negativa lenta que se produce cuando se presentan dos estímulos separados por un intervalo de tiempo. Alcanza su máxima amplitud cuanto mas cerca se esta del segundo estímulo.
- Componentes sensoriales: Son respuestas del sistema nervioso a estímulos externos.
- N100: Onda negativa que aparece a los 100ms después de un estímulo.
- P300, P3, P3a y P3b: Se trata de una serie de picos positivos que aparecen ante estímulos inesperados que son relevantes para el sujeto. La amplitud del mismo se ve modulada por el grado de expectación que el sujeto tiene del estímulo.

# 3 PRE-PROCESADO Y EXTRACCIÓN DE CARACTERÍSTICAS DE LOS EEG

---

## 3.1 Introducción

En este capítulo se describirá el método llevado a cabo para la extracción de diferentes características de cada uno de los EEG.

En primer lugar, se describirá el método que se ha llevado a cabo para la captación de los EEG. A continuación, se especificarán las diferentes operaciones a realizar en las señales con el fin de adecuarlas para su posterior estudio. Posteriormente se extraerán ciertos parámetros de interés de las señales pre-procesadas.

## 3.2 Captación de los EEG

Para la captación de los EEGs se ha sometido a los sujetos al paradigma de “oddball”.

Este proceso consiste en una secuencia aleatoria de dos estímulos diferentes, uno con mayor probabilidad que el otro. El sujeto tendrá que discriminar el estímulo menos frecuente pulsando un botón de respuesta.

Este estímulo genera el conocido potencial evocado “P300”. Es un potencial positivo de mayor amplitud que se genera sobre los electrodos parietales, que se manifiesta en torno a los 300ms.

## 3.3 Pre-procesado

Una vez adquiridas las señales, es necesario adaptarlas para que puedan proporcionar información útil. Los EEG suelen contener una gran cantidad de ruido y algunos artefactos con una amplitud tan grande, que no permite analizar correctamente la señal.

Para poder realizar este pre-procesado, utilizaremos MATLAB y un programa llamado Brainstorm, que utilizaremos para observar y aplicar el método SSP a las diferentes grabaciones.

### 3.3.1 Análisis SSP

El primer paso que se va a realizar en el pre-procesado, es la aplicación del método SSP.

Utilizando la herramienta Brainstorm, vamos a observar como la señal EEG tiene una serie de picos de gran amplitud en comparación con el resto de la señal. Estos picos corresponden a los llamados “blinks” (parpadeo) y nuestro primer objetivo será la detección y eliminación de los mismos.

Para ello, Brainstorm cuenta con funciones para la detección de eventos entre los que están los blinks. Utilizaremos el canal Veog como referencia para este proceso. Siendo este, un sensor colocado próximo al ojo y cuya función es la de detectar los parpadeos.

Una vez se han detectado los eventos, procedemos a aplicar el método SSP, consiguiendo en gran medida la supresión de ruido y artefactos no deseados. Consiguiendo así tener la señal perteneciente únicamente a los procesos cognitivos.

### 3.3.1.1 Fundamento

La proyección de la señal desde el espacio (SSP) es un método para el rechazo de perturbaciones externas.

A diferencia de muchos otros enfoques sobre la cancelación de ruido, SSP no requiere sensores adicionales de referencia para registrar las zonas de trastornos. En su lugar, SSP se basa en el hecho de que las distribuciones de campos magnéticos generados por las fuentes en el cerebro, tienen distribuciones espaciales suficientemente diferentes de las generadas por fuentes de ruido externo. Además, se asume implícitamente que el espacio lineal abarcado por los patrones de ruido externos significativos tiene una dimensión mínima. [1]

Sin pérdida de generalidad, siempre se puede descomponer cualquier medición de un canal  $b(t)$  en sus componentes de señal y ruido como:

$$b(t) = b_s(t) + b_n(t) \quad (3-1)$$

Además, si sabemos que  $b_n(t)$  está bien caracterizado por unos patrones de campo  $b_1 \dots b_m$ , podemos expresar la perturbación como

$$b_n(t) = U c_n(t) + e(t) \quad (3-2)$$

donde las columnas de  $U$  constituyen una base ortonormal para  $b_1 \dots b_m$ ,  $c_n(t)$  es un  $m$ -vector columna componente, y el término de error  $e(t)$  es pequeño y no presenta ninguna distribución espacial coherente a lo largo del tiempo, es decir,  $C_e = E\{e e^T\} = I$ . Posteriormente, llamaremos al espacio columna de  $U$ , el subespacio de ruido. La idea básica de la SSP es que podemos encontrar un pequeño conjunto de bases  $b_1 \dots b_m$  tal que las condiciones descritas anteriormente son satisfechas. Ahora podemos construir el operador de complemento ortogonal:

$$P_{\perp} = I - U U^T \quad (3-3)$$

y aplicarlo a  $b(t)$ , produciendo:

$$b(t) \approx P_{\perp} b_s(t) \quad (3-4)$$

desde  $P_{\perp} b_n(t) = P_{\perp} U c_n(t) \approx 0$ . El operador  $P_{\perp}$  se denomina “operador de proyección en el espacio de señal” y generalmente proporciona un considerable rechazo de ruido en la supresión de perturbaciones externas por un factor de 10 o más. La eficacia de la SSP depende de dos factores:

1. La base establecida  $b_1 \dots b_m$  debe ser capaz de caracterizar los patrones de campos de perturbación por completo.
2. Los ángulos entre el espacio subespacio de ruido abarcado por  $b_1 \dots b_m$  y los vectores de señal  $b_s(t)$  deben ser lo más cerca de  $\pi / 2$  como sea posible.

Si el primer requisito no se cumple, algo de ruido escapará porque  $P_{\perp} b_n(t) \neq 0$ . Si cualquiera de los vectores de las señales del cerebro  $b_s(t)$  está cerca del subespacio de ruido (no sólo el ruido sino también la señal), será atenuado por la aplicación de  $P_{\perp}$ .

Puesto que la proyección en el espacio de señal modifica los vectores que se originan en el cerebro, es necesario aplicar la proyección a la solución hacia adelante en el curso de los cálculos inversos.

La lógica de la computación SSP es el siguiente:

1. Tomar una pequeña ventana de tiempo alrededor de cada evento para capturar el efecto completo del artefacto. La ventana de tiempo predeterminado es  $[-200, +200]$  ms para parpadeo de los ojos, y  $[-40, +40]$  ms para los latidos del corazón.
2. Filtrar las señales en una banda de frecuencia de interés, en el que el artefacto es la más visible (en la práctica, extraemos un segmento de tiempo suficiente para que pueda ser filtrada apropiadamente, y cortar después de la filtración).
3. Concatenar todos estos bloques de tiempo en una matriz grande  $A = [b_1, \dots, b_m]$
4. Calcular la descomposición de valor singular de esta matriz  $A$ :  $[U, S, V] = \text{svd}(A, 'econ')$
5. Los vectores singulares  $U_i$  junto con los más altos valores singulares  $S_i$  son una base ortonormal del subespacio artefacto que queremos restar de las grabaciones. El software selecciona por defecto el vector con el mayor valor propio. Entonces es posible redefinir de forma interactiva los componentes seleccionados.
6. Calcular el operador de proyección:

$$P_{\perp_i} = I - U_i U_i^T \quad (3-5)$$

7. Aplicar esta proyección sobre grabaciones MEG o EEG  $F$ :  $F = P_{\perp_i} F$

$$F = P_{\perp_i} F \quad (3-6)$$

8. El proceso tiene que ser repetido por separado varias veces para cada tipo de sensor y cada artefacto.

### 3.3.1.2 Ejemplo Práctico

El algoritmo SSP se le aplicará a las señales EEG utilizando las funciones de la herramienta Brainstorm, que pueden ser consultadas en el anexo de este trabajo.

En las figuras se pueden ver las señales, correspondientes a uno de los registros del sujeto A, antes y después de aplicarles el algoritmo SSP. Las señales Veog+, Veog-, Heog+ y Heog- corresponden a unos electrodos situados alrededor de los ojos, cuya función es detectar los parpadeos que realiza el sujeto durante el registro.

Observamos en la figura 3-1 los picos en la señal, pertenecientes a los blinks:

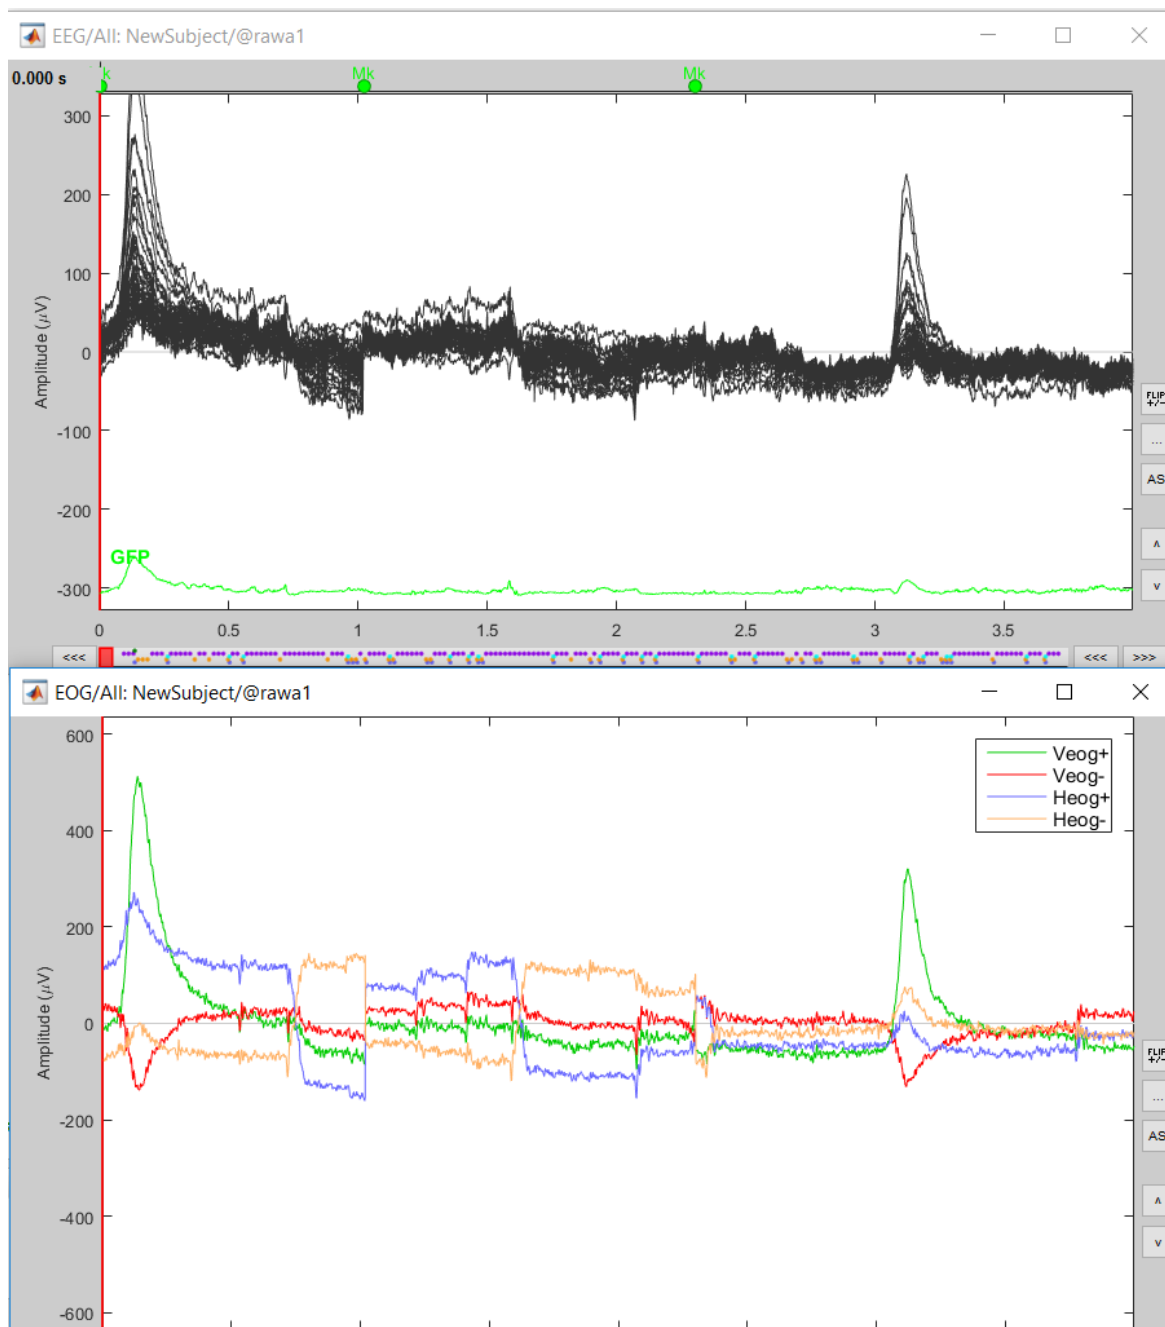


Figura 3-1 Señal sin procesar del EEG de A-1



Tras aplicar la detección de blinks (parpadeos) y el algoritmo SSP:




Figura 3-2 Señal, tras aplicar el algoritmo SSP, del EEG de A-1

Se aprecia como el algoritmo SSP ha reducido notablemente los artefactos no deseados correspondientes a los eventos “blinks”, hasta una amplitud igual a la de las señales pertenecientes a los procesos cognitivos.

### 3.3.2 Filtrado

Para poder estudiar los potenciales evocados y así poder llevar a cabo este estudio, se hace conveniente el filtrado de las señales de EEG. Esto es necesario porque, por regla general, los potenciales evocados se encuentran en frecuencias inferiores a los 35Hz. Con esto conseguiremos eliminar una gran cantidad de ruido y artefactos que suelen aparecer a frecuencias más altas.

Tras el filtrado, eliminamos las muestras que corresponden al transitorio del filtro. Con esto se elimina un conjunto de muestras que nos aportarían datos erróneos de los EEGs.

Se utiliza Matlab para el diseño y la implementación de los filtros, utilizando la función “designfilt”. A continuación se muestra a modo de ejemplo, el diseño del filtro paso de banda para la onda cerebral Alpha. Se introducirá como argumentos de la función: el orden del filtro, las bandas de frecuencia y la frecuencia de muestreo.

```
Filtro = designfilt('bandpassiir', 'FilterOrder', 4, ...  
                  'HalfPowerFrequency1', 8, 'HalfPowerFrequency2', 13.99,  
                  'SampleRate', 500);
```

Figura 3-3 Ejemplo de uso de la función designfilt para el diseño del filtro Alpha.

Para la implementación del mismo en el proceso de filtrado de nuestros registros, se utiliza la función “filtfilt”. La función realiza los siguientes procesos: Después de filtrar los datos en la dirección de entrada, se invierte la secuencia que se acaba de filtrar y se filtra de nuevo. Con esto se consigue que la salida del filtro tenga la fase igual a cero.

En este trabajo se han llevado a cabo cuatro tipos de filtrado para evaluar la señal, suprimir el ruido y los artefactos de los EEGs del banco de datos utilizado. A continuación, se describen los diferentes tipos de filtros que se han diseñado, y un ejemplo de como queda la señal EEG tras aplicarle dichos filtros.

- **Filtro paso de banda entre 0.1Hz y 3.99Hz:** Este filtrado se realiza para la detección de la onda cerebral Delta. Podemos observar en la figura un ejemplo de como quedaría la señal tras este filtro.




Figura 3-4 Señal de EEG tras el filtro Delta

- **Filtro paso de banda entre 4Hz y 7.99Hz:** Con este filtrado detectamos la onda cerebral Theta. En la siguiente figura, podemos observar un ejemplo de como sería.




Figura 3-5 Señal de EEG tras el filtro Theta

- **Filtro paso de banda entre 8Hz y 13.99Hz:** Con este filtrado detectamos la onda cerebral Alpha. En la figura, observamos un ejemplo de como sería.




Figura 3-6 Señal de EEG tras el filtro Alpha

- **Filtro paso de banda entre 14Hz y 30Hz:** Con este filtrado detectamos la onda cerebral Beta. En la figura, observamos un ejemplo de como sería.




Figura 3-7 Señal de EEG tras el filtro Beta.



### 3.3.3 Segmentación

Una vez realizado el filtrado de la señal y eliminados la mayor cantidad posible de ruido y artefactos no deseados de los EEGs, procedemos a dividir la señal en épocas. Estas épocas serán instantes temporales de cierta duración dentro del total del EEG continuo.

Para el análisis de este estudio, utilizaremos épocas de un segundo de duración y un solapamiento de 0.2 segundos entre cada una de ellas.

A continuación se detalla como se utilizan dichas épocas para la extracción de características y así poder analizar los EEGs de una manera más óptima.

## 3.4 Extracción de características

La extracción de características de las señales de los EEGs se define como el cálculo de parámetros de dicho registro con el fin de poder caracterizarlo mediante los mismos.

Se realizará la extracción de características para todos los bloques de todos los registros de la base de datos. Generándose los llamados vectores de características, que posteriormente utilizaremos en estudio con la red SVM.

Actualmente, existen multitud de parámetros utilizados para caracterizar los diferentes potenciales cerebrales tanto en el dominio temporal como en el frecuencial. En este estudio se ha utilizado la potencia por ser la característica más discriminadora, que nos permite diferenciar con mayor claridad a los diferentes sujetos.

Para el estudio no será útil el cálculo de la varianza, pues su valor será igual al de la potencia. Esto se debe a que tras el filtrado, la componente de continua de los diferentes registros EEG es eliminada. Por tanto, la media tomará valores muy próximos a cero.

Si nos fijamos en la fórmula de la varianza de la señal:

$$Var(x) = E[x^2] - E[x]^2 \quad (3-6)$$

Si la media de la señal es cero, se demuestra que la potencia o energía de la señal será igual a la varianza. Por tanto no consideraremos la varianza en el estudio.

### 3.4.1 Potencia

La potencia de una señal se define como la suma de todos los valores que toma la señal al cuadrado, dividido entre el número de muestras de las que consta dicha señal (N puntos).

$$P = \frac{\sum_{i=1}^N |x(t)|^2}{N} \quad (3-7)$$



# 4 CLASIFICACIÓN

Este capítulo se centrará en la descripción de las bases teóricas relativas a los clasificadores y de su implementación en este trabajo.

En este estudio se ha utilizado un clasificador, perteneciente a la rama de los clasificadores lineales generalizados, capaz de separar diferentes grupos mediante fronteras de decisión muy complejas.

Mediante su uso se pretende obtener una medida de las tasas de acierto en la clasificación de diferentes sujetos. Como entrada se utilizarán las características extraídas a los EEGs, que se detallan en el capítulo anterior.

## 4.1 Máquinas de Soporte Vectorial

Las Máquinas de Soporte de Vectores (Support Vector Machine, SVM) son sistemas de aprendizaje supervisado que pertenecen a la rama de los clasificadores lineales generalizados. En este trabajo se ha utilizado la librería LIBSVM, por lo que se utilizará este para la descripción de las bases teóricas.

Una clasificación suele implicar separar los datos en conjuntos de vectores de entrenamiento y de pruebas. Cada conjunto de vectores de entrenamiento, debe contener una etiqueta que determine su clase y las características o variables extraídas.

El objetivo de una SVM es la creación de un modelo, a partir de los datos de entrenamiento, que posteriormente podrá predecir la clase a la que pertenecen los datos de prueba. [6]




Figura 4-1 Funcionamiento SVM

Los vectores de entrenamiento  $x_i$  se transforman en un espacio de mayor dimensión a través de la función  $\phi$ . Formulando el problema para que el procedimiento de clasificación transforme los datos mediante las funciones kernel,  $K$ .

### 4.1.1 Descripción del clasificador lineal óptimo

Se basa en la selección del hiperplano,  $H_0$ , que actúa como frontera de separación entre las clases que se hayan considerado, maximizando la distancia de separación entre los vectores transformados. Esta distancia de separación se obtiene mediante la construcción de dos hiperplanos paralelos al anterior, siendo este, el de separación óptima. Estos dos hiperplanos paralelos deben contener al menos a uno de los vectores transformados, denominado vector de soporte. Cuanto mayor sea la distancia mejor será la capacidad de clasificación del modelo.

Se caracterizan por su buena capacidad de generalización, estando esta directamente relacionada con la distancia entre los dos hiperplanos paralelos. Así como por minimizar el efecto de sobre-aprendizaje del conjunto de entrenamiento, del que son susceptibles otros métodos de aprendizaje como los clasificadores basados en redes neuronales.

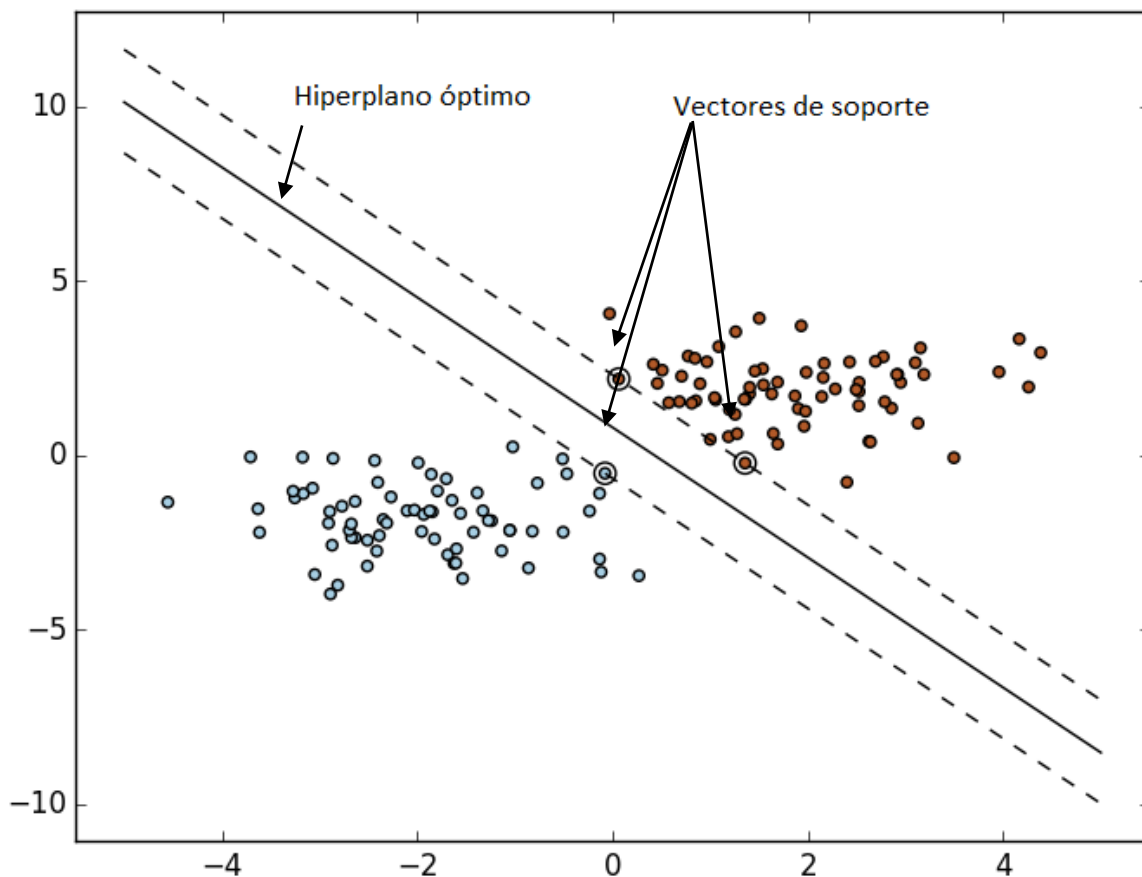


Figura 4-2 Representación del hiperplano óptimo junto con sus vectores de soporte asociados



#### 4.1.2 Descripción del problema de optimización lineal

Dado un conjunto de datos o vectores de entrada  $x \in \mathbb{R}^n$  de las diferentes clases  $y \in \mathbb{N}$ , se desea encontrar el valor de los parámetros del hiperplano:  $\{w, b\}$ , que da lugar a la mayor separación del hiperplano a dichas clases.

Matemáticamente se obtiene la expresión recogida en la ecuación 4-1.

$$\begin{aligned} wx_i + b \leq y_i \quad / \quad \begin{cases} y_i = 1 & \forall x_i \in C_i = A \\ y_i = -1 & \forall x_i \in C_i = B \end{cases} \Rightarrow \\ \Rightarrow \exists (w^*, b^*) \quad / \quad w^*x + b^* = 0 \quad \text{Hiperplano óptimo} \end{aligned} \quad (4-1)$$

Para el desarrollo formal solo se usan dos clases:  $\{A, B\}$ , pero las conclusiones son extrapolables para el caso de un mayor número de clases.

El mejor hiperplano, para la clasificación de los datos de prueba, será aquel cuya distancia de separación a los vectores vecinos de las dos clases sea máxima.

Al hiperplano,  $H_0$ , así obtenido se le denomina hiperplano de separación óptima, para el que el margen es máximo. Este margen se obtiene como la distancia entre los dos hiperplanos paralelos, que contienen al menos un vector de cada clase, denominados vectores de soporte.

La expresión matemática de estos dos hiperplanos paralelos  $H_1$  y  $H_2$  se muestra a continuación:

$$H_1: wx - b = 1 \quad (4-2)$$

$$H_2: wx - b = -1 \quad (4-3)$$

Si los vectores de entrada son linealmente separables, es posible elegir dos hiperplanos entre los que no haya datos y maximicen la distancia entre ellos.

Geoméricamente el vector  $w$  es perpendicular al hiperplano que define, y la distancia al origen del sistema de coordenadas viene dada por la siguiente ecuación.

$$d = \frac{b}{|w|} \quad (4-4)$$

Utilizando las ecuaciones 4-2 y 4-3 se obtiene que la distancia entre  $H_1$  y  $H_2$  es:

$$d = \frac{2}{|w|} \quad (4-5)$$

Por lo que el objetivo de maximizar la distancia de separación entre ambos hiperplanos es equivalente a minimizar  $|w|$ . A la vez que la solución propuesta debe evitar que haya vectores de entrada dentro de la región entre ambos hiperplanos.

$$y_i(wx_i - b) \geq 1, \quad 1 \leq i \leq n \quad (4-6)$$

Todo lo anterior da lugar a la expresión del siguiente problema de optimización:

$$\text{Minimizar} \quad \Omega(w) = \frac{1}{2} |w|^2 \quad (4-7)$$

$$\text{Considerando la restricción} \quad y_i(wx_i - b) \geq 1, \quad 1 \leq i \leq n \quad (4-8)$$

Para su resolución, se utiliza el método de multiplicadores de Lagrange, dando lugar a la siguiente función lagrangiana:

$$L(w, b, \alpha) = \frac{1}{2} w^T w - \sum_{i=1}^N \alpha_i [y_i(w^T x_i + b) - 1] \quad (4-9)$$

Cuya resolución en el punto óptimo da lugar al sistema de ecuaciones 4-10 y 4-11, resoluble si los datos son linealmente separables, asegurando que el mínimo encontrado es un mínimo global.

$$\frac{\delta L}{\delta w} = 0 \rightarrow w = \sum_{i=1}^N \alpha_i y_i x_i \quad (4-10)$$

$$\frac{\delta L}{\delta b} = 0 \rightarrow w = \sum_{i=1}^N \alpha_i y_i = 0 \quad (4-11)$$

Estas ecuaciones dan lugar a:

$$w^T w = w^T \sum_{i=1}^N \alpha_i y_i x_i = \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j x_i x_j \quad (4-12)$$

Que sustituyendo en la ecuación 4-9 hacen que la función a maximizar  $Q(\alpha)$  sea:

$$J(w, b, \alpha) = Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j x_i x_j \quad (4-13)$$

Estando sujeta a las restricciones:

$$\sum_{i=1}^N \alpha_i y_i = 0 \quad (4-14)$$

$$\alpha_i \geq 0 \quad i = 1, \dots, N$$

Donde se puede demostrar que sólo los  $\alpha_i$  correspondientes a vectores soporte son distintos de cero.

De todo lo cual se deduce que el hiperplano de separación óptima,  $H_0$ , solo depende de los vectores de soporte provenientes del conjunto de entrenamiento.

Una vez hayados los valores  $\alpha_i^*$  se obtienen los coeficientes del hiperplano:

$$\alpha_i^* \Rightarrow w^* = \sum_{i=1}^N \alpha_i^* y_i x_i \rightarrow b^* = 1 - w^{*T} x_s \quad (4-15)$$

### 4.1.3 Margen blando

En el análisis anterior se considera que en la región comprendida entre los hiperplanos paralelos al óptimo no va a haber ningún vector, ni que estos pudieran ser erróneamente clasificados. Esta consideración es muy difícil de encontrar en caso práctico real. Por eso se propuso una nueva idea de margen máximo, a la que se le denomina “Margen blando”.

Para este se selecciona el hiperplano que separando los vectores de entrada tan limpiamente como sea posible, permite errores de clasificación a la vez que maximiza la distancia al resto de los datos que han sido identificados correctamente.




Figura 4-3 Separación lineal: margen blando.

Esta nueva variante introduce las denominadas “variables de holgura”:  $h_i, i = \{1, \dots, N\}$ , que permiten ponderar el grado de desclasificación de cada vector, tal que:

$$y_i(w^T x_i + b) \geq 1 - h_i, \quad i = 1, \dots, N \quad (4-16)$$

En donde:

$$h_i \geq 0 \quad \forall i \Rightarrow \begin{cases} 0 \leq h_i \leq 1 & \rightarrow \text{clasificación correcta} \\ h_i > 1 & \rightarrow \text{clasificación incorrecta} \end{cases} \quad (4-17)$$

Originando que la nueva función objetivo,  $\Omega(w, h)$ , contenga un término que penaliza a la variables de holgura, convirtiéndose la optimización en un balance entre el mayor margen y el error de penalización.

En caso de que la función de penalización sea lineal, la función objetivo 4-7 se transforma en:

$$\text{Minimizar } \Omega(w, h) = \frac{1}{2} |w|^2 + C \sum_{i=1}^N h_i \quad (4-18)$$

$$\text{Considerando la restricción } y_i(wx_i - b) \geq 1, \quad 1 \leq i \leq n \quad (4-19)$$

Siguiendo un proceso de resolución semejante al seguido con anterioridad, da lugar a que en el problema dual las variables de ajuste desaparezcan, manteniéndose sólo la constante C como restricción adicional en los multiplicadores de Lagrange, la cual controla el compromiso entre complejidad del modelo y el número de datos no separables, esta constante se especifica empíricamente mediante el procedimiento de la validación cruzada. [3]

#### 4.1.4 Clasificador no lineal

Hay casos en los que los conjuntos de datos no son separables linealmente, por eso se propuso un nuevo tipo de clasificador, que tras la transformación a través de una función no lineal  $\Phi(\cdot)$  de los conjuntos de datos originales a conjuntos de datos en espacios de características original, y separables linealmente, emplearan el algoritmo de determinación de hiperplano óptimo,  $H_0$ , como método de separación de dichos conjuntos. [3]

El algoritmo resultante es formalmente similar al descrito con anterioridad, con la diferencia de que el producto escalar de vectores original es reemplazado por una función de kernel K no lineal.

El procedimiento aplica una transformación no lineal,  $\Phi(\cdot)$ , a los datos de entrada convirtiéndolos en un espacio de dimensión superior, en el cual es posible realizar una separación lineal de los datos transformados.

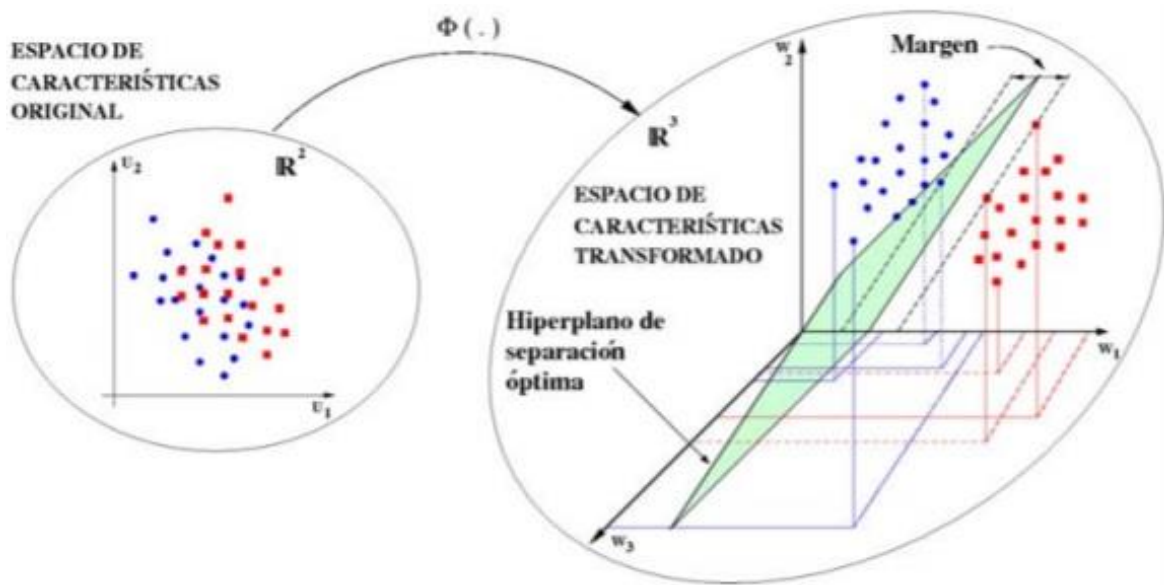


Figura 4-4 Clasificador no lineal

Por lo que, teniendo en cuenta el desarrollo del procedimiento de optimización lineal anterior y la consideración realizada para margen blando, la función objetivo a minimizar,  $\Omega(w, h)$ , es equivalente a la considerada en la ecuación 4-18:

$$\Omega(w, h) = \frac{1}{2} w^T w + C \sum_{i=1}^N h_i \quad (4-20)$$

Teniendo en cuenta que en las restricciones equivalentes a la ecuación 4-19, la función de transformación  $\Phi(x)$  sustituye al vector de datos  $x$ , se da lugar a:

$$\begin{aligned} y_i(w^T \Phi(x_i) + b) &\geq 1 - h_i, \quad i = 1, \dots, N \\ h_i &\geq 0 \quad \forall i \end{aligned} \quad (4-21)$$

Obteniéndose los parámetros del hiperplano  $\{w, b\}$  en el nuevo espacio de características  $\mathbb{R}^m$ .

Hay que tener en cuenta que la transformación explícita,  $\Phi(x)$ , es costosa en caso de que  $m$  sea elevado, por lo que se buscan alternativas para no tener que realizar la transformación explícita de cada dato, dando lugar a las denominadas funciones Kernel  $K$ .

#### 4.1.4.1 Función Kernel K

Teniendo en cuenta que en la ecuación 4-13 de la formulación dual, aparece solamente el producto escalar de los datos, y que su equivalente para el caso de clasificación no lineal sería la siguiente ecuación:

$$Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \Phi(x_i)^T \Phi(x_j) \quad (4-22)$$

El objetivo será encontrar una función en la que el producto escalar de las transformaciones de cada dato,  $\Phi(x)$ , sea igual a la transformación del producto escalar de los datos, lo cual origina que no sea preciso transformar explícitamente los datos de entrada para resolver el problema de optimización o entrenamiento de las SVMs, ni que sea preciso el conocimiento exacto de la expresión de la función  $\Phi(x)$ .

## 4.2 Implementación en el trabajo

Para este estudio se ha utilizado el toolbox LIBSVM (A Library for Support Vector Machines) de MATLAB. Es un software integrado para realizar la clasificación, regresión y la estimación de distribuciones mediante SVM.

Se han utilizado los EEGs de tres sujetos distintos, aplicándoles el pre-procesado explicado en el capítulo anterior. Una vez extraídas las características que se van a utilizar, se han generado vectores con el formato con el que trabaja LIBSVM. Estos vectores serán los utilizados para el entrenamiento y las posteriores pruebas, para obtener un conjunto de tasas de éxito en la identificación de un sujeto por su EEG.

# 5 RESULTADOS

En este capítulo se pretenden exponer los diferentes resultados extraídos de la Máquina de Soporte Vectorial.

En primer lugar, se demostrará el principio por el cual es posible llegar a los resultados que se van a estudiar en este TFG. A continuación, se llevarán a cabo una serie de pruebas en las que analizaremos diferentes posibilidades de clasificación e identificación de los sujetos. Se realizarán pruebas para distintos sensores y ondas cerebrales, obteniendo la tasa de acierto de cada uno de ellos. Se hará uso de los métodos expuestos en los capítulos anteriores (SSP, filtrado, extracción de características) para obtener los distintos resultados de interés del estudio.

## 5.1 Base de datos

Para este estudio se ha utilizado una base de datos que consta de tres sujetos (A, B, C), donde a cada uno se le han registrado dos EEGs. En la siguiente tabla se muestra el nombre con el que se ha trabajado con cada uno de ellos, con la intención de facilitar su mención en los apartados posteriores.

| SUJETO A        | SUJETO B        | SUJETO C        |
|-----------------|-----------------|-----------------|
| A-1 (308.8 seg) | B-1 (298.8 seg) | C-1 (314 seg)   |
| A-2 (306.4 seg) | B-2 (299.2 seg) | C-2 (312.5 seg) |

Tabla 5-1 Base de datos.

## 5.2 Demostración del principio

El primer objetivo de este capítulo será demostrar que, en la clasificación de los vectores de características de un mismo sujeto, no será posible una separación viable de los mismos. Mientras que, para sujetos diferentes, se podrá obtener una separación que permita obtener resultados positivos en la clasificación de los vectores de prueba.

El primer experimento se ha llevado a cabo como sigue: para cada individuo hemos dividido sus registros en bloques de un segundo y extraído las características (potencia por bandas) del mismo. Después hemos entrenado una red SVM con los bloques de los dos registros del sujeto, aprendiendo la red a diferenciar entre ambos, si es posible. Se pretende comprobar si la red SVM es capaz o no de apreciar las diferencias.

- La siguiente figura muestra los vectores de características de dos registros de un mismo individuo. Se utilizarán los vectores de características de los dos EEGs correspondientes al sujeto “A” filtrados para la onda cerebral Delta. Se observa en la figura que las características se superponen, siendo por tanto imposible discriminarlas. Este hecho se interpreta como que no existen diferencias significativas para una misma persona entre diferentes sesiones. Podemos observarlo en la figura 5-1.




Figura 5-1 Representación de los vectores de características para el sujeto “A” correspondientes a la onda cerebral Delta. Para la representación se han tomado únicamente las características de los electrodos Fp1 y F7.



- La siguiente figura, al igual que la anterior, muestra los vectores de características de dos registros de un mismo individuo. Se utilizarán los vectores de características de los dos EEGs correspondientes al sujeto “B” filtrados para la onda cerebral Alpha. Se observa en la figura que las características se superponen, siendo por tanto imposible discriminarlas. Este hecho se interpreta como que no existen diferencias significativas para una misma persona entre diferentes sesiones. Podemos observarlo en la figura 5-2.




Figura 5-2 Representación de los vectores de características para el sujeto “B” correspondientes a la onda cerebral Alpha. Para la representación se han tomado únicamente las características de los electrodos Fp1 y F7.

Este segundo experimento se ha llevado a cabo como sigue: para cada individuo hemos dividido sus registros en bloques de un segundo y extraído las características (potencia por bandas) del mismo. Después hemos entrenado una red SVM con los bloques de dos registros de sujetos diferentes, aprendiendo la red a diferenciar entre ambos, si es posible. Se pretende comprobar si la red SVM es capaz o no de apreciar las diferencias.

- La siguiente figura muestra los vectores de características de dos registros de dos individuos distintos. Se utilizarán los vectores de características de los dos EEGs correspondientes al sujeto "A-2" y a "B-1", filtrados para la onda cerebral Beta. Se observa en la figura que las características no se superponen, siendo por tanto posible discriminarlas. Este hecho se interpreta como que existen diferencias significativas para diferentes personas. Podemos observarlo en la figura 5-3.




Figura 5-3 Representación de los vectores de características para el sujeto "A-2" y "B-1" correspondientes a la onda cerebral Beta. Para la representación se han tomado únicamente las características de los electrodos Fp1 y F7.

- La siguiente figura muestra los vectores de características de dos registros de dos individuos distintos. Se utilizarán los vectores de características de los dos EEGs correspondientes al sujeto “A-1” y a “C-1”, filtrados para la onda cerebral Beta. Se observa en la figura que las características no se superponen, siendo por tanto posible discriminarlas. Este hecho se interpreta como que existen diferencias significativas para diferentes personas. Podemos observarlo en la figura 5-3.

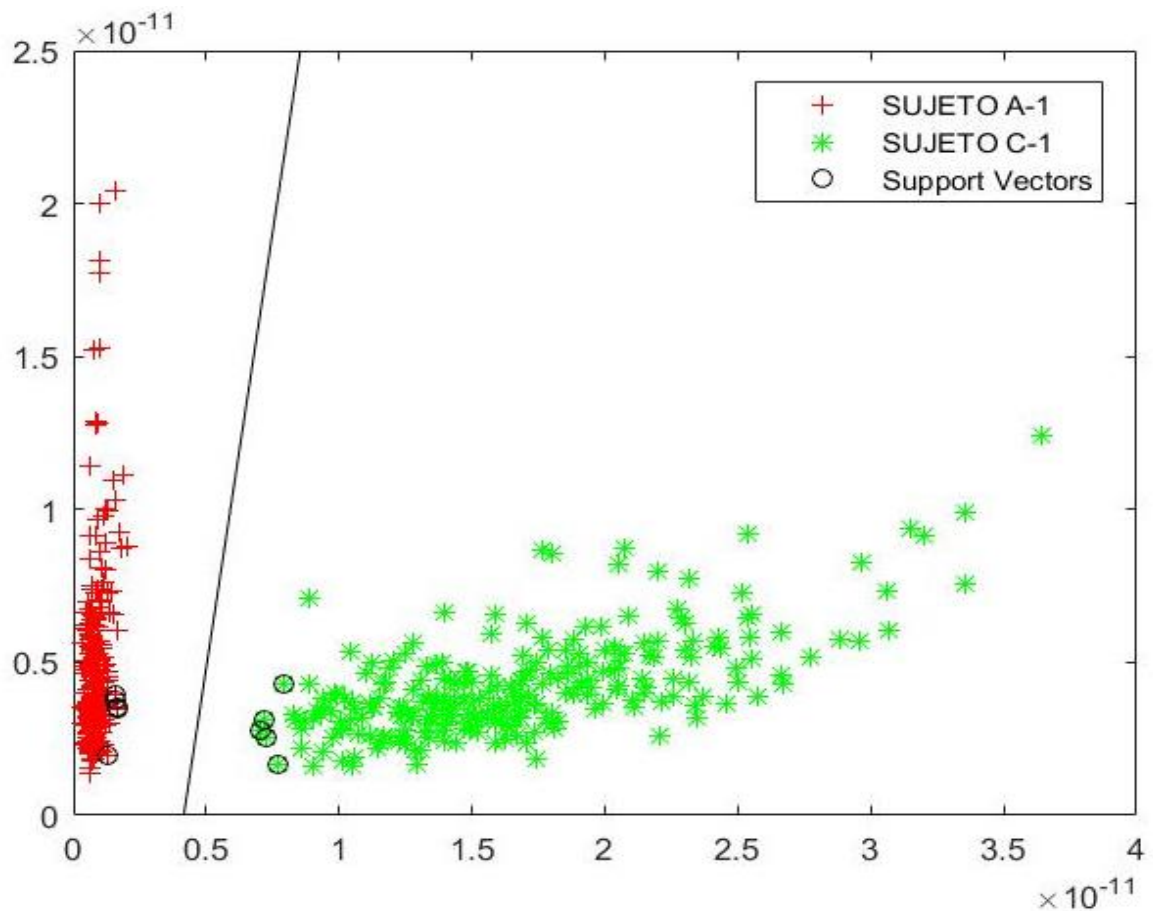


Figura 5-4 Representación de los vectores de características para el sujeto “A-1” y “C-1” correspondientes a la onda cerebral Beta. Para la representación se han tomado únicamente las características de los electrodos Fp1 y F7.

### 5.3 Resultados de la clasificación. Caso 1

En este primer estudio se han utilizado los sensores Fp1 y F7, situados en el lóbulo frontal, para conformar los vectores de características de entrenamiento de la red SVM.

Este experimento se ha llevado a cabo como sigue: para cada individuo hemos dividido sus registros en bloques de un segundo y extraído las características (potencia por bandas) del mismo. Después hemos entrenado una red SVM con los bloques de dos registros, un registro de un sujeto y otro registro de un individuo diferente, aprendiendo la red a diferenciar entre ambos, como hemos demostrado en el experimento anterior que es posible.

Finalmente, hemos alimentado esta red ya entrenada con los vectores del segundo registro de uno de los sujetos. Se pretende comprobar si la red SVM es capaz o no, y con que tasa de acierto, de identificar al sujeto al que pertenece el vector de características que se acaba de introducir.

#### 5.3.1 Sujeto A

Se realizan diferentes pruebas en las que se calculará la tasa de acierto en la identificación del sujeto "A". Se usará como vectores de entrenamiento los correspondientes a "A-1" y los correspondientes a los otros dos individuos. Para realizar la prueba de identificación se utilizarán los vectores de características de "A-2".

| A-1   | B-1 | B-2 | C-1  | C-2  |
|-------|-----|-----|------|------|
| BETA  | 72% | 54% | 100% | 100% |
| ALPHA | 48% | 46% | 98%  | 100% |
| THETA | 48% | 38% | 100% | 100% |
| DELTA | 98% | 90% | 92%  | 96%  |

Tabla 5-2 Tasas de acierto. Caso 1. Sujeto A.

En las siguientes figuras van a representarse cómo estarían situados los vectores de características para algunos de los casos anteriores, a modo de demostración de los resultados expuestos en la tabla anterior.

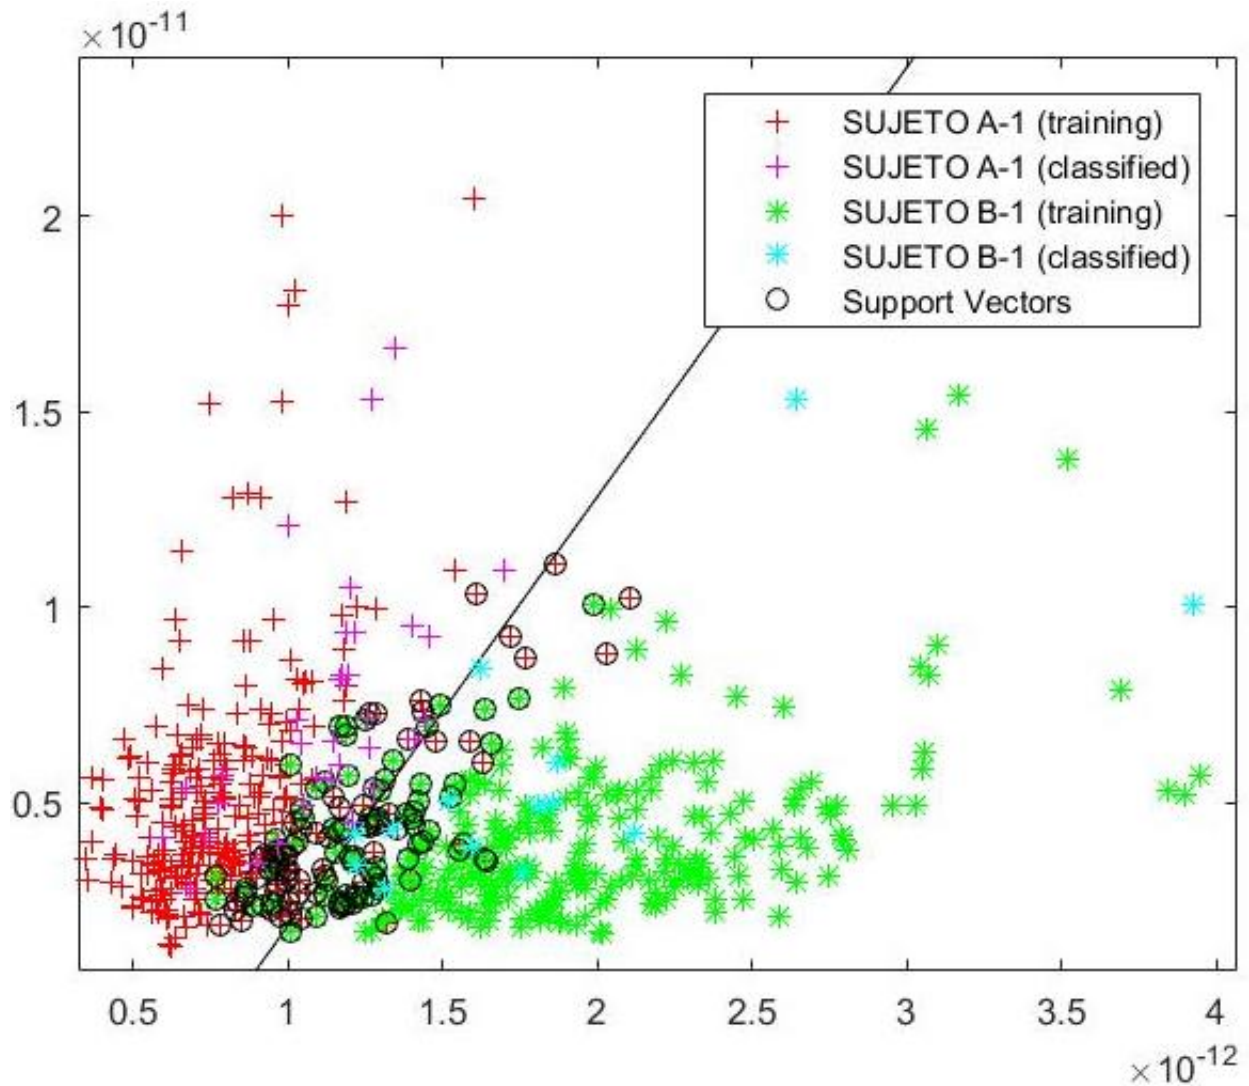


Figura 5-5 Representación de los vectores de características para el sujeto "A-1" y "B-1" para la onda cerebral Beta, correspondientes a los sensores Fp1 y F7.

Se observa de qué manera para el sensor Fp1 (Eje de abscisas), la potencia del sujeto B-1 es mayor que para A-1. Siendo, para el sensor F7 (Eje de ordenadas), aproximadamente la misma para ambos sujetos.

Por tanto, el sensor Fp1 será, en este caso, el que produce la separación entre ambos sujetos. Permitiendo que la SVM sea capaz de clasificar a los dos individuos y obteniendo una buena tasa de acierto en la identificación del sujeto A-2.




Figura 5-6 Representación de los vectores de características para el sujeto “A-1” y “B-2” para la onda cerebral Alpha, correspondientes a los sensores Fp1 y F7.

Se observa cómo para el sensor Fp1 (Eje de abscisas), la potencia del sujeto B-2 es parecida a la de A-1 en la zona donde hay mayor densidad de puntos por parte de ambos sujetos. Siendo, para el sensor F7 (Eje de ordenadas), aproximadamente la misma para ambos.

Por tanto, en este caso, ninguno de los dos sensores produce una separación apropiada entre ambos sujetos. Esto no permite que la SVM sea capaz de clasificar el vector (A-2) de una forma óptima.



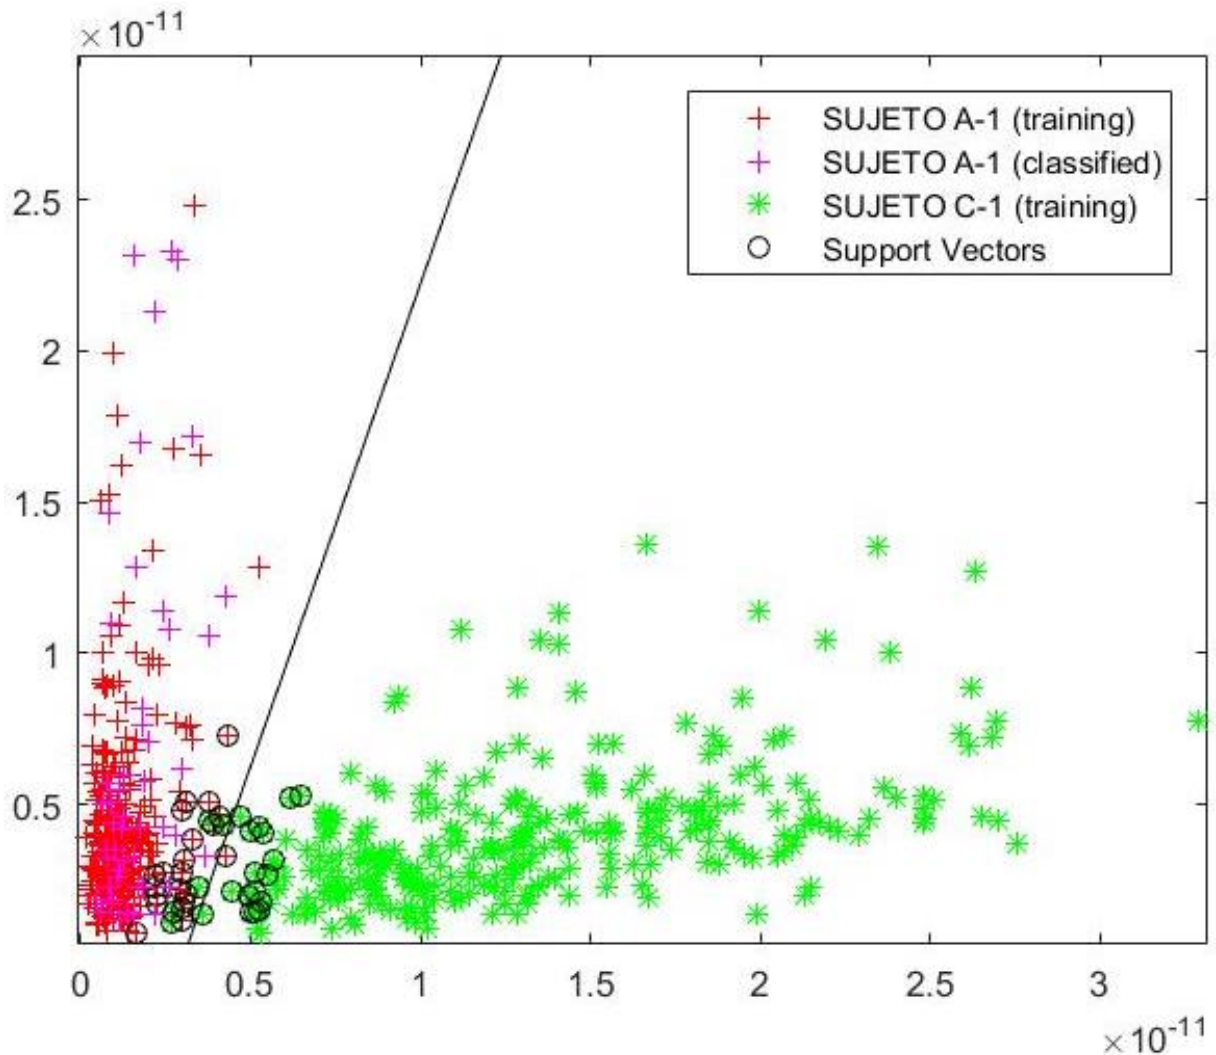


Figura 5-7 Representación de los vectores de características para el sujeto “A-1” y “C-1” para la onda cerebral Theta, correspondientes a los sensores Fp1 y F7.

Se observa de qué manera para el sujeto C-1 la potencia se distribuye principalmente sobre el sensor Fp1 (Eje de abscisas), mientras que para la persona A-1 es sobre el sensor F7 (Eje de ordenadas).

Esta diferencia permitirá una amplia separación entre ambos sujetos, haciendo que la SVM sea capaz de clasificar a los dos individuos, obteniendo una óptima tasa de acierto en la identificación del sujeto A-2.




Figura 5-8 Representación de los vectores de características para el sujeto “A-1” y “C-2” para la onda cerebral Delta, correspondientes a los sensores Fp1 y F7.

Se observa de qué manera para el sujeto C-2 la potencia se distribuye principalmente sobre el sensor Fp1 (Eje de abscisas), mientras que para la persona A-1 es sobre el sensor F7 (Eje de ordenadas).

Esta diferencia permitirá una amplia separación entre ambos sujetos, permitiendo que la SVM sea capaz de clasificar a los dos individuos y obteniendo una óptima tasa de acierto en la identificación del sujeto A-2.



### 5.3.2 Sujeto B

Se realizan diferentes pruebas en las que se calculará la tasa de acierto en la identificación del sujeto "B". Se usará como vectores de entrenamiento los correspondientes a "B-1" y los correspondientes a los otros dos individuos. Para realizar la prueba de identificación se utilizarán los vectores de características de "B-2".

| B-1   | A-1 | A-2 | C-1  | C-2  |
|-------|-----|-----|------|------|
| BETA  | 72% | 62% | 100% | 100% |
| ALPHA | 66% | 39% | 97%  | 99%  |
| THETA | 68% | 81% | 98%  | 99%  |
| DELTA | 61% | 54% | 20%  | 9%   |

Tabla 5-3 Tasas de acierto. Caso 1. Sujeto B.

En las siguientes figuras van a representarse cómo estarían situados los vectores de características para algunos de los casos anteriores, a modo de demostración de los resultados expuestos en la tabla anterior.




Figura 5-9 Representación de los vectores de características para el sujeto “B-1” y “A-1” para la onda cerebral Beta, correspondientes a los sensores Fp1 y F7.

Se observa cómo para el sensor Fp1 (Eje de abscisas), la potencia del sujeto B-1 es mayor que para A-1. Siendo, para el sensor F7 (Eje de ordenadas), aproximadamente la misma para ambos sujetos.

Por tanto, el sensor Fp1 será, en este caso, el que produce la separación entre ambos sujetos. Permitiendo que la SVM sea capaz de clasificar a los dos individuos y obteniendo una buena tasa de acierto en la identificación del sujeto B-2.




Figura 5-10 Representación de los vectores de características para el sujeto “B-1” y “A-2” para la onda cerebral Alpha, correspondientes a los sensores Fp1 y F7.

Para este caso, la potencia de ambos sujetos en estos dos sensores es muy parecida. Es decir, que ninguno de los dos sensores será discriminatorio. Esto hará que a la SVM no lo sea posible hacer una correcta clasificación del vector de prueba. Esto se ve reflejado en la baja tasa de acierto.




Figura 5-11 Representación de los vectores de características para el sujeto “B-1” y “C-1” para la onda cerebral Theta, correspondientes a los sensores Fp1 y F7.

Se observa de qué manera para el sujeto C-1 la potencia se distribuye principalmente sobre el sensor Fp1 (Eje de abscisas), mientras que para la persona B-1 es sobre el sensor F7(Eje de ordenadas).

Esta diferencia permitirá una amplia separación entre ambos sujetos, por lo que la SVM será capaz de clasificar a los dos individuos obteniendo una óptima tasa de acierto en la identificación del sujeto B-2.




Figura 5-12 Representación de los vectores de características para el sujeto “B-1” y “C-2” para la onda cerebral Delta, correspondientes a los sensores Fp1 y F7.

Para esta onda cerebral, ninguno de los dos sensores registra valores discriminatorios para estos dos EEGs. Los dos sujetos se solapan en la zona con mayor densidad de puntos.

Esto hará que a la SVM no lo sea posible hacer una correcta clasificación del vector de prueba. Esto se ve reflejado en la baja tasa de acierto.

### 5.3.3 Sujeto C

Se realizan diferentes pruebas en las que se calculará la tasa de acierto en la identificación del sujeto "C". Se usará como vectores de entrenamiento los correspondientes a "C-1" y los correspondientes a los otros dos individuos. Para realizar la prueba de identificación se utilizarán los vectores de características de "C-2".

| C-1   | A-1  | A-2  | B-1  | B-2  |
|-------|------|------|------|------|
| BETA  | 100% | 100% | 100% | 100% |
| ALPHA | 99%  | 100% | 97%  | 98%  |
| THETA | 99%  | 99%  | 100% | 99%  |
| DELTA | 93%  | 90%  | 86%  | 94%  |

Tabla 5-4 Tasas de acierto. Caso 1. Sujeto C.

En las siguientes figuras van a representarse como estarían situados los vectores de características para algunos de los casos anteriores, a modo de demostración de los resultados expuestos en la tabla anterior.




Figura 5-13 Representación de los vectores de características para el sujeto “C-1” y “A-1” para la onda cerebral Beta, correspondientes a los sensores Fp1 y F7.

Se observa cómo para el sujeto C-1 la potencia se distribuye principalmente sobre el sensor Fp1 (Eje de abscisas), mientras que para la persona A-1 es sobre el sensor F7 (Eje de ordenadas). La diferencia de potencia para el sensor Fp1 entre ambos sujetos es muy grande, lo que produce una amplia separación entre los dos, esto hará que la SVM sea capaz de clasificar a los dos individuos con una óptima tasa de acierto en la identificación del sujeto C-2.






Figura 5-14 Representación de los vectores de características para el sujeto "C-1" y "A-2" para la onda cerebral Alpha, correspondientes a los sensores Fp1 y F7.

Se observa de qué manera para el sujeto C-1 la potencia se distribuye principalmente sobre el sensor Fp1 (Eje de abscisas), mientras que para la persona A-2 es sobre el sensor F7 (Eje de ordenadas). Al igual que para el caso anterior, la diferencia de potencia para el sensor Fp1 entre ambos sujetos es lo suficientemente grande, lo que produce una amplia separación entre los dos. Esto hará que la SVM sea capaz de clasificar a los dos individuos con una óptima tasa de acierto en la identificación del sujeto C-2.






Figura 5-15 Representación de los vectores de características para el sujeto "C-1" y "B-1" para la onda cerebral Theta, correspondientes a los sensores Fp1 y F7.

Al igual que en los casos anteriores, la amplia diferencia de potencia entre ambos sujetos en el sensor Fp1, permitirá una óptima tasa de aciertos en la clasificación de vector de prueba C-2.




Figura 5-16 Representación de los vectores de características para el sujeto “C-1” y “B-2” para la onda cerebral Delta, correspondientes a los sensores Fp1 y F7.

Para el caso de la onda cerebral Delta, la diferencia de potencia no será tan grande. Pero se observa que igual que en los casos anteriores, para el sujeto C-1 la potencia se distribuye principalmente para por el sensor Fp1 (Eje de abscisas). Por el contrario, para B-2, esta se distribuye por el sensor F7 (Eje de ordenadas).

A pesar de que la diferencia entre ambos no es tan grande como en casos anteriores, la SVM será capaz de clasificarlos con unas tasas de éxito alta.

## 5.4 Resultados de la clasificación. Caso 2

En este apartado se ha utilizado como vectores de entrenamiento un registro de cada sujeto. Utilizando el segundo como vectores de prueba. En este segundo estudio se han utilizado todos los sensores.

En este segundo estudio se han utilizado todos los sensores que conforman los registros, para obtener los vectores de características de entrenamiento de la red SVM.

Este experimento se ha llevado a cabo como sigue: para cada individuo hemos dividido sus registros en bloques de un segundo y extraído las características (potencia por bandas) del mismo. Después hemos entrenado una red SVM con los bloques de dos registros, un registro de un sujeto y otro registro de un individuo diferente, aprendiendo la red a diferenciar entre ambos, como hemos demostrado en el experimento anterior que es posible.

Finalmente, hemos alimentado esta red ya entrenada con los vectores del segundo registro de uno de los sujetos. Se pretende comprobar si la red SVM es capaz o no, y con que tasa de acierto, de identificar al sujeto al que pertenece el vector de características que se acaba de introducir.

### 5.4.1 Sujeto A

Se realizan diferentes pruebas en las que se calculará la tasa de acierto en la identificación del sujeto "A". Se usará como vectores de entrenamiento los correspondientes a "A-1" y los correspondientes a los otros dos individuos. Para realizar la prueba de identificación se utilizarán los vectores de características de "A-2".

| A-1   | B-1 | B-2 | C-1  | C-2 |
|-------|-----|-----|------|-----|
| BETA  | 90% | 99% | 100% | 99% |
| ALPHA | 95% | 92% | 99%  | 92% |
| THETA | 92% | 90% | 98%  | 98% |
| DELTA | 76% | 86% | 96%  | 97% |

Tabla 5-5 Tasas de acierto. Caso 2. Sujeto A.

En las siguientes figuras van a representarse de qué manera estarían situados los vectores de características para algunos de los casos anteriores. Debido a la alta dimensionalidad de los datos, no es posible hacer una representación total de los mismos. Por tanto, se utilizarán únicamente dos sensores para poder generar las figuras. Se podrá observar una aproximación de la tasa de acierto que se ha conseguido.

Para seleccionar los sensores, se observa los registros EEG de cada sujeto y se desestiman los que tengan más ruido o sean excesivamente planos.




Figura 5-17 Representación de los vectores de características para el sujeto “A-1” y “B-1” para la onda cerebral Beta, correspondientes a los sensores Fp2 y F8. Los círculos verdes corresponden al vector de prueba de “A-2”.

Para la representación de los vectores de los sujetos A-1 y B-1, se han utilizado los sensores Fp2 y F8.

Se observa cómo la potencia del sujeto B-1 se distribuye principalmente por el sensor Fp2 (Eje de abscisas), mientras que para el sujeto A-1 se distribuye por el sensor F8 (Eje de ordenadas).

Son pocos los puntos que de cada sujeto que se encuentran entre los del otro. Esto permite que la SVM sea capaz de clasificar a los dos individuos y obtener una buena tasa de acierto en la identificación del sujeto A-2.

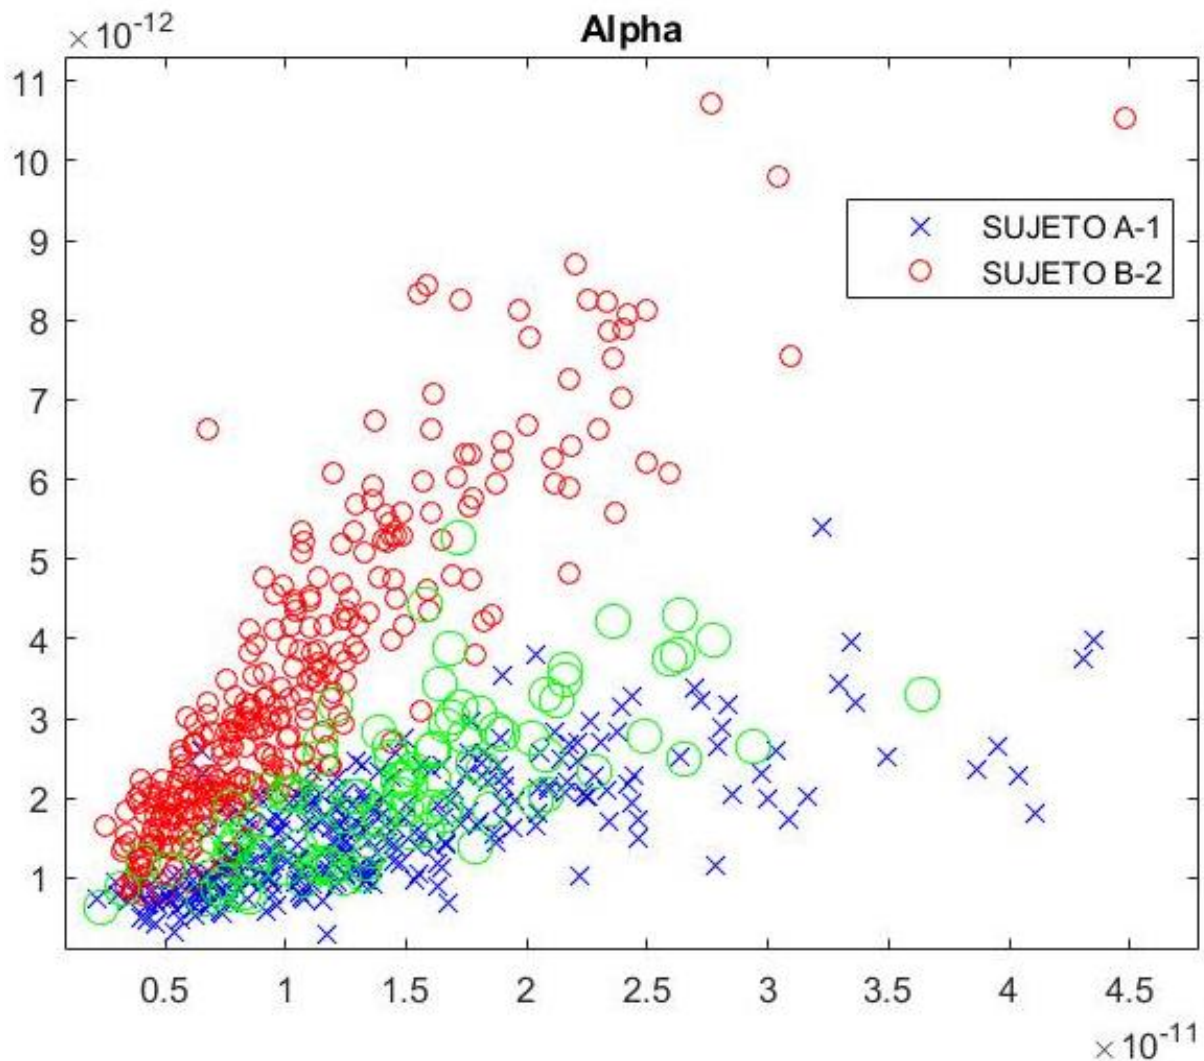


Figura 5-18 Representación de los vectores de características para el sujeto “A-1” y “B-2” para la onda cerebral Alpha, correspondientes a los sensores Fp2 y AF4. Los círculos verdes corresponden al vector de prueba de “A-2”.

Para la representación de de los vectores de los sujetos A-1 y B-2, se han utilizado los sensores Fp2 y AF4.

Se observa de qué manera la potencia del sujeto A-1 se distribuye principalmente por el sensor Fp2 (Eje de abscisas), mientras que para el sujeto B-2 se distribuye por el sensor AF4 (Eje de ordenadas).

Son pocos los puntos que de cada sujeto que se encuentran entre los del otro. Esto permite que la SVM sea capaz de clasificar a los dos individuos y obtener una buena tasa de acierto en la identificación del sujeto A-2.






Figura 5-19 Representación de los vectores de características para el sujeto “A-1” y “C-1” para la onda cerebral Theta, correspondientes a los sensores Fp1 y F7. Los círculos verdes corresponden al vector de prueba de “A-2”.

Para la representación de de los vectores de los sujetos A-1 y C-1, se han utilizado los sensores Fp1 y F7.

Se observa cómo la potencia del sujeto C-1 se distribuye principalmente por el sensor Fp1 (Eje de abscisas), mientras que para el sujeto A-1 se distribuye por el sensor F7 (Eje de ordenadas).

La gran diferencia de distribución de la potencia entre ambos sujetos permite que la SVM sea capaz de clasificar a los dos individuos y obtener una buena tasa de acierto en la identificación del sujeto A-2.

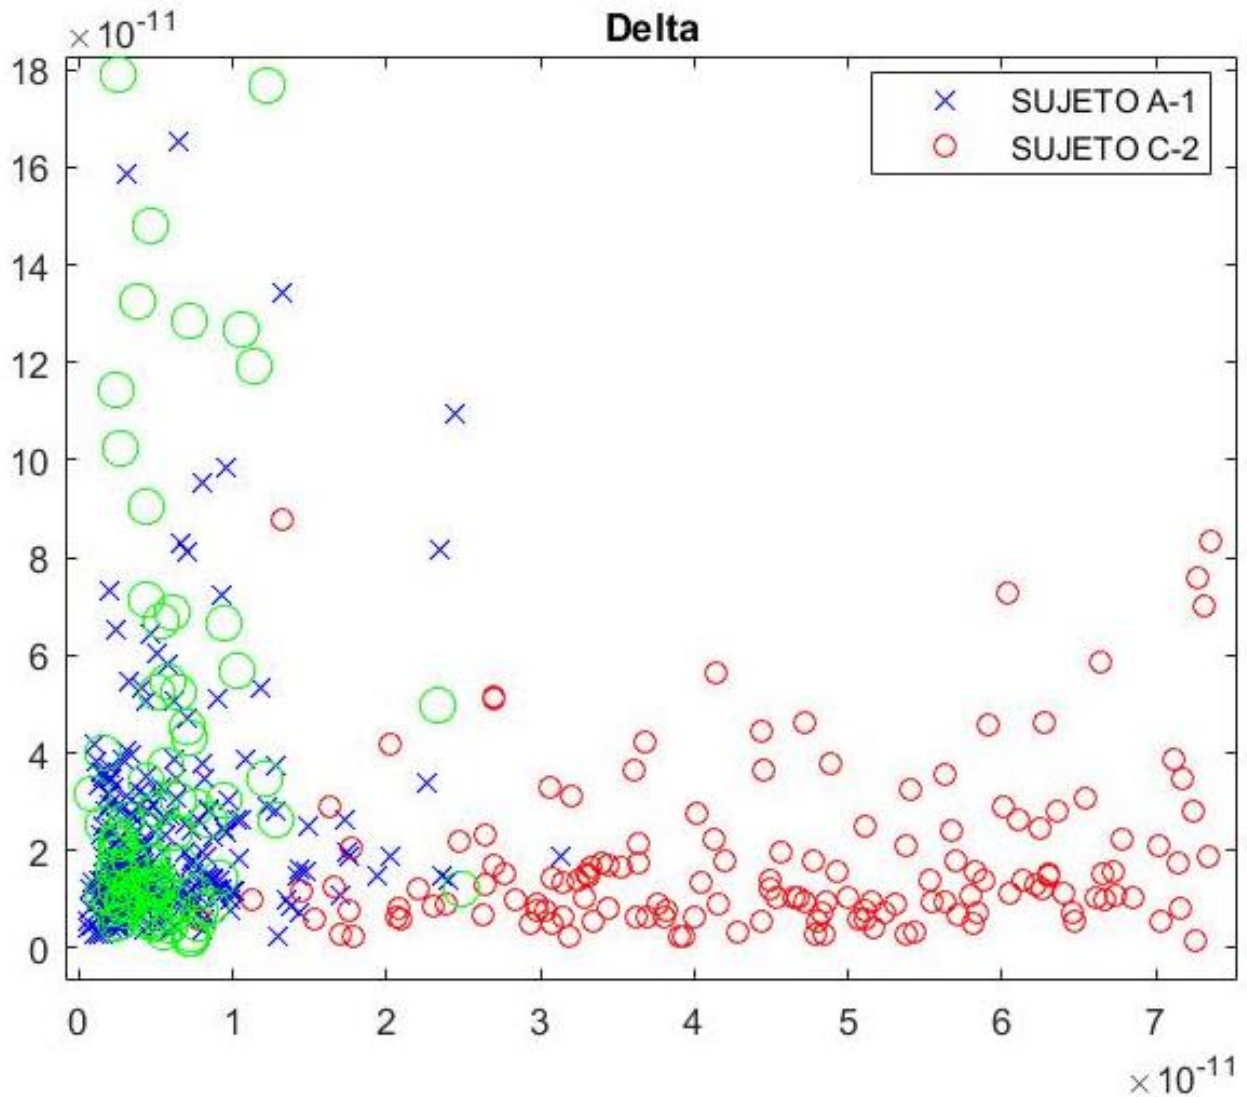


Figura 5-20 Representación de los vectores de características para el sujeto “A-1” y “C-2” para la onda cerebral Delta, correspondientes a los sensores Fp1 y F7. Los círculos verdes corresponden al vector de prueba de “A-2”.

Para la representación de de los vectores de los sujetos A-1 y C-2, se han utilizado los sensores Fp1 y F7.

Se observa de qué manera la potencia del sujeto C-2 se distribuye principalmente por el sensor Fp1 (Eje de abscisas), mientras que para el sujeto B-2 se mantiene bastante uniforme para ambos sensores.

La gran diferencia de distribución de la potencia entre ambos sujetos y los pocos puntos que se solapan entre ambos sujetos, permite que la SVM sea capaz de clasificar a los dos individuos y obtener una buena tasa de acierto en la identificación del sujeto A-2.

### 5.4.2 Sujeto B

Se realizan diferentes pruebas en las que se calculará la tasa de acierto en la identificación del sujeto "B". Se usará como vectores de entrenamiento los correspondientes a "B-1" y los correspondientes a los otros dos individuos. Para realizar la prueba de identificación se utilizarán los vectores de características de "B-2".

| B-1   | A-1 | A-2 | C-1  | C-2 |
|-------|-----|-----|------|-----|
| BETA  | 70% | 99% | 100% | 97% |
| ALPHA | 85% | 85% | 99%  | 96% |
| THETA | 81% | 96% | 99%  | 96% |
| DELTA | 50% | 27% | 76%  | 44% |

Tabla 5-6 Tasas de acierto. Caso 2. Sujeto B.

En las siguientes figuras van a representarse cómo estarían situados los vectores de características para algunos de los casos anteriores. Debido a la alta dimensionalidad de los datos, no es posible hacer una representación total de los mismos. Por tanto, se utilizarán únicamente dos sensores para poder generar las figuras. Se podrá observar una aproximación de la tasa de acierto que se ha conseguido.

Para seleccionar los sensores, se observa los registros EEG de cada sujeto y se desestiman los que tengan mas ruido o sean excesivamente planos.






Figura 5-21 Representación de los vectores de características para el sujeto “B-1” y “A-1” para la onda cerebral Beta, correspondientes a los sensores Fp2 y F8. Los círculos verdes corresponden al vector de prueba de “B-2”.

Para la representación de los vectores de los sujetos B-1 y A-1, se han utilizado los sensores Fp2 y F8.

Se observa de qué manera la potencia del sujeto B-1 es mayor que la de A-1 para el sensor Fp2 (Eje de abscisas), mientras que para el sensor F8 (Eje de ordenadas) la distribución es prácticamente igual.

La diferencia de potencia entre ambos sujetos, para el sensor Fp2, permite que la SVM sea capaz de clasificar a los dos individuos y obtener una buena tasa de acierto en la identificación del sujeto B-2.




Figura 5-22 Representación de los vectores de características para el sujeto “B-1” y “A-2” para la onda cerebral Alpha, correspondientes a los sensores Fp2 y AF4. Los círculos verdes corresponden al vector de prueba de “B-2”.

Para la representación de los vectores de los sujetos B-1 y A-2, se han utilizado los sensores Fp2 y AF4.

Se observa cómo la potencia del sujeto B-1 es igual que la de A-2 para el sensor Fp2 (Eje de abscisas), mientras que para el sensor F8 (Eje de ordenadas) la potencia del sujeto B-1 es ligeramente superior.

La diferencia de potencia entre ambos sujetos, para el sensor AF4, permite que la SVM sea capaz de clasificar a los dos individuos y obtener una buena tasa de acierto en la identificación del sujeto B-2.




Figura 5-23 Representación de los vectores de características para el sujeto “B-1” y “C-1” para la onda cerebral Theta, correspondientes a los sensores Fp1 y F7. Los círculos verdes corresponden al vector de prueba de “B-2”.

Para la representación de de los vectores de los sujetos B-1 y C-1, se han utilizado los sensores Fp1 y F7.

Se observa de qué manera la potencia del sujeto C-1 es mayor que la de B-1 para el sensor Fp2 (Eje de abscisas), mientras que para el sensor F8 (Eje de ordenadas) la distribución es prácticamente igual.

La diferencia de potencia entre ambos sujetos, para el sensor Fp2, permite que la SVM sea capaz de clasificar a los dos individuos y obtener una óptima tasa de acierto en la identificación del sujeto B-2.




Figura 5-24 Representación de los vectores de características para el sujeto “B-1” y “C-2” para la onda cerebral Delta, correspondientes a los sensores Fp1 y Fpz. Los círculos verdes corresponden al vector de prueba de “B-2”.

Para la representación de los vectores de los sujetos B-1 y C-2, se han utilizado los sensores Fp1 y Fpz.

Se observa cómo la potencia del sujeto B-1 es mayor que la de C-2 para el sensor Fpz (Eje de abscisas), mientras que para el sensor Fp1 (Eje de ordenadas) la distribución es prácticamente igual.

La poca diferencia de potencia entre ambos sujetos para esta onda cerebral, en el sensor Fpz, permite que la SVM sea incapaz de clasificar a los dos individuos y obtener una óptima tasa de acierto en la identificación del sujeto B-2.

### 5.4.3 Sujeto C

Se realizan diferentes pruebas en las que se calculará la tasa de acierto en la identificación del sujeto "C". Se usará como vectores de entrenamiento los correspondientes a "C-1" y los correspondientes a los otros dos individuos. Para realizar la prueba de identificación se utilizarán los vectores de características de "C-2".

| C-1   | A-1 | A-2  | B-1 | B-2 |
|-------|-----|------|-----|-----|
| BETA  | 96% | 99%  | 82% | 96% |
| ALPHA | 98% | 94%  | 73% | 77% |
| THETA | 99% | 100% | 98% | 99% |
| DELTA | 93% | 97%  | 77% | 88% |

Tabla 5-7 Tasas de acierto. Caso 2. Sujeto C

En las siguientes figuras van a representarse de qué manera estarían situados los vectores de características para algunos de los casos anteriores. Debido a la alta dimensionalidad de los datos, no es posible hacer una representación total de los mismos. Por tanto, se utilizarán únicamente dos sensores para poder generar las figuras. Se podrá observar una aproximación de la tasa de acierto que se ha conseguido.

Para seleccionar los sensores, se observa los registros EEG de cada sujeto y se desestiman los que tengan mas ruido o sean excesivamente planos.




Figura 5-25 Representación de los vectores de características para el sujeto “C-1” y “A-1” para la onda cerebral Beta, correspondientes a los sensores Fp1 y F7. Los círculos verdes corresponden al vector de prueba de “C-2”.

Para la representación de de los vectores de los sujetos C-1 y A-1, se han utilizado los sensores Fp1 y F7.

Se observa de qué manera la potencia del sujeto C-1 se distribuye principalmente por el sensor Fp1 (Eje de abscisas), mientras que para el sujeto A-1 se distribuye por el sensor F7 (Eje de ordenadas).

La gran diferencia de distribución de la potencia entre ambos sujetos permite que la SVM sea capaz de clasificar a los dos individuos y obtener una buena tasa de acierto en la identificación del sujeto C-2.






Figura 5-26 Representación de los vectores de características para el sujeto “C-1” y “A-2” para la onda cerebral Alpha, correspondientes a los sensores Fp1 y F7. Los círculos verdes corresponden al vector de prueba de “C-2”.

Para la representación de los vectores de los sujetos C-1 y A-2, se han utilizado los sensores Fp1 y F7.

Se observa cómo la potencia del sujeto C-1 se distribuye principalmente por el sensor Fp1 (Eje de abscisas), mientras que para el sujeto A-2 se distribuye por el sensor F7 (Eje de ordenadas).

La gran diferencia de distribución de la potencia entre ambos sujetos permite que la SVM sea capaz de clasificar a los dos individuos y obtener una buena tasa de acierto en la identificación del sujeto C-2.




Figura 5-27 Representación de los vectores de características para el sujeto “C-1” y “B-1” para la onda cerebral Theta, correspondientes a los sensores Fp1 y F7. Los círculos verdes corresponden al vector de prueba de “C-2”.

Para la representación de de los vectores de los sujetos C-1 y B-1, se han utilizado los sensores Fp1 y F7.

Se observa cómo la potencia del sujeto C-1 se distribuye principalmente por el sensor Fp1 (Eje de abscisas), mientras que para el sujeto B-1 se distribuye por el sensor F7 (Eje de ordenadas).

La gran diferencia de distribución de la potencia entre ambos sujetos permite que la SVM sea capaz de clasificar a los dos individuos y obtener una buena tasa de acierto en la identificación del sujeto C-2.






Figura 5-28 Representación de los vectores de características para el sujeto "C-1" y "B-2" para la onda cerebral Delta, correspondientes a los sensores Fp1 y F7. Los círculos verdes corresponden al vector de prueba de "C-2".

Para la representación de de los vectores de los sujetos C-1 y B-1, se han utilizado los sensores Fp1 y F7.

Se observa de qué manera la potencia del sujeto C-1 se distribuye principalmente por el sensor Fp1 (Eje de abscisas), mientras que para el sujeto B-2 se distribuye por el sensor F7 (Eje de ordenadas).

La gran diferencia de distribución de la potencia entre ambos sujetos permite que la SVM sea capaz de clasificar a los dos individuos y obtener una buena tasa de acierto en la identificación del sujeto C-2.



## 6 CONCLUSIÓN

---

En este trabajo se han analizado dos casos para demostrar el potencial del electroencefalograma para su uso en procesos de verificación de identidad e identificación biométrica de personas. En el primero de ellos se han utilizado dos sensores (Fp1 y F7), y en segundo los 62 sensores que componen los registros EEG de la base de datos utilizada.

Para el primer estudio, la elección de estos dos sensores en particular se ha realizado pensando en un caso más práctico. Ambos sensores registran la actividad del lóbulo frontal, y es por ello que el proceso de captación del electroencefalograma se puede realizar de una forma mas simple.

Se puede concluir, para este, que la manera en la que se distribuye la potencia, para unos sensores determinados, establecerá la distancia entre los vectores de características, de dos sujetos distintos. Siendo esta la característica más determinante, para la obtención de altas tasas de acierto.

Esto puede verse reflejado en las tablas de resultados del capítulo anterior, donde se observa que las tasas de acierto son muy altas cuando se utiliza al sujeto C como uno de los vectores de entrenamiento.

En segundo lugar, si la distribución de la potencia no produce una “gran” distancia entre los vectores, el tipo de onda cerebral con la que se genere el vector de características será determinante para la obtención de una tasa de acierto aceptable.

Esto puede verse reflejado en las tablas de resultados del capítulo anterior, donde se observa como juegan un papel fundamental los tipos de onda cerebral, en las tasas de acierto, cuando se trabaja con los sujetos A y B, cuyos vectores de características se encuentran mas próximos.

Para el segundo estudio, el uso de todos los sensores produce unas tasas de acierto, en general, más altas. En este, el tipo de onda cerebral deja de tener un papel importante en los resultados. Siendo la gran cantidad de datos introducidos, y las diferencias en la distribución de la potencia que tienen los EEGs de distintas personas, los factores más determinantes.

Debido a que el estudio ha sido realizado para una pequeña cantidad de sujetos, las tasas de acierto y los resultados obtenidos no serán concluyentes. Pero sí demuestran el potencial del electroencefalograma para establecer la identidad de una persona.



# REFERENCIAS

---

- [1] Brainstorm. <http://neuroimage.usc.edu/brainstorm/Introduction>.
- [2] Rafael Barea Navarro, «Instrumentación Biomédica», Departamento Electrónica, Universidad Alcalá.
- [3] Gray; Richard L. Drake, A. Wayne Vogl, Adam W. M. Mitchell. «Anatomía para estudiantes». Elsevier España, cop. 2015
- [4] Manuel Jose Ríos Aguaded. «Análisis espectral multivariable aplicado a señales cerebrales reales (EEG)». Proyecto Fin de Carrera Univ. Sevilla, 2005
- [5] Lorenzo Santos Mayo, «Desarrollo y evaluación de clasificadores neuro-genéticos basados en señales de EEG para la ayuda al diagnóstico de la esquizofrenia», 2015.
- [6] José Luis Martínez Pérez, «Comunicación con computador mediante señales cerebrales. Aplicación a la tecnología de la rehabilitación». Tesis Doctoral, 2009

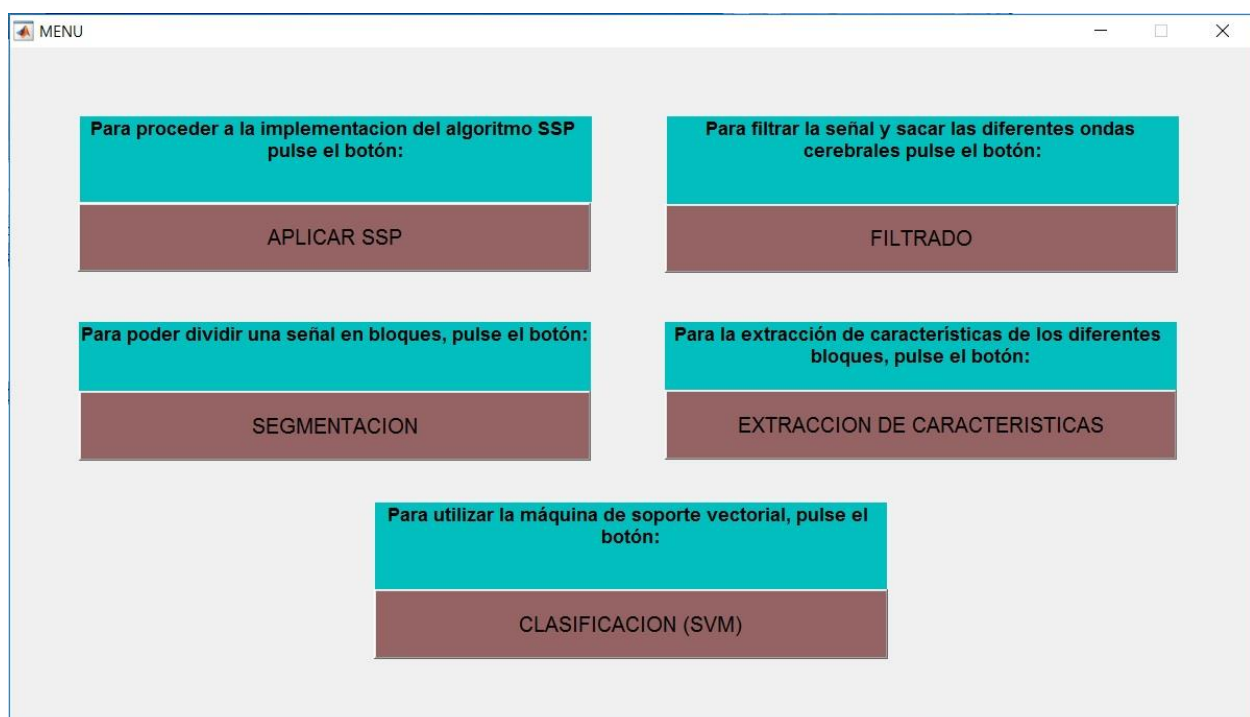


# ANEXOS

En este capítulo se añadirán los códigos utilizados para la realización del pre-procesado y el uso de la máquina de soporte vectorial (SVM), que no han sido incluidos en capítulos anteriores para agilizar la lectura.

Se ha desarrollado una interfaz para que el usuario pueda realizar todos los procesos de una forma mas cómoda y ágil. Se ha creado mediante una utilidad disponible en Matlab para el desarrollo de interfaces de usuario (GUI) llamada GUIDE.

El usuario abrirá un menú donde se encuentran todas las funciones para el pre-procesado de las señales EEG.



1. **APLICAR SSP:** En esta opción utilizaremos el programa Brainstorm para analizar ficheros “.eeg” de la base de datos. Primero detectaremos los Blinks y se aplicará el algoritmo SSP para limpiar las señales de artefactos indeseados.

El código mostrado a continuación, utiliza las funciones de Brainstorm para realizar el proceso:

```

%Script parar detectar "blinks" y posteriormente aplicar el
algoritmo SSP.

% Cargamos el fichero al que queremos aplicar SSP.
nombre= load('nombre_ICA.mat');
nombre=char(nombre.nombre);
ruta_programa = load('ruta_brains.mat');
ruta_programa = char(ruta_programa.ruta_brainstorm);
ruta_programa=strcat(ruta_programa,'\');
ruta_fichero =
strcat(ruta_programa,'brainstorm_db\TFG\data\NewSubject\@raw');
fichero = strcat(ruta_fichero,nombre);
F=ls(fichero);
fichero=strcat(fichero,'\');
fichero =strcat(fichero,F(5,:));

% Input files
sFiles = {fichero};

% Start a new report
bst_report('Start', sFiles);

% Process: Detect: blink
sFiles = bst_process('CallProcess', 'process_evt_detect', sFiles,
[], ...
    'eventname',    'blink', ...
    'channelname',  'Veog+', ...
    'timewindow',   [], ...
    'bandpass',     [1.5, 15], ...
    'threshold',    6, ...
    'blanking',     0.1, ...
    'isnoisecheck', 1, ...
    'isclassify',   0);

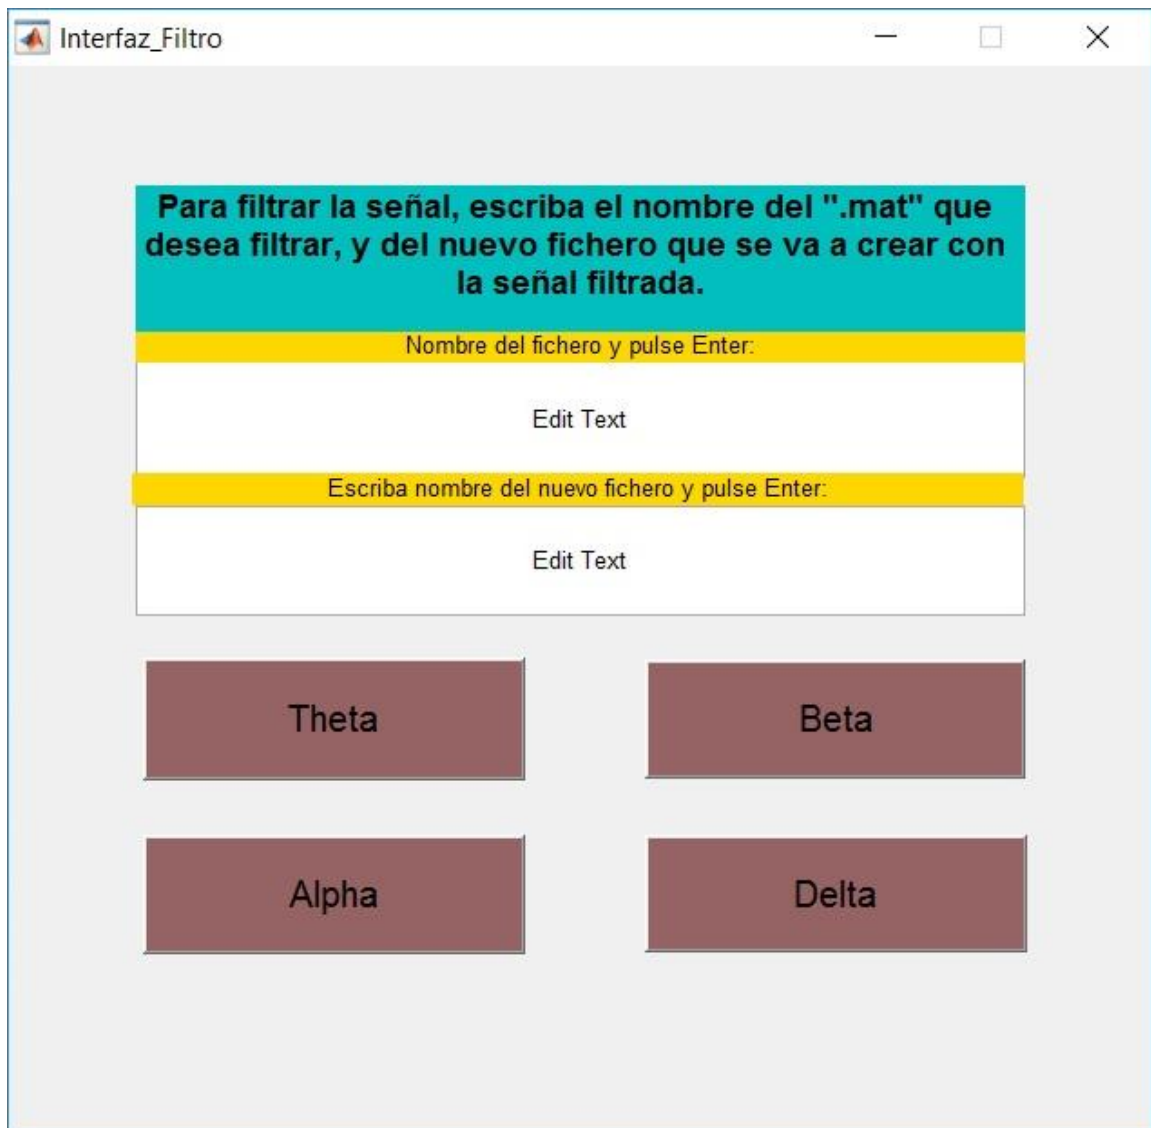
% Process: SSP EOG: blink
sFiles = bst_process('CallProcess', 'process_ssp_eog', sFiles, [],
...
    'eventname',    'blink', ...
    'sensortypes',  'EEG', ...
    'usessp',       1, ...
    'select',       1);

% Save and display report
ReportFile = bst_report('Save', sFiles);
bst_report('Open', ReportFile);
% bst_report('Export', ReportFile, ExportDir);

```

- FILTRADO:** En esta opción utilizaremos MATLAB para generar cuatro filtros paso de banda, uno para cada tipo de onda cerebral. A continuación, se procederá al filtrado de las diferentes señales EEG.





Se muestra, a continuación, el código de una de las funciones para el filtrado de las señales:

```
%Creamos un filtro para obtener la onda cerebral "alpha".
d1 = designfilt('bandpassiir','FilterOrder',4, ...
'HalfPowerFrequency1',8,'HalfPowerFrequency2',13.99, ...
'SampleRate',500);

%Cargamos la ruta y el nombre de la señal que queremos filtrar.
nombre= load('nombre_freq.mat');
nombre=char(nombre.nombre);
ruta_programa = load('ruta_prog.mat');
ruta_programa = char(ruta_programa.ruta_programa);
ruta_fichero =
strcat(ruta_programa, '\PROGRAMA\datos\eeg_original\');
fichero=strcat(ruta_fichero,nombre);
fichero=load(fichero);
data=fichero.data;

%Filtramos la señal para cada sensor.
dim=size(data);
for i=1:1:dim(1)

    data(i,:) = filtfilt(d1,data(i,:));

end

%Tras haber analizado el transitorio del filtro, eliminamos las
muestras de la señal que están alteradas por este.
data(:, [1:450])=[];
dim=size(data);
data(:, [(dim(2)-449):dim(2)])=[];

%Cargamos el nombre y la ruta, que queremos ponerle, de nuestro
fichero con la señal ya filtrada.
nombre= load('nombre.mat');
nombre=char(nombre.nombre);
ruta_programa = load('ruta_prog.mat');
ruta_programa = char(ruta_programa.ruta_programa);
ruta_fichero = strcat(ruta_programa, '\PROGRAMA\datos\eeg_alfa\');
ruta_nueva=strcat(ruta_fichero,nombre);

%Guardamos el fichero en la ruta elegida.
save(ruta_nueva, 'data')
```

- 3. SEGMENTACIÓN:** Se procede a la segmentación de las señales EEG ya filtradas, para posteriormente realizar la extracción de características de cada uno de los bloques en los que se ha dividido. Se utiliza MATLAB para el desarrollo de una función que nos permite realizar este proceso.

The screenshot shows a MATLAB GUI window titled "Interfaz\_Separar". At the top, there is a cyan instruction box with the following text:

- 1º) Para poder dividir una señal en bloques. Escribimos el tiempo que queremos que dure cada bloque (N) y el tiempo de solapamiento entre bloques (L).
- 2º) Elegimos la ruta de alguna de las señales exportadas anteriormente.
- 3º) Escribimos el nombre del fichero que vamos a dividir.
- 4º) Escribimos el nombre del nuevo fichero que vamos a crear.

Below the instructions, the GUI contains several input fields and a button:

- Two side-by-side input fields labeled "N(seg)" and "L(seg)", each containing the text "Edit Text".
- A label "Ruta del fichero y pulse Enter:" followed by an "Edit Text" field.
- A label "Nombre del fichero a dividir y pulse Enter:" followed by an "Edit Text" field.
- A label "Nombre del fichero dividido y pulse Enter:" followed by an "Edit Text" field.
- A large brown button at the bottom labeled "Separar Bloques".

```

function [Matriz_bloques] = Separar_bloques(t,l,datos)
% t = tiempo que queremos que ocupe cada bloque.
% l = tiempo de solapamiento entre bloques.

N = t*500; %Cada segundo equivale a 500 muestras.
L = l*500;

dim_datos = size(datos); %Metemos en una variable las dimensiones
                          de la matriz
a=1;                      %Contador de bloques

    for i=1:1:dim_datos(1) %filas de la matriz (numero de sensores)

        if a==1           %Solo se aplicará
                           para el primer bloque de cada fila(sensor)
            for j=1:1:N+1  %El tamaño del
                           bloque será igual a N
                Matriz_bloques(i,a,j)=datos(i,j); %Copiamos el valor
                                                    en la nueva Matriz.
            end
        end

        a=a+1;
        %Generamos "(n° de muestras-L)/(N-L)" columnas(bloques).
        while a>1 && a<=(round((dim_datos(2)-L)/(N-L)))
            %Utilizamos la variable b para desplazarnos por ambas matrices.
            for b=((a-1)*(N-L))+1:1:(((a-1)*(N-L))+N)+1
                %Cuando la variable b supere el numero de muestras de la matriz,
                dejará de copiar.
                if b <= dim_datos(2)
                    %Formamos la matriz de bloques.
                    Matriz_bloques(i,a,(b-(a-1)*(N-L)))=datos(i,b);
                end
            end
            a=a+1;
        end
    end
    a=1;
end
end

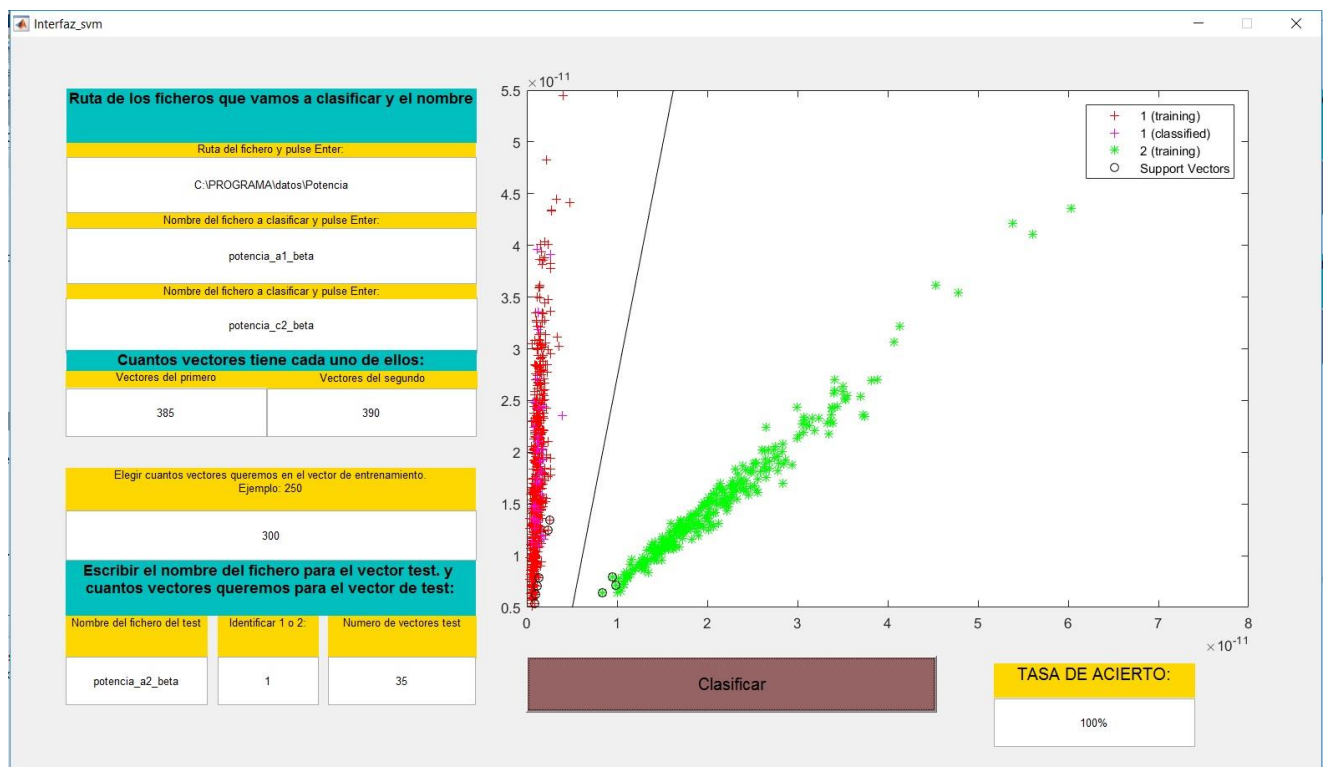
```

4. **EXTRACCIÓN DE CARACTERÍSTICAS:** Se determina la potencia de cada bloque, con lo que obtendremos el vector de características que necesitamos para introducirlo en la máquina de soporte vectorial.

```
function [potencia] = parametros(matriz)

dim_matriz = size(matriz);
%POTENCIA
for i=1:1:dim_matriz(1)
    for j=1:1:dim_matriz(2)
        potencia(i,j) = sum((matriz(i,j,:)).^2)/dim_matriz(3);
    end
end
end
```

5. **CLASIFICACIÓN (SVM):** Usaremos la interfaz creada para elegir los vectores que vamos a utilizar para la clasificación. En la ventana se representará la frontera generada por la SVM, así como los puntos correspondientes a los vectores de entrenamiento y test.



El código para la utilización de la maquina de soporte vectorial es:

```
%Cargamos los vectores de características del primer sujeto
nombre= load('nombre_svm.mat');
nombre=char(nombre.nombre);
ruta=load('ruta_svm.mat');
ruta=char(ruta.ruta);
ruta=strcat(ruta, '\');
fichero=strcat(ruta, nombre);
fichero=load(fichero);
vector1=fichero.potencia;

N=load('vectores1_svm.mat');
N=str2double(N.vectores1);

vector1=vector1';
vector1((N+1):end,:)=[];
vector1(:,3:end)=[];
training_label_vector=[vector1];

%Cargamos los vectores de características del segundo sujeto
nombre= load('nombre_svm_2.mat');
nombre=char(nombre.nombre);
ruta=load('ruta_svm.mat');
ruta=char(ruta.ruta);
ruta=strcat(ruta, '\');
fichero=strcat(ruta, nombre);
fichero=load(fichero);
vector2=fichero.potencia;

vector2=vector2';
vector2((N+1):end,:)=[];
vector2(:,3:end)=[];
training_label_vector=[training_label_vector;vector2];
%Cargamos los vectores de características del primer sujeto
(EEG-2)
nombre= load('nombre_svm_test.mat');
nombre=char(nombre.nombre);
ruta=load('ruta_svm.mat');
ruta=char(ruta.ruta);
ruta=strcat(ruta, '\');
fichero=strcat(ruta, nombre);
fichero=load(fichero);
vector3=fichero.potencia;
```

```
N2=load('vectores3_svm.mat');
N2=str2double(N2.vectores3);

vector3=vector3';
vector3(1:300,:)=[];
a=size(vector3,1);
vector3(1:(a-N2),:)=[];
vector3(:,3:end)=[];
test_vector=[vector3];

%Generamos el vector de clases.
dim=size(training_label_vector);
training_instance_matrix=cell(dim(1),1);
training_instance_matrix(1:(N),1)={'1'};
training_instance_matrix((N+1):(2*N),1)={'2'};

%Generación del modelo y la clasificación del vector de prueba
model=svmtrain(training_label_vector,
training_instance_matrix,'ShowPlot', true);
resultado=svmclassify(model,test_vector,'ShowPlot', true);

ident=load('ident_svm.mat');
ident=ident.ident;
cont=0;
for i=1:N2
    if cell2mat(resultado(i,:)) == cell2mat(ident)
        cont=cont+1;
    end
end

cont=(cont/N2)*100;

%Guardamos la tasa de acierto en un fichero.
cont=int2str(cont);
cont=strcat(cont,'%');
nombre='accuracy.mat';
ruta_programa = load('ruta_prog.mat');
ruta_programa = char(ruta_programa.ruta_programa);
ruta_fichero =
strcat(ruta_programa,'\\PROGRAMA\\herramientas\\');
ruta = strcat(ruta_fichero,nombre);

save(ruta,'cont')
```