



Universidad Zaragoza



Escuela de  
Ingeniería y Arquitectura  
Universidad Zaragoza

Proyecto Fin de Carrera  
Ingeniería en Informática

# CLASIFICACIÓN DE LOS ESTADOS DE REPOSO, PREPARACIÓN Y EJECUCIÓN DEL MOVIMIENTO DEL BRAZO A TRAVÉS DEL ELECTROENCEFALOGRAMA

*Autor:* Miguel Rodrigo Gómez

*Directores:* Luis Montesano del Campo  
Javier Mínguez Zafra



Departamento de Informática  
e Ingeniería de Sistemas

Zaragoza, Septiembre 2011



# Agradecimientos

En primer lugar, me gustaría agradecer a mi director del proyecto, Luis Montesano, y mi codirector, Javier Mínguez, por todo su esfuerzo, dedicación, paciencia y por lo muchísimo que he aprendido a lo largo de todo el tiempo dedicado al proyecto, además por haberme dado la oportunidad de participar en la elaboración de un artículo para la comunidad científica.

En segundo lugar, dar las gracias a todos los trabajadores de la empresa *BitBrain*: María, Soraya, Mónica, Isabel, Escolano, Dani, Marco, Edu y Sergio, por todo el *feedback* proporcionado, así como por esos grandes momentos en su compañía, que dieron lugar a grandes ideas para este proyecto. Y al Grupo de Robótica de la universidad de Zaragoza por los datos suministrados, en especial a Mauricio, por el tiempo dedicado a enseñarme el trabajo realizado.

A todos los viejos amigos de Cáceres, en especial David Rivas, por haberme hecho la persona que soy ahora, ya que sin su apoyo y su amistad no habría llegado al final del camino. A los nuevos amigos de Zaragoza, los cuáles han hecho que mi estancia aquí me permitiera seguir adelante y dar lo mejor de mí mismo.

A todas las personas que de una manera u otra, han estado a mi lado y que me haya podido olvidar de ellas: lo siento, mi memoria ya no es lo que era.

A mi familia, por no haber perdido la fe y haber apostado por mí, contra viento y marea.

Y, por último, a Jara González Íñigo, cambió mi vida: le dio un significado mayor del que ya tenía y me hizo coger el impulso necesario para afrontar cualquier reto del camino, sabiendo que lo afrontaremos juntos.



# Resumen

Un interés creciente ha aparecido, en los últimos años, en torno al uso de *"interfaces cerebro computador"* aplicadas a terapias de rehabilitación, para ayudar a personas con discapacidad motora a mover sus miembros. Una de las aplicaciones más importantes dentro de este contexto, es la de detectar las intenciones del paciente y, gracias a ellas, ajustar mejor las terapias de rehabilitación, así como, un control más preciso de prótesis robóticas.

El objetivo del proyecto será detectar los estados de reposo, preparación o anticipación y ejecución del movimiento del brazo, utilizando la señal de electroencefalograma obtenida durante el proceso. Para ello, a partir de la señal original, estudiaremos cómo distintos filtros espaciales lineales, filtros frecuenciales, rectificado y suavizado de la señal, actúan en la mejora de la separabilidad de las tres clases. Con las mejores características seleccionadas, trataremos de detectar, por un lado, los estados por parejas: reposo y preparación, reposo y movimiento y preparación y movimiento, y, por otro lado, las tres clases de manera simultánea, para lo cuál entrenaremos dos clasificadores lineales: *"lineal discriminant analysis"*, *LDA*, y *"shrinkage"*.

Los resultados de la clasificación, en el caso de detectar los estados en parejas, fueron cercanos al 65 % de datos bien clasificados, alcanzando en algunos sujetos una cota cercana al 75 %. En el caso de la clasificación de los tres estados simultáneamente conseguimos una tasa de aciertos en torno al 55 % de promedio, obteniendo en algunos casos valores por encima del 60 %.

Como conclusión, hay que destacar que el procesado de la señal para seleccionar las características que mejoren la separabilidad de las clases, da unos resultados aceptables, puesto que éste es un campo de investigación reciente y en el cuál se está investigando mucho en la actualidad. La mejora de las técnicas de selección de características permitirá en el futuro, desarrollar unas terapias de rehabilitación que se ajusten de manera personal a cada paciente, además logrará que la integración de prótesis robóticas a la persona sea más íntima y eficaz de lo que es en la actualidad.

---

# Índice general

<b>1. Introducción</b>	<b>13</b>
1.1. Contexto . . . . .	13
1.2. Estado del Arte . . . . .	14
1.3. Objetivos . . . . .	14
1.4. Organización de la memoria . . . . .	16
1.5. Herramienta . . . . .	17
<b>2. Protocolo de Experimentación</b>	<b>19</b>
2.1. Introducción . . . . .	19
2.2. Descripción del experimento . . . . .	19
2.3. Obtención de los datos de EEG . . . . .	21
<b>3. Procesado de la señal</b>	<b>25</b>
3.1. Introducción . . . . .	25
3.2. Filtros espaciales lineales . . . . .	26
3.2.1. Descripción . . . . .	26
3.2.2. CAR . . . . .	27
3.2.3. Filtros Bipolares . . . . .	27
3.2.4. Filtros Laplacianos . . . . .	27
3.2.5. Selección del filtro . . . . .	28
3.3. Selección de Filtros y Canales . . . . .	31
3.4. Rectificado y Suavizado . . . . .	33
3.5. Señal seleccionada . . . . .	34
<b>4. Clasificación</b>	<b>37</b>
4.1. Introducción . . . . .	37
4.2. Metodología . . . . .	37
4.2.1. Validación cruzada de los datos . . . . .	37
4.2.2. Análisis de las Componentes Principales (PCA) . . . . .	38

---

4.2.3. Normalización . . . . .	39
4.2.4. Clasificadores . . . . .	39
<b>5. Resultados</b>	<b>41</b>
5.1. Parejas de clases independientes . . . . .	41
5.1.1. Shrinkage . . . . .	41
5.1.2. LDA . . . . .	42
5.1.3. Interpretación de los resultados . . . . .	42
5.2. Resultados de las tres clases simultáneamente . . . . .	43
5.2.1. Shrinkage . . . . .	43
5.2.2. LDA . . . . .	43
5.2.3. Interpretación de los resultados . . . . .	44
<b>6. Fases del proyecto</b>	<b>45</b>
6.1. Descripción de las fases . . . . .	45
6.2. Diagrama de Gantt . . . . .	47
<b>7. Cierre del proyecto</b>	<b>49</b>
7.1. Conclusiones . . . . .	49
7.2. Trabajo futuro . . . . .	50

# Índice de figuras

1.1. Desarrollo del proyecto . . . . .	16
2.1. Descripción del experimento . . . . .	20
2.2. Trayectorias ejecutadas por los usuarios . . . . .	20
2.3. Disposición de los electrodos en la cabeza . . . . .	21
2.4. Segmentación de los canales . . . . .	23
3.1. estimador $r^2$ para el Sujeto 1 con los datos raw . . . . .	29
3.2. estimador $r^2$ para el Sujeto 1 con filtro bipolar FC1 para Reposo - Preparación y Reposo - Movimiento y filtro bipolar P3 para Preparación - Movimiento . . . . .	30
3.3. Estimador $r^2$ para todos los canales del sujeto 4 . . . . .	30
3.4. Tipos de señales en el dominio del tiempo para el sujeto 1, de arriba abajo: filtrado espacial, frecuencial, rectificado, suavizado . . . . .	34
6.1. Diagrama de Gantt con las fases del proyecto . . . . .	47



# Índice de cuadros

2.1. Número de repeticiones o "trials" por cada sujeto . . . . .	20
3.1. Filtros seleccionados para cada Sujeto . . . . .	31
3.2. Tipo de filtro <i>butterworth</i> para cada sujeto . . . . .	32
3.3. Canales seleccionados para cada sujeto . . . . .	33
3.4. Señal seleccionada para cada sujeto . . . . .	35
5.1. Porcentaje de aciertos por parejas usando " <i>shrinkage</i> " . . . . .	41
5.2. Porcentaje de aciertos por parejas usando LDA . . . . .	42
5.3. Promedio de clasificación para los tres estados usando " <i>shrinkage</i> " . . . . .	43
5.4. Promedio de clasificación para los tres estados usando LDA . . . . .	43



# Capítulo 1

## Introducción

### 1.1. Contexto

Las "interfaces cerebro-computador" o "brain-computer interfaces", *BCI*, son comunicaciones entre un dispositivo tecnológico y el cerebro, mediante la captura de las señales eléctricas generadas por el cerebro. Existen dos tipos, según el método de obtención de la señal: *métodos invasivos*, son aquellos en los que la señal se consigue mediante unos electrodos situados dentro del cráneo, y *métodos no invasivos*, son los que tienen los electrodos están colocados fuera del cráneo. Dentro de éstos últimos hay que destacar el electroencefalograma, *EEG*, los electrodos están situados a lo largo del cuero cabelludo.

Los *BCI* tienen unas grandes expectativas de futuro, en gran medida por su uso en terapias de rehabilitación en pacientes que sufrieron infartos cerebrales, ya que permitirá obtener una información precisa de los procesos mentales relacionados con el movimiento, y ayudará a complementar la información de la que dispone el terapeuta o automatizar el proceso. Además, se ha sugerido que los *BCI* pueden desempeñar un papel clave en la intención del movimiento, percepción de *feedback* y en la atención [1].

Una de las apuestas más prometedoras de los *BCI*, y del *EEG* en particular, es la posibilidad de detección y clasificación de los distintos estados que existen en la realización del movimiento: el estado de *reposo*, el estado de *preparación* o *anticipación* surge en el momento en el que una persona decide que va a ejecutar un movimiento y abarca hasta el momento en el que inicia el movimiento en sí; por último, el estado de ejecución del movimiento o *movimiento* en sí. La detección de estos tres estados servirá para desarrollar terapias de rehabilitación personalizadas y para el control de prótesis robóticas en pacientes que han sufrido accidentes cerebro-vasculares. Hay que tener en cuenta que el estado de preparación sólo puede ser identificado a través de la actividad cerebral, puesto

que no presenta ninguna manifestación física externa.

El Grupo de Robótica de la Universidad de Zaragoza y la empresa *BitBrain Technologies*, "spin-off" de la misma institución, llevan a cabo en la actualidad investigaciones de *BCI* aplicados a la detección de los tres estados anteriores, con el fin de desarrollar terapias de rehabilitación más eficaces. Este proyecto se efectuó con la colaboración de ambas instituciones. Actualmente la empresa se encuentra involucrada en el desarrollo del proyecto europeo "CORBYS" ("*Cognitive Control Framework for Robotic Systems*"), el cual está centrado en la relación simbiótica entre el ser humano y prótesis robóticas.

## 1.2. Estado del Arte

Las investigaciones actuales tratan de distinguir entre reposo y preparación o entre reposo y movimiento, pero todavía no existe ningún trabajo que trate de detectar los tres estados a la vez. Durante la realización del movimiento se produce una desincronización asociada al evento, "*event-related desynchronization*" o *ERD* en la zona motora [2], así como una baja actividad cortical ("*motor-related potential*") [3]. Esta sincronización o desincronización es la característica clave empleada para diferenciar entre reposo y ejecución del movimiento [4]. Diversos trabajos demuestran que aparece actividad cerebral previa al movimiento en el *EEG* y que estas señales son distintas a las que se producen en el movimiento en sí. Algunos estudios están focalizados en detectar preparación y ejecución del movimiento entre los distintos hemisferios [5], [6], [7], [8].

## 1.3. Objetivos

El objetivo de este proyecto será detectar los estados de reposo, preparación y ejecución del movimiento del brazo utilizando la señal capturada con el *EEG*, la cual se obtuvo mediante un experimento en el que un sujeto debía mover su brazo hasta una posición dada y luego devolverlo hasta la posición inicial. Para la detección se llevará a cabo un estudio de las características de la señal, discriminando cuáles servirán para mejorar la separabilidad entre las clases. Se buscará distinguir entre parejas de estados: *reposo - preparación*, *reposo - movimiento* y *preparación - movimiento*, pero además, se tratará de detectar los tres estados de manera simultánea, hecho que diferencia este proyecto de los trabajos realizados hasta la fecha. Para cumplir con el objetivo principal será necesario conseguir los siguientes subobjetivos:

- **Documentación:** estudiará el estado de arte en materia de revelar las distintas fases del movimiento.
- **Procesado de la señal:** tratará de discernir cómo hay que procesar las características de la señal para mejorarlas e incrementar la separabilidad de los tres estados. Para ello, estudiaremos el efecto de aplicar distintos filtros espaciales, filtros frecuenciales, rectificado de la señal y, por último, el suavizado. Seremos capaces de elegir las mejores características con todo el estudio de la señal.
- **Clasificación:** Este subobjetivo consistirá en detectar los tres estados de la señal, a partir de las características seleccionadas en el procesado de los datos. Para ello se implementarán dos clasificadores lineales: "*linear discriminant analysis*" o LDA y "shrinkage". Los clasificadores realizarán dos tipos de pruebas: las tres clases simultáneas y con parejas de datos.
- **Resultados:** estudio de los valores obtenidos en la clasificación de los datos. Para ello, analizará los efectos de entrenar un clasificador lineal por cada pareja de estados: *reposo - preparación*, *reposo - movimiento* y *preparación - movimiento*, así como el entrenamiento de un único clasificador lineal dedicado a distinguir los tres estados de manera simultánea.

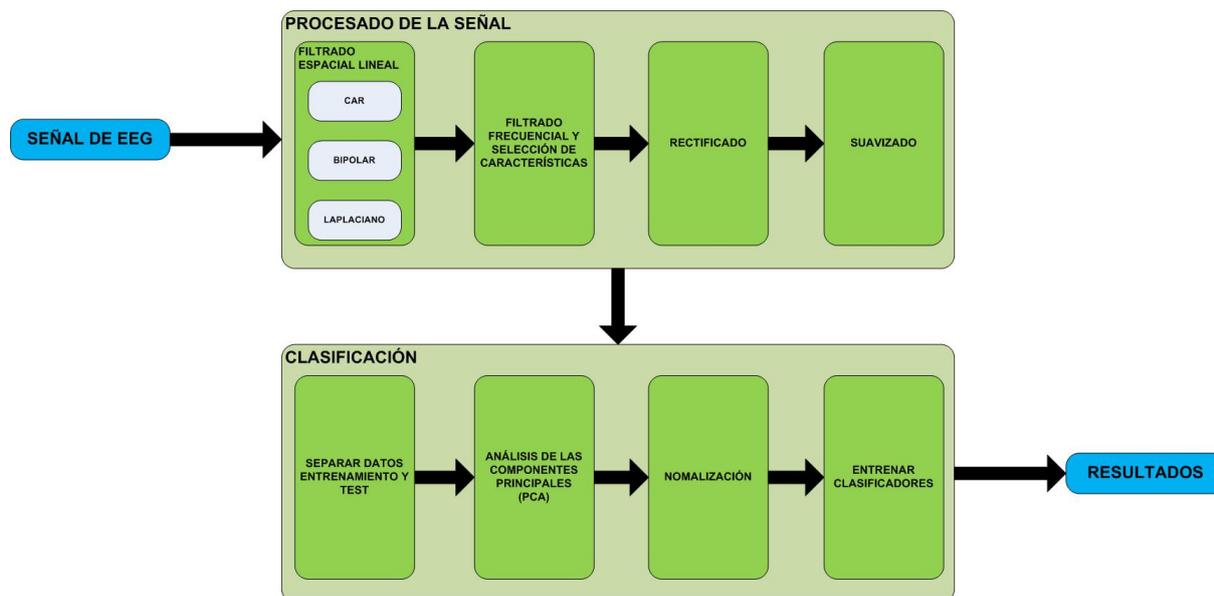


Figura 1.1: Desarrollo del proyecto

## 1.4. Organización de la memoria

La presente memoria está estructurada en una serie de capítulos de manera que abarquen todo el proceso seguido durante la realización del proyecto. Debido a la imposibilidad de plasmar todos los aspectos técnicos en los distintos capítulos, se harán diferentes referencias a la bibliografía utilizada, así como una serie de anexos que amplíen la información de los capítulos.

El primer capítulo expone el contexto en el que se realizó el proyecto, además de una descripción del estado del arte y la herramienta utilizada para codificar los programas. El segundo capítulo describe el protocolo del experimento para obtener los datos del *EEG*. El tercero describe el procesamiento de la señal para la mejora de sus características: uso de filtros espaciales, frecuenciales, rectificado y suavizado de la señal, y cuál fue la selección de características para cada sujeto. El cuarto capítulo trata sobre el proceso de clasificación: reducción de la dimensionalidad de la señal, normalización y entrenamiento de los clasificadores. El quinto expone los resultados que se obtuvieron, tanto clasificando en parejas de estados, como utilizando la señal con las tres clases a la vez. El sexto enumera las fases seguidas para la realización del trabajo, mostrándolo además de manera gráfica con el diagrama de Gantt utilizado. Por último, el séptimo capítulo muestra las conclusiones a las que se han llegado, así como las líneas de trabajo futuro en el campo de la investigación sobre el reconocimiento de los tres estados.

Debido a la densidad del trabajo fue necesario incluir una serie de anexos: el primer anexo describirá el estimador  $r^2$  o *coeficiente de determinación* más al detalle. En el segundo anexo analizaremos en profundidad los aspectos teóricos de los clasificadores lineales utilizados. En el siguiente anexo, expondremos todos los resultados obtenidos en el caso de la clasificación simultánea de los tres estados. Mostraremos en el cuarto anexo cuáles han sido los programas desarrollados y, por último, en el quinto adjuntamos el artículo científico que se envió y se aprobó para la trigésimo tercera conferencia anual de ingeniería en medicina y biología (IEEE EMBC) con toda la investigación realizada en este proyecto, así como los resultados y conclusiones obtenidas.

## 1.5. Herramienta

Seleccionamos el lenguaje de programación Matlab para codificar todo el procesado de la señal y los clasificadores, porque es el lenguaje que se está utilizando en la empresa *BitBrain Technologies* para desarrollar el proyecto *CORBYS*. La versión elegida fue, en un primer momento, la revisión *r2010a*, cuando apareció la nueva actualización se substituyó por ésta.



# Capítulo 2

## Protocolo de Experimentación

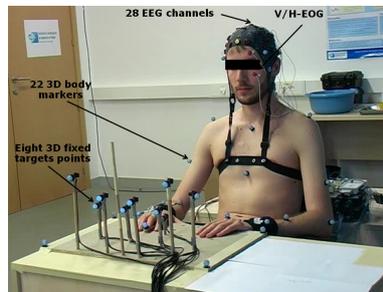
### 2.1. Introducción

Este capítulo describe el experimento realizado por el Grupo de Robótica de la Universidad de Zaragoza, para la captura de la señal de *EEG* producida por el movimiento del brazo. Con los datos de la señal, se pretende detectar los tres estados asociados al movimiento: el sujeto se encuentra en reposo, el sujeto se prepara para desplazar el brazo y el sujeto inicia la trayectoria.

### 2.2. Descripción del experimento

El objetivo del experimento es grabar el *EEG*, en el proceso de mover el brazo derecho, y, con estos datos, decodificar los estados de reposo, preparación y ejecución asociados al movimiento. Para ello, seis sujetos fueron sentados en una cómoda silla frente del instrumental de investigación, ver **Figura 2.1**, y se les pidió que movieran el brazo derecho desde la posición de reposo hasta una de las ocho localizaciones posibles. Una vez que hubieran tocado la posición deseada deberían volver a mover el brazo hasta la localización origen. Este proceso lo iniciaba la persona voluntariamente cada 7'5 segundos aproximadamente de media(habiéndose registrado un mínimo de 2'8 y un máximo de 9,7 segundos). Mientras que el sujeto estaba realizando el desplazamiento al lugar elegido, se le instaba a que no parpadee o que lo haga lo menos posible, sugiriéndole que mirase fijamente a un punto. Entre repetición y repetición, podían parpadear todo lo que quisieran. Todo el proceso se repitió a lo largo de cinco bloques de cinco minutos cada uno, durante los cuales cada uno de los usuarios hizo un número diferente de repeticiones o "*trials*", como se puede ver en la **Tabla 2.1**. Durante el tiempo que duraba cada repetición, se iba registrando una señal de sincronización que nos cuándo es el instante en el que se comenzó a ejecutar el movimiento. Además de la obtención de la señal de *EEG*, se grababan las diversas trayectorias

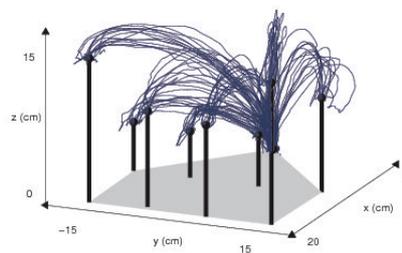
que realizaba el sujeto para ser utilizados en la decodificación de las trayectorias a partir del *EEG* para otros proyectos, ver **Figura 2.2**



**Figura 2.1:** Descripción del experimento

SUJETO	REPETICIONES
1	196
2	98
3	157
4	75
5	135
6	130

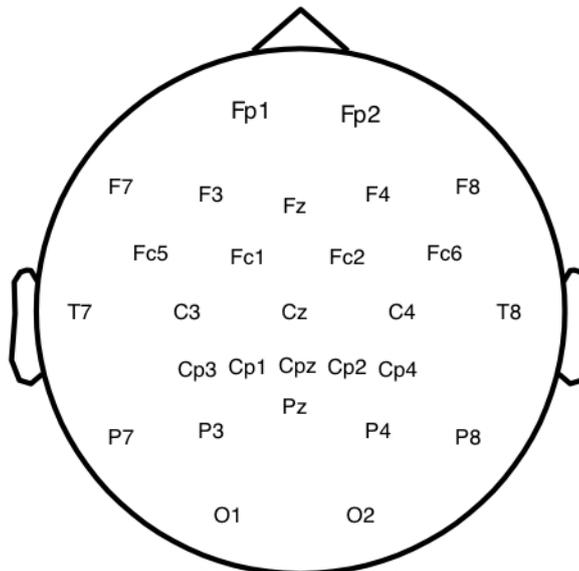
**Tabla 2.1:** Número de repeticiones o "trials" por cada sujeto



**Figura 2.2:** Trayectorias ejecutadas por los usuarios

### 2.3. Obtención de los datos de EEG

La actividad de *EEG* fue grabada con un sistema *gTec* (2 *gUSBamp* amplificadores con 28 electrodos situados de acuerdo al sistema 10/10 internacional como se puede ver en la **Figura 1**, con la toma a tierra en *FPz* y tomando como referencia el lóbulo de la oreja. Para registrar el movimiento de los musculos que rodean a los ojos se utilizó un Electrooculograma o EOG, ya que dicho movimiento interfiere en la señal de EEG. Los movimientos tanto verticales como horizontales fueron grabados para su posterior eliminación de la señal del electroencefalograma. Los dos tipos de señales, tanto el *EEG* como el EOG, son digitalizadas con una frecuencia de sampleo de 256 Hz, a las cuales se les aplica un filtro de primera clase y un filtro de paso bajo a 60 Hz. Los 28 electrodos o canales reciben los siguientes nombres: *Fp1*, *Fp2*, *F7*, *F8*, *F3*, *Fz*, *F4*, *T7*, *T8*, *C3*, *Cz*, *C4*, *P7*, *P8*, *P3*, *Pz*, *P4*, *O1*, *O2*, *FC1*, *FC2*, *FC5*, *FC6*, *CPz*, *CP1*, *CP2*, *CP3*, *CP4* y su disposición, a lo largo del cráneo de los sujetos, era:



**Figura 2.3:** Disposición de los electrodos en la cabeza

Además de las medidas de EEG, con la señal de sincronización que indica en qué momento se inicia el movimiento, el sistema también grabó marcadores de tiempo correspondientes al inicio del movimiento del brazo, quedando la señal en todos los casos organizada de la siguiente manera: tenemos un marcador negativo hasta que llegamos al marcador 0 que nos indica que es entonces cuando el sujeto ha comenzado a mover el brazo. Esta información se obtuvo teniendo tanto en el brazo, como en el punto destino, botones que registraban esta actividad. A través de los marcadores del tiempo, la señal se dividió en tres segmentos de 300 ms cada uno, uno por cada clase, del siguiente modo: los 300 ms iniciales de la señal para el reposo, los 300 ms desde el instante marcado como 0 corresponderán al estado de ejecución del movimiento y los 300 ms previos al instante 0 serán considerados como anticipación, como se puede ver en la **Figura 2.4**.

Como resultado tendremos la señal en crudo, o "*raw data*", la cuál está organizada de la siguiente manera:  $X \in \mathbb{R}^{C \times T}$ , siendo  $T$  el número de muestras temporales, una vez que nos hemos quedado con los 300 ms por clase (en nuestro caso en particular, como estaba realizado el experimento y la frecuencia de sampleo de las muestras, tenemos que son 77 muestras por clase), y  $C$  el número de canales.

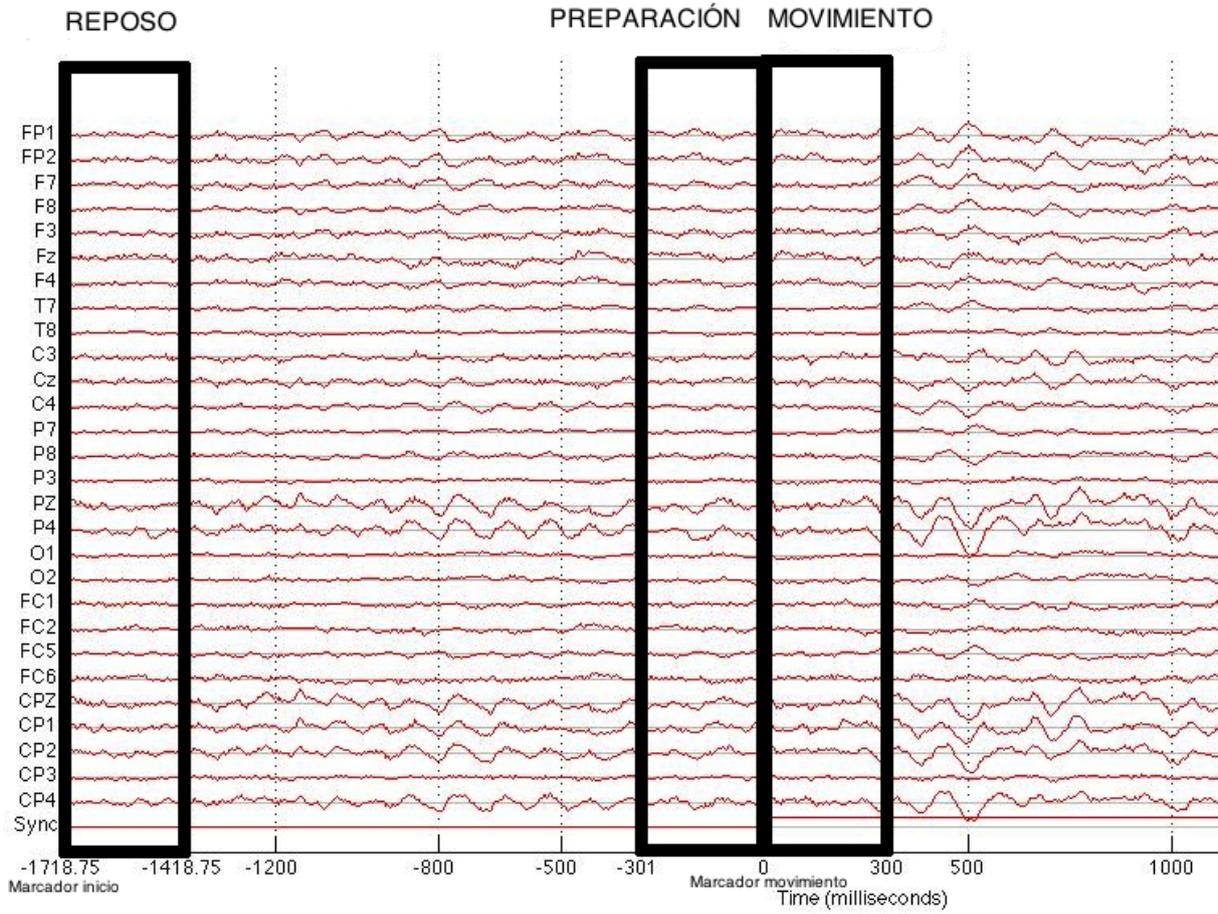


Figura 2.4: Segmentación de los canales



# Capítulo 3

## Procesado de la señal

### 3.1. Introducción

Como la señal de *EEG* presenta ruido, así como otros procesos que no son de interés para este proyecto, es imprescindible estudiar las características o "*features*" para poder clasificar adecuadamente los estados de reposo, preparación y movimiento. Con el estudio de las características, podemos diferenciar cuáles son las más significativas y seleccionarlas para la clasificación. Con las más importantes seleccionadas, será el momento de comenzar un proceso de realce de dichas propiedades, lo cuál redundará en una mejor clasificación de las clases.

De acuerdo con estudios anteriores, la información más relevante es la conocida como "desincronizaciones o sincronizaciones relacionadas con el evento" o "*event-related potentials*" (ERD/ERS) de las áreas motoras [2], las cuales se encuentran en las frecuencias comprendidas entre los 12 y los 15 Hz, así como una importante actividad en las bajas frecuencias correspondientes a los "potenciales corticales lentos" o "*slow cortical potentials*", los cuales se relacionan con la preparación motora [3]. A priori, esta información debería ser suficiente por sí sola para poder distinguir claramente los tres estados, puesto que hasta la fecha los ERD/ERS han sido utilizados para clasificar reposo y movimiento y los potenciales corticales lentos lo fueron para separar preparación o anticipación de la ejecución del movimiento.

Los resultados obtenidos con estas "*features*" no dieron buenos resultados, por lo que tuvimos que recurrir a un refinado de la señal, que nos mejorara la separabilidad de las clases, para lo que se aplicaron distintos filtros: filtros espaciales, como pueden ser laplacianos, bipolares o CAR, y filtros frecuenciales, en el rango de frecuencias en los cuales se encuentre la mayor diferencia estadística entre clases utilizando el estimador  $r^2$ , conoci-

do también como "coeficiente de determinación", para más información ver **Anexo A.1**. Además, en pasos posteriores se estudió el empleo de técnicas de rectificado y/o suavizado de la señal para mejorar las "features" de la señal.

El electrodo  $C3$  está asociado al control del brazo de acuerdo a múltiples estudios [11], [13]. Por lo tanto, el principal cometido en esta fase consistió en obtener el valor de  $r^2$  para el canal  $C3$  con los datos en crudo y mejorar este valor mediante el procesado de la señal.

## 3.2. Filtros espaciales lineales

### 3.2.1. Descripción

Uno de las técnicas más utilizadas a la hora de mejorar la separabilidad de las clases en cualquier estudio, consiste en aplicar a la señal varios filtros y compararlos para ver cuál de ellos produjo la mayor diferencia estadística entre las clases, para lo cuál se utiliza por lo general el estimador  $r^2$  [9], para más información ver **Anexo A.1**. En este proyecto, se aplicaron algunos de los filtros más comunes utilizados en la bibliografía: los filtros espaciales lineales[10], [11], [12].

Los filtros espaciales lineales consisten en alterar el valor de un canal como resultado de una combinación lineal de otro canal o conjunto de otro de canales. Dependiendo de esta combinación lineal, se tendrán unos filtros u otros, para este proyecto se han utilizado los más comunes como son el CAR, los bipolares o los laplacianos. Con estos filtros se busca mejorar las características de la señal.

Como se ha mencionado anteriormente, para ver cuál de estos filtros es el que mayor diferencia estadística proporciona mejorando así la separabilidad de las clases, se emplea el "coeficiente de determinación" o  $r^2$ , que básicamente consiste en la correlación de los datos elevada al cuadrado. Con este estimador podemos comprobar cuáles son los datos que están más correlacionados y, por lo tanto, cuáles son los más importantes a la hora de separar las clases; para ello, se comparará el valor antes de aplicar ningún filtro espacial y luego con los distintos filtros aplicados. Nos interesará en particular mejorar el valor del estimador  $r^2$  del canal  $C3$  porque éste canal está asociado al movimiento del brazo derecho.

### 3.2.2. CAR

Este filtro cuyas siglas significan "*Common Average Reference*", consiste en que al valor de un canal dado se le resta el valor del promedio de todos los canales en ese instante de tiempo:

$$X \in \mathbb{R}^{C \times T} \quad (3.1)$$

$X$  = "Raw data",  $C$  = Número de Canales,  $T$  = Instantes de Tiempo.

$$\bar{X} = \frac{1}{C} * \sum_{i=1}^C X^{iXt}, \forall t \in T \quad (3.2)$$

Siendo  $\bar{X}$  la media de todos los canales en cada uno de los instantes de tiempo, con esto tenemos que la señal filtrada con CAR es:

$$X_{CAR} = X^{cXt} - \bar{X}^t, \forall c \in C, \forall t \in T \quad (3.3)$$

### 3.2.3. Filtros Bipolares

Un filtro bipolar consiste en restarle al valor de la señal en un instante de tiempo dado y para todos los canales, el valor, en el mismo instante de tiempo, de un canal de referencia, este proceso se repite para todos los canales en todos los instantes de tiempo, menos para  $C3$  porque necesitamos mejorar el estimador  $r^2$  para  $C3$ , y, al final, obtenemos un total de " $C$ " filtros que genera las señales:

$$X_{B_i} \in \mathbb{R}^{C \times T} \quad (3.4)$$

Como en todos los casos buscaremos en  $C3$  el que dé la mayor diferencia estadística entre las clases de una pareja.

### 3.2.4. Filtros Laplacianos

Por último, también se utilizaron distintos filtros laplacianos, que consisten en la aplicación de una máscara  $3 \times 3$  a cada valor de la señal de *EEG* crudo para un canal y un instante de tiempo. Para los elementos de la máscara se toman los valores de los vecinos

del canal que estamos filtrando, dependiendo de qué vecinos cojamos el laplaciano será de un tipo o de otro: *laplaciano menor*, es aquel que toma los vecinos más cercanos físicamente de un canal dado, por ejemplo: como podemos ver en la **Figura 2.3**, los vecinos del canal  $Cp_z$  serían  $Cz$ ,  $Cp1$ ,  $Cp2$  y  $Pz$ , mientras que los *laplacianos mayores* no tienen en consideración los vecinos más cercanos físicamente sino los segundos más cercanos, por ejemplo: para el caso de  $Cz$  los vecinos utilizados serían:  $Fz$ ,  $Cp3$ ,  $Cp4$  y  $O1$  o  $O2$ . Los dos operadores laplacianos utilizados, tanto para laplacianos mayores como para menores, son dos de los más comunes:

$$W_1 = \begin{bmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad W_2 = \begin{bmatrix} 1 & 4 & 1 \\ 4 & -20 & 4 \\ 1 & 4 & 1 \end{bmatrix} \quad (3.5)$$

Con estas máscaras, obtenemos la señal filtrada bipolarmente:

$$X_L = W * X_{raw}^{cXt} \quad (3.6)$$

Ahora compararemos el coeficiente de determinación de la señal en  $C3$  y lo compararemos con el de la señal en crudo, comprobando si con este filtro se consiguen mejorar las características.

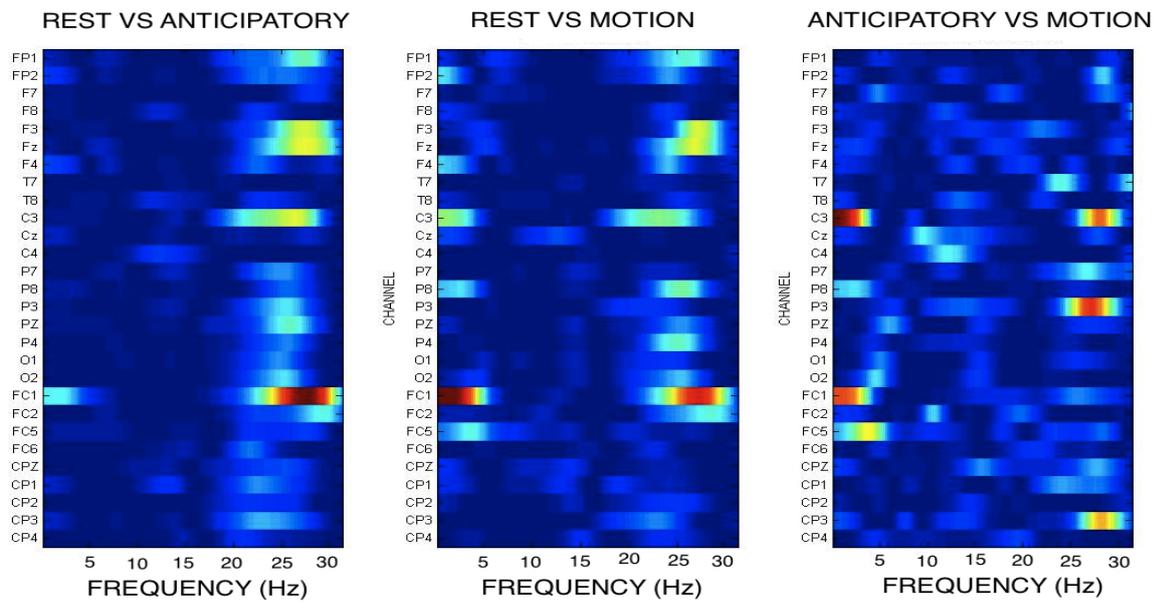
### 3.2.5. Selección del filtro

Una vez que se ha filtrado la señal, se elige cuál de todos los filtros expuestos con anterioridad, es el más adecuado para el problema de la clasificación. Para ello, como se ha explicado previamente se utilizará el estimador  $r^2$  o coeficiente de determinación. El procedimiento es el siguiente: teniendo la señal  $X \in \mathbb{R}^{CXT}$  en el dominio del tiempo, la pasamos al dominio de la frecuencia, usando el periodograma, ver **Ecuación 3.7** con lo que ahora disponemos de  $X \in \mathbb{R}^{CXF}$  y hacemos lo mismo con  $X_{CAR}$ ,  $X_{B_i}$ ,  $\forall i \in C$  y  $X_L$ .

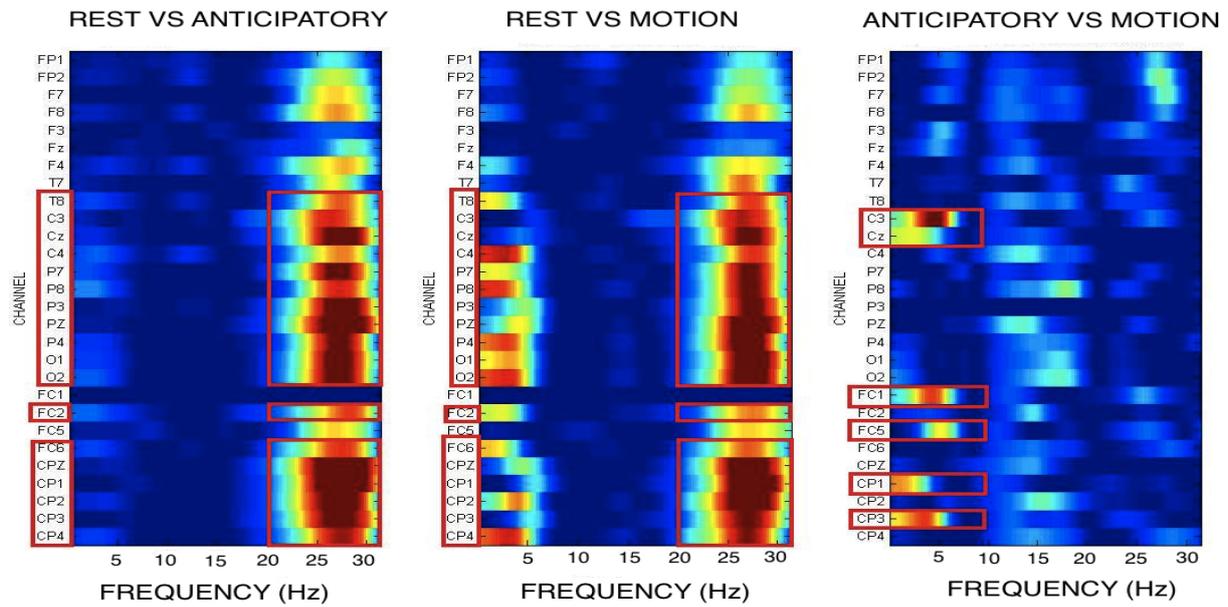
$$S(f) = \frac{1}{F_s * N} * \left| \sum_{n=1}^N x_n^{e^{-j*(2*\pi*\frac{f}{F_s})*n}} \right|^2 \quad (3.7)$$

A continuación separamos los cuatro tipos de procesados de señales en parejas de estados: Reposo - Preparación, Reposo - Movimiento y Preparación - Movimiento. Una vez hecho esto, calculamos el estimador estadístico  $r^2$  para cada una de las parejas de cada una

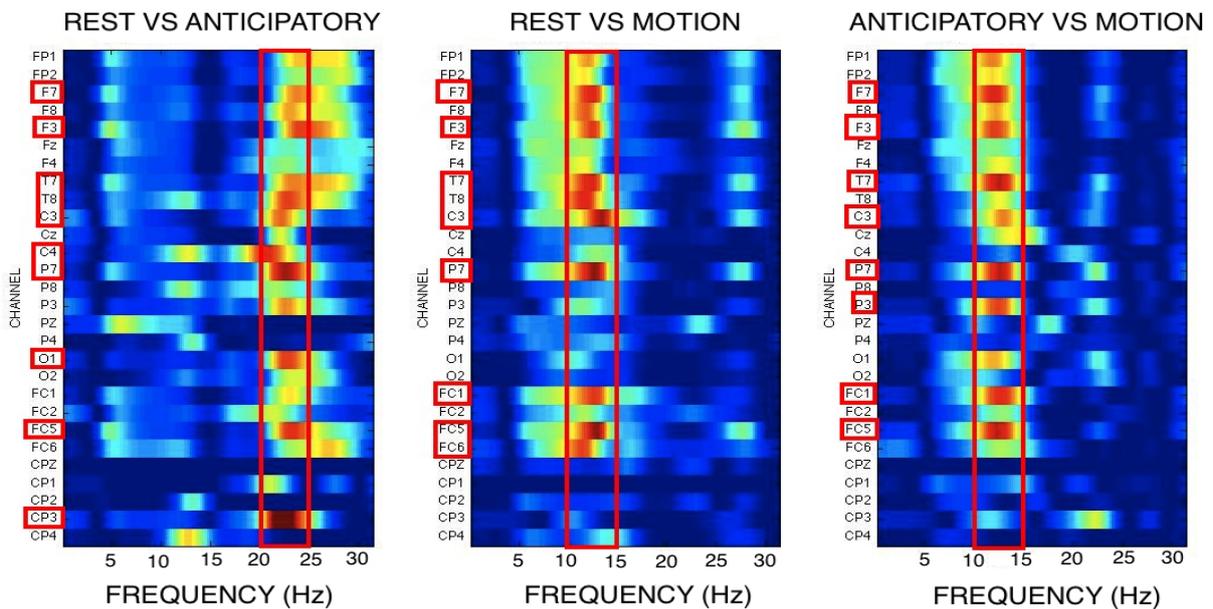
de los tipos de señales. Tomando como referencia los resultados obtenidos para la señal en crudo, la compararemos con los resultados de cada pareja de los distintos filtros y seleccionaremos aquel que dé mayor diferencia estadística entre las clases en  $C3$ . En la **Figura 3.1** tenemos el coeficiente de determinación para las tres parejas de estados en el caso de la señal en crudo, mientras que en la **Figura 3.2** podemos comprobar cómo se han realizado las características de la señal indicándonos en qué frecuencias se encuentra la mayor diferencia estadística, así como los canales más significativos.



**Figura 3.1:** estimador  $r^2$  para el Sujeto 1 con los datos raw



**Figura 3.2:** estimador  $r^2$  para el Sujeto 1 con filtro bipolar FC1 para Reposo - Preparación y Reposo - Movimiento y filtro bipolar P3 para Preparación - Movimiento



**Figura 3.3:** Estimador  $r^2$  para todos los canales del sujeto 4

Como podemos apreciar el incremento de la separabilidad utilizando un filtro bipolar

ha sido grande. Repitiendo el proceso para cada uno de los seis sujetos tenemos que para cada uno de ellos, se necesita un filtrado espacial distinto, pero todos ellos tienen en común que utilizan un filtro bipolar, diferenciándose únicamente en cuál de los canales se emplea para filtrar. En la **Tabla 3.1** podemos ver cuál ha sido el tratamiento idóneo para cada sujeto. En el **Anexo B** podemos ver el  $r^2$  para cada sujeto.

SUJETO	REP- PREP	REP - MOV	PREP- MOV
1	Bipolar FC1	Bipolar FC1	Bipolar P3
2	Bipolar Fz	Bipolar FC2	Bipolar FC2
3	Bipolar CP3	Bipolar F7	Bipolar CP3
4	Bipolar CPz	Bipolar CP1	Bipolar CPz
5	Bipolar P4	Bipolar O1	Bipolar O1
6	Bipolar P8	Bipolar FP1	Bipolar FP1

**Tabla 3.1:** Filtros seleccionados para cada Sujeto

### 3.3. Selección de Filtros y Canales

Con el periodograma, ver **Ecuación 3.7** calculado, y con  $r^2$  también, nos centramos en ver cuáles son las bandas en las que se produce el mayor valor numérico del estimador para el canal  $C3$ . Sabiendo cuáles son las frecuencias que debemos filtrar, lo único que hay que hacer será diseñar un filtro *Butterworth*, ver **Ecuación 3.8** de paso bajo, paso banda o paso alto que nos quede con ese rango de frecuencias. En la **Figura 3.3** podemos ver cuáles son las frecuencias relevantes para el sujeto 4.

$$|H(\Omega)|^2 = \frac{1}{1 + \left(\frac{\Omega}{\Omega_c}\right)^{2*N}} \quad (3.8)$$

Para el sujeto 1, como apreciamos en la **Figura 3.2**, la banda seleccionada para separar reposo y preparación y reposo y movimiento, corresponde con una desincronización relacionada con el evento (ERD) en la banda  $\beta$  superior (en torno a los 25 Hz), en el caso de reposo y movimiento aparece también cierta información relevante en las bandas  $\delta$  (menores de 5 Hz). En el caso de preparación y movimiento sólo aparece la diferencia es-

tadística en las frecuencias bajas. Este último responde, probablemente, a los potenciales bajos relacionados con el movimiento como se describe en [14]. Como vemos en la **Figura 3.3** para el peor sujeto, las frecuencias significativas son totalmente distintas: entre reposo y preparación surge en la parte media de la banda  $\beta$ , mientras que entre reposo y movimiento aparece en la banda  $\alpha$ , igual que entre preparación y movimiento. En la **Tabla 3.2** se puede ver qué filtros y qué rango de frecuencias  $f_r$  han sido seleccionados para cada uno de los seis sujetos.

SUJETO	REP- PREP	REP - MOV	PREP- MOV
1	paso banda 20 - 30 hz	paso banda 20 - 30 hz	paso bajo 10 hz
2	paso banda 25 - 30 hz	paso bajo 10 - 20 hz	paso banda 10 - 20 hz
3	paso banda 20 - 30 hz	paso bajo 5 hz	paso banda 20 - 30 hz
4	paso banda 20 - 25 hz	paso banda 10 - 15 hz	paso banda 10 - 15 hz
5	paso banda 10 - 15 hz	paso banda 15 - 25 hz	paso banda 17 - 20 hz
6	paso banda 5 - 10 hz	paso bajo 10 hz	paso bajo 10 hz

**Tabla 3.2:** Tipo de filtro *butterworth* para cada sujeto

El proceso de selección de canales es análogo al de selección del filtro espacial y de las frecuencias: a partir del coeficiente de determinación, podemos ver en qué canales, además del C3, son los que presentan un valor numérico más alto y por lo tanto, van a ser los más significativos a la hora de poder separar las clases de la mejor manera posible.

En las **Figuras 3.2** y **3.3** podemos ver de una manera visual cuáles son los canales seleccionados para los sujetos 1 y 4.

En la **Tabla 3.3** podemos ver todos los canales seleccionados para cada sujeto, en todas ellas debe aparecer C3 por su importancia para la investigación.

SUJETO	REP- PREP	REP - MOV	PREP- MOV
1	T8, C3, C4, P7, P8, P3, Pz, P4, O1, O2, FC2, FC6, CPZ, CP1, CP2, CP3, CP4	T8, C3, C4, P7, P8, P3, Pz, P4, O1, O2, FC2, FC6, CPZ, CP1, CP2, CP3, CP4	C3, Cz, FC1, FC5, CP1, CP3
2	FP1, F7, F3, T7, C3, P7, FC5	F3, C3, P7, CP1, CP3	F3, C3, P7, CP1, CP3
3	F3, C3, P7, FC1, CP1, CP3	F3, C3, P7, FC1, CP1, CP3	F3, C3, P7, FC1, CP1, CP3
4	F7, F3, T7, T8, C3, C4, P7, O1, FC5, CP3	F7, F3, T7, T8, C3, P7, FC1, FC5, FC6	F7, F3, T7, T8, C3, P7, P3, FC1, FC5
5	FP1, FP2, F7, F8, F3, T7, T8, C3, P7, FC5, FC6, CP3	T8, C3, C4, P7, P8, P3, CP1, CP2, CP3, CP4	F3, Fz, C3, P3, FC1
6	F7, F3, C3, Cz, FC1, FC5, CP1, CP3	C3, C4, P3, P4, FC2, FC6, CP2, CP3	C3, Cz, C4, P3, Pz, P4, O1, O2, FC2, CPz, CP1, CP2, CP3

Tabla 3.3: Canales seleccionados para cada sujeto

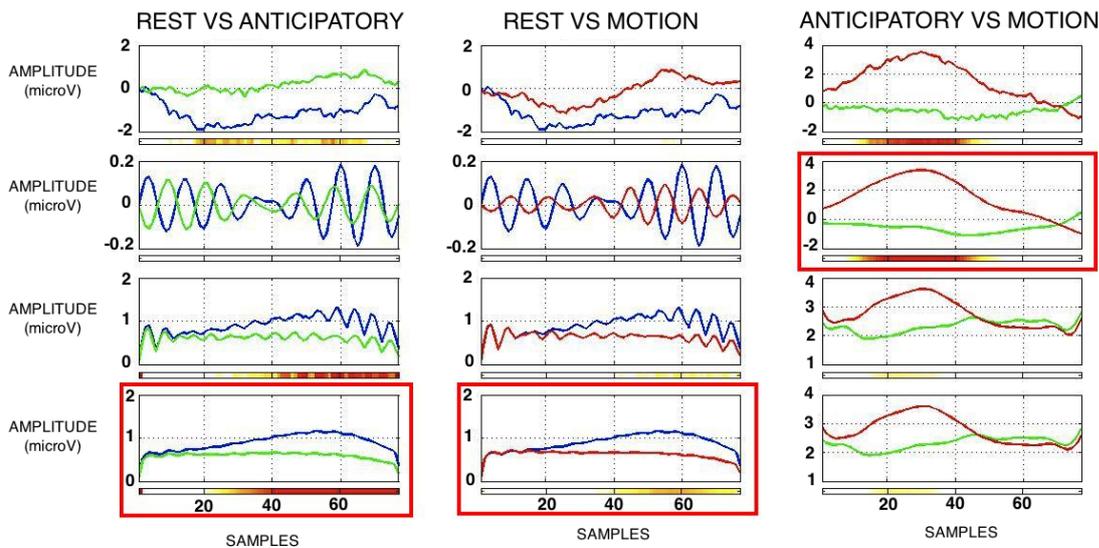
### 3.4. Rectificado y Suavizado

El último paso antes de entrenar el clasificador consistió en procesar los canales seleccionados en el dominio del tiempo nuevamente. Primero, aplicamos un filtro "Butterworth", ver **Ecuación 3.8** en el espectro de la frecuencia seleccionado  $f_r$ . Diversos estudios demuestran que una buena manera de mejorar la estabilidad de la señal e incrementar la diferencia estadística entre clases consiste en rectificar y suavizar la señal [15].

El rectificado consiste en hacer positiva toda la señal, es decir, el valor absoluto de toda la señal. Por otro lado, la técnica de suavizado utilizó una media móvil simple (SMA) utilizando los  $n = 3$  datos anteriores.

### 3.5. Señal seleccionada

Por último, igual que en el caso de la elección los distintos tipos de características, se utilizó un test de  $r^2$  para seleccionar cuál de los cuatro tipos de señales es la mejor para la clasificación. Los cuatro tipos de señales son: señal filtrada espacialmente, señal filtrada espacialmente y frecuencialmente, señal filtrada espacialmente, frecuencialmente y rectificadora y, por último, la señal con todo el procesamiento indicado: filtrada espacialmente, frecuencialmente, rectificadora y suavizada. En la **Figura 3.4** se puede ver las cuatro señales para el sujeto 1 y cuáles se seleccionaron a tenor de lo mostrado por el coeficiente de determinación. Para ver de manera gráfica cuáles fueron los canales seleccionados, las bandas de frecuencias y el tipo de señal seleccionada para cada uno de los sujetos consultar el **Anexo B**.



**Figura 3.4:** Tipos de señales en el dominio del tiempo para el sujeto 1, de arriba abajo: filtrado espacial, frecuencial, rectificadora, suavizada

En la **Tabla 3.4** se puede ver cuál de los cuatro tipos de señales se seleccionaron para la clasificación.

SUJETO	REP- PREP	REP - MOV	PREP- MOV
1	Suavizada	Suavizada	Filtrado frecuencial
2	Filtrado espacial	Filtrado espacial	Filtrado espacial
3	Filtrado espacial <sup>1</sup>	Filtrado frecuencial	Filtrado espacial <sup>1</sup>
4	Filtrado espacial	Suavizado	Filtrado espacial
5	Suavizado	Filtrado frecuencial	Suavizado
6	Filtrado espacial	Filtrado espacial	Filtrado espacial

**Tabla 3.4:** Señal seleccionada para cada sujeto

<sup>1</sup>Empíricamente se demostró que para clasificar las tres clases por separado es mejor usar la señal suavizada



# Capítulo 4

## Clasificación

### 4.1. Introducción

Con las características finales de la señal seleccionadas, el último paso del proceso consistió en el entrenamiento de dos clasificadores lineales multiclase: LDA y "shrinkage" [16], [17], [18], [19], [20], [21]. Como el número de características de la señal es parecido, en el mejor de los casos, o mucho mayor, en el peor, se utilizó "shrinkage" como estimador de la matriz de covarianza de las clases [16], [17].

Como se disponen de pocas muestras de la señal, y más si los comparamos con el número de características, se necesita una validación de estos datos. Para ello, se utilizará la técnica de *validación cruzada de los datos*, que nos dividirá en dos grupos de datos: "entrenamiento" y "test" un número determinado de veces. Con los datos separados en entrenamiento y validación, les aplicaremos un *análisis de las componentes principales* o *PCA* para reducir la dimensionalidad de los datos, después normalizaremos los datos y, por último, entrenaremos los clasificadores con los datos de "entrenamiento" y validaremos con los datos de "test"

### 4.2. Metodología

#### 4.2.1. Validación cruzada de los datos

Necesitamos dividir los datos en datos para entrenar los clasificadores y datos para probarlos, pero disponemos de un conjunto pequeño de muestras de los datos, se hace necesario un proceso de validación de los datos, en nuestro caso usamos el método de validación cruzada de datos. La validación cruzada o "*cross-validation*" es una práctica estadística que consiste en un grupo de datos, se subdividen en dos subconjuntos: uno

de entrenamiento y otro de validación. Éste proceso se repite un número "n" de veces obteniendo así la validación del modelo y de los datos.

Para este proyecto se utiliza la variación conocida como "*ten-fold cross validation*" que consiste en separar los datos en dos conjuntos: el primer conjunto de entrenamiento con el 90 % de los datos y el conjunto de validación con el 10 % restante. Éste proceso se repite un total de 10 veces, con lo que todos los datos han sido usados como entrenamiento y como validación.

### 4.2.2. Análisis de las Componentes Principales (PCA)

El análisis de las componentes principales, en inglés "*principal component analysis*" (PCA), es una técnica estadística que sirve para reducir la dimensionalidad de los datos. Esta técnica es utilizada para estudiar la variabilidad de las componentes de los datos y ordenarlas de mayor a menor importancia. PCA elabora una serie de transformaciones lineales que seleccionan unos nuevos sistemas de coordenadas en los cuales las componentes ordenadas de mayor a menor variabilidad ocupan los nuevos ejes de manera ordenada.

Tenemos una matriz  $X$  con  $m$  filas y  $n$  columnas:

$$X^T \in \mathbb{R}^{n \times m} \quad (4.1)$$

Calculamos su descomposición en valores singulares:

$$X = W * \Sigma * V^T \quad (4.2)$$

Con  $W$  los autovectores de  $X * X^T$ ,  $\Sigma \in \mathbb{R}^{m \times n}$  una matriz diagonal regular y  $V$  los autovectores de  $X^T * X$  y siendo  $W_L^T$ , los  $L$  primeros autovectores de  $W$ , la matriz con la dimensionalidad reducida sería:

$$Y = W_L^T * X \quad (4.3)$$

En el caso del proyecto, con unas matrices de datos muy grandes fue necesario reducir la dimensionalidad de los datos para que los clasificadores dieran resultados válidos. Entonces, con el 90 % de los datos para validación o "*entrenamiento*" aplicamos PCA para quedarnos con el 99 % de la variabilidad de la señal. Una vez que teníamos la matriz de transformación para quedarnos con el 99 % de los datos la utilizábamos para reducir las

dimensiones de los datos de "entrenamiento" y de "test" por separado, para que no hubiera interferencia entre los datos.

### 4.2.3. Normalización

Con los datos de validación obteníamos el máximo y el mínimo, siendo estos valores 1 y 0. Luego aplicábamos esta normalización con esos valores a los datos de validación, para que éstos estuvieran en la misma escala, pudiendo haber valores de más de 1 o menores que 0 puesto que puede que el máximo global de la señal se encontrara en los datos de validación y no en los de entrenamiento.

Si tenemos que  $xmax = \max(\text{entrenamiento})$ ,  $xmin = \min(\text{entrenamiento})$ ,  $y_{max} = 1$ ,  $y_{min} = 0$ , entonces tenemos que:

$$valor\_normalizado = \frac{(y_{max} - y_{min}) * (x_i - xmin)}{(xmax - xmin) + y_{min}}, \forall x_i \in X_{entrenamiento} \cup X_{test} \quad (4.4)$$

### 4.2.4. Clasificadores

El paso final de la consistió en elegir qué métodos de clasificación se iban a utilizar y cómo se iban a clasificar los datos. Los métodos que seleccionamos fueron dos clasificadores lineales, ampliamente utilizados en investigación sobre BCI: el análisis lineal discriminante o LDA y el método de estimación de las matrices de covarianza derivado del LDA, conocido como "shinkage".

LDA (ver **Anexo A.2.2**) asume que los datos están distribuidos siguiendo una normal con media  $\mu_k$  y covarianza  $\Sigma_k, \forall k \in 1..N$ , siendo N el número de clases distintas. En nuestro caso k puede tomar valores 1 (reposo), 2 (preparación) y 3 (anticipación). La particularidad de este método es que asume que todas las clases tienen la misma covarianza:  $\Sigma_k = \Sigma$ . La matriz de covarianza estimada es la matriz de covarianza empírica. Cada muestra pertenecerá a la clase  $k$  que minimice la función:

$$\delta_k(X) = (X - \hat{\mu}_k)' * \hat{\Sigma}^{-1} * (X - \hat{\mu}_k) + \ln|\hat{\Sigma}| - 2 * \ln\pi_k \quad (4.5)$$

El estimador estándar de la matriz de covarianza es la covarianza empírica. Con datos que tienen muchas dimensiones pero pocas muestras en comparación, como es nuestro caso, este estimador se vuelve impreciso porque el número de parámetros desconocidos que hay que aproximar es cuadrático con respecto al número de dimensiones, por ello se

hizo necesario usar otro método: "shrinkage". El método "shrinkage", ver **Anexo A.2.3**, parte del mismo principio, pero surge para contrarrestar el "bias" o sesgo sistemático que surge en la estimación de la matriz de covarianza. Para solucionar esto, la matriz de covarianza  $\Sigma$ , es reemplazada por la estimación,  $\tilde{\Sigma}$ :

$$\tilde{\Sigma}(\gamma) = (1 - \gamma) * \Sigma + \gamma * \nu * I \quad (4.6)$$

Siendo  $\gamma \in [0, 1]$  el parámetro de afinación,  $\nu$  el promedio de la traza de los autovalores dividido entre la dimensión de los datos e "I" la matriz identidad. Con  $\gamma = 1$  asumimos matrices de covarianza esféricas y con  $\gamma = 0$  estamos en el caso de LDA.

Los dos tipos de clasificaciones hechas fueron: clasificando entre dos clases (*reposo - preparación*, *reposo - movimiento* y *preparación - movimiento*), utilizando el vector de características formado por el par de señales en cuestión, y clasificando las tres clases a la vez simultáneamente usando la concatenación de las características seleccionadas para cada par de clases.

# Capítulo 5

## Resultados

### 5.1. Parejas de clases independientes

#### 5.1.1. Shrinkage

SUJETO	REP- PREP	REP - MOV	PREP- MOV
1	69'59	67'86	80'78
2	67'30	81'01	75'01
3	72'01	72'57	68'47
4	58'63	55'39	63'18
5	57'83	58'85	54'09
6	66'92	60'85	65'38
PROMEDIO	65'38	66'08	67'81

**Tabla 5.1:** Porcentaje de aciertos por parejas usando "shrinkage"

En la **T6** mostramos que el promedio de aciertos de todos los sujetos se sitúa en torno al 66 %, teniendo picos en momentos puntuales que llegan a alcanzar el 80 %. Podemos comprobar que los individuos que mejor han respondido han alcanzado un porcentaje de clasificación por encima del 71 %, teniendo un caso intermedio en el sujeto 6 que llega al 65 %. En el otro extremo, los sujetos que peor funcionan no alcanzan el 60 % de los datos bien clasificados.

### 5.1.2. LDA

SUJETO	REP- PREP	REP - MOV	PREP- MOV
1	69'07	66'06	81'29
2	68'39	80'54	75'01
3	70'38	72'90	70'38
4	56'09	57'30	60'42
5	58'55	60'33	53'72
6	67'31	58'08	65'77
PROMEDIO	64'96	65'87	67'76

**Tabla 5.2:** Porcentaje de aciertos por parejas usando LDA

En la **Tabla 5.2** podemos comprobar los resultados para cada uno de los sujetos. El promedio de acierto se sitúa en torno al 66 % de manera global para cada una de las clases, pero comprobamos que para los sujetos mejor clasificados: el primero, el segundo y el tercero, el promedio se sitúa por encima del 71 % llegando incluso casi al 75 % en el mejor caso. Por contra, los sujetos que peor responden al procesado aplicado son los sujetos cuarto y quinto, que están entorno al 55 %, siendo el peor el quinto sujeto, alcanzando a duras penas el 53 %. Podemos ver que alcanzamos en algunas situaciones concretas una tasa acierto por encima del 80 %.

### 5.1.3. Interpretación de los resultados

Los dos métodos implementados arrojan unos resultados muy parecidos, siendo ligeramente mejores los de "shrinkage", pero en todo caso no alcanza ni un 1 % de diferencia entre ambos casos. El que estén situadas su tasas de acierto en torno al 66 % para cada pareja de clases, nos indica que se tratan de unos clasificadores muy interesantes para su aplicación en esta clase de problemas debido a su relación eficacia - rapidez. El problema se encuentra en los sujetos que no se han podido encontrar un conjunto de características que den una tasa de aciertos aceptable, y que bajan la media global de la clasificación.

## 5.2. Resultados de las tres clases simultáneamente

### 5.2.1. Shrinkage

REAL VS CLASIFICADO	REPOSO	PREP	MOVIMIENTO
REPOSO	54'99	23'51	21'49
PREPARACIÓN	23'64	54'74	21'62
MOVIMIENTO	22'63	20'48	56'89

**Tabla 5.3:** Promedio de clasificación para los tres estados usando "shrinkage"

Como observamos en la **Tabla 5.3** y comparándola con la **Tabla 5.1** vemos que el porcentaje de aciertos ha caído un 10 % con respecto a la clasificación por parejas, situando la media de aciertos en torno al 55 % para cada uno de los estados. Como analizaremos en el **Anexo ??**, los mejores sujetos están por encima del 60 % bien clasificado, el problema vuelve a surgir con los peores que están esta vez en torno al 40 % lo que reduce la eficacia global del sistema.

### 5.2.2. LDA

REAL VS CLASIFICADO	REPOSO	PREP	MOVIMIENTO
REPOSO	51'89	23'08	25'03
PREPARACIÓN	23'91	53'88	23'21
MOVIMIENTO	24'07	20'56	55'37

**Tabla 5.4:** Promedio de clasificación para los tres estados usando LDA

Como podemos apreciar en la **Tabla 5.4** y analizándola junto con la 5.2, y al igual que el caso de "shrinkage", el rendimiento disminuye en torno al 10 % de manera global. Como expone el **Anexo ??**, tenemos que los tres primeros sujetos se mantienen en unos porcentajes superiores al 60 % bien de media, pero los peor clasificados no alcanzan ni siquiera un 50 %.

### 5.2.3. Interpretación de los resultados

Igual que en el caso de la clasificación por parejas, a penas hay diferencias del 1% entre ambos métodos de clasificación, pero hay un descenso brusco del rendimiento de los mismos, debido en parte al esfuerzo extra que supone para ellos tener que discernir entre tres clases en vez de entre dos. Si a esto sumamos el hecho de que hay tres sujetos de los denominados "*non-responders*", que son aquellos sujetos que no responden a un tratamiento que para otras personas sí que funciona, es normal que haya un bajo porcentaje de aciertos. Para los que sí que responden al procesado se encuentra la tasa de acierto por encima del 60% de media, lo cual en este punto de las investigaciones es un comienzo prometedor.

# Capítulo 6

## Fases del proyecto

### 6.1. Descripción de las fases

El proyecto constó de cinco fases: la primera fase consistió en la documentación. En primer lugar hubo que documentarse sobre los métodos lineales de clasificación que se iban a utilizar, pues en un principio éste iba a ser el punto de partida del proyecto de fin de carrera. Cuando necesitamos para la clasificación la reducción de las dimensiones, nos documentamos sobre PCA. Una vez que se enfocó el proyecto al procesado de la señal de EEG relacionado con el movimiento del brazo derecho, leímos mucho sobre los diversos filtros espaciales y frecuenciales, así como el procesado que se había utilizado en otras publicaciones científicas y/o investigaciones.

La siguiente fase versó sobre la codificación de los distintos aspectos técnicos relacionados con el proyecto. Al principio y una vez entendido los métodos lineales de clasificación LDA y "*shrinkage*", las programamos en Matlab y las probamos, ésta fue la siguiente fase del trabajo. Programamos las herramientas a medida que las necesitábamos para mejorar la clasificación, como fueron PCA y la normalización. Cuando trabajamos con los datos del EEG relativo al movimiento, implementamos los diversos filtros, rectificadores y suavizados para cada una de los sujetos. Por último, comenzamos a trabajar en "*Modelos Ocultos de Markov*" pero no se obtuvieron resultados significativos, aunque estas primeras implementaciones podrán ser usadas en futuros proyectos fin de carrera o investigaciones sobre el tema.

El tercer bloque consistió en la realización de las pruebas: cuando desarrollábamos un módulo de programación era probado con los datos y optimizado el código con las mejoras necesarias de eficacia y rendimiento. Primero trabajamos con los datos de simulación, generándonos unos datos que siguieran una distribución normal de dimensionalidad 2,

cuando dominamos y entendimos la técnica, aumentamos progresivamente la complejidad de los datos, incrementando las dimensiones. Cuando las técnicas de clasificación lineal estaban dominadas procedimos a probarlas con datos de EEG, primero fueron los datos de ERPS y luego nos centramos en los datos de EEG sobre el movimiento del brazo derecho, siendo éste el enfoque final del proyecto. Por último, aplicamos los modelos ocultos de markov al EEG del movimiento pero no se obtuvieron resultados satisfactorios.

La cuarta faceta del proyecto fue la redacción y envío de un artículo científico a una prestigiosa conferencia relativa al mundo de la neurociencia. Durante esta fase, recapitulamos todo lo aprendido, volvimos a revisar los datos y a organizarlos y plasmarlos en el "paper". Este artículo finalmente fue aceptado para su presentación en el IEEE EMBC de 2011.

Por último gran parte del trabajo relacionado con el procesado de la señal se llevó a cabo formando parte de la empresa *BitBrain Technologies*. Durante esta fase paralela, obtuvimos gran cantidad de información sobre qué se hacía en el campo de la investigación en cuanto al tema del procesado de la señal y la búsqueda de las características más importantes a la hora de querer clasificar la señal.

## 6.2. Diagrama de Gantt

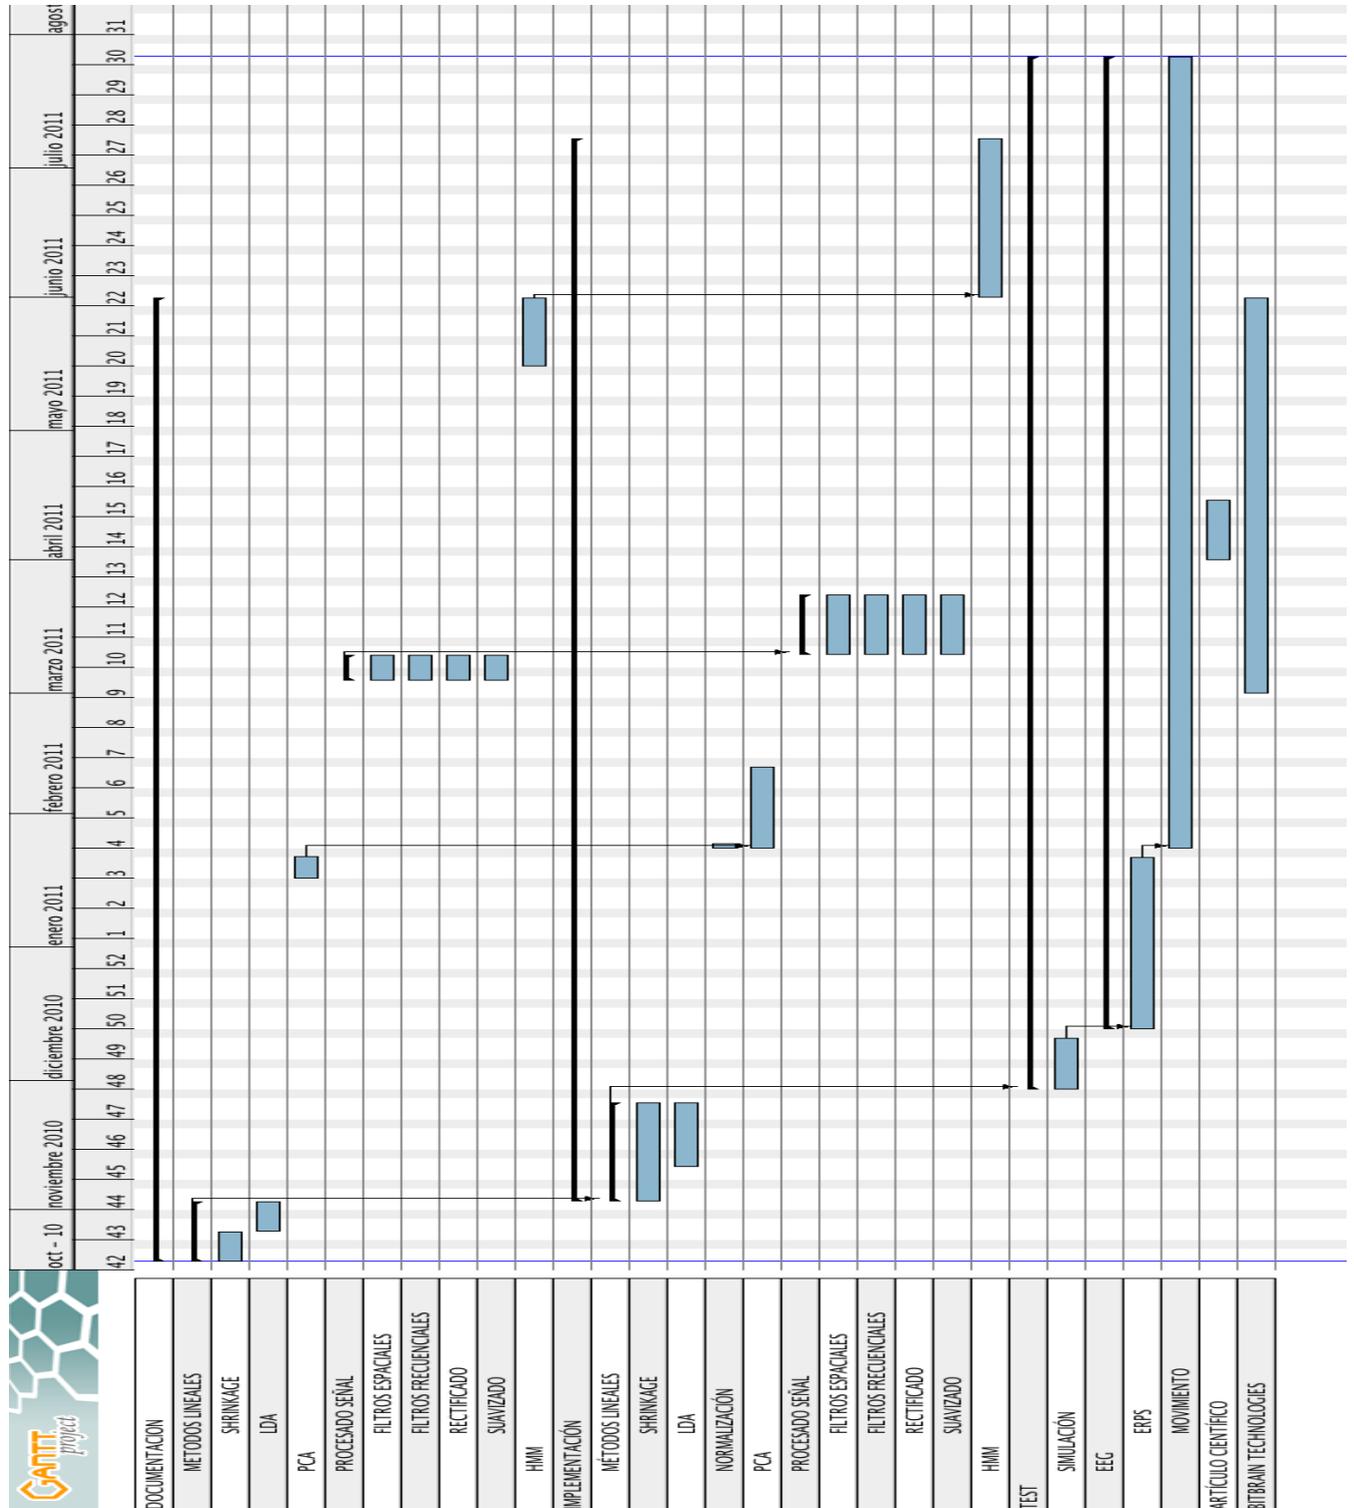


Figura 6.1: Diagrama de Gantt con las fases del proyecto



# Capítulo 7

## Cierre del proyecto

### 7.1. Conclusiones

Este proyecto trata sobre la investigación en la clasificación de los estados de reposo, preparación y ejecución del movimiento del brazo derecho a través del electroencefalograma. Siguiendo un procesamiento de la señal, ampliamente conocido en el campo de la neuro-ciencia y el *BCI*, se ha aplicado a seis sujetos de manera dispar: tres sujetos responden muy bien al procesado, que son conocidos como "*responders*", y otros tres que no responden al mismo sistema. Esto se puede apreciar ya en el test de  $r^2$ , pues hay muchas dificultades para encontrar canales con una diferencia estadística significativa en el canal *C3*.

El hecho de que haya "*non-responders*" no responde a una causa clara y común, a veces es debido a fallos en la interpretación del experimento por parte del sujeto, la aparición de muchos artefactos por la tensión inherente al propio experimento o porque su estructura mental no se ajusta a lo que se considera "normalidad", es decir, que el canal *C3* no es el más relevante en el movimiento del brazo derecho, es decir, que el punto de mayor diferencia no se encuentra justo donde lo tiene la mayoría de las personas.

Por otro lado, cuando clasificamos los estados por parejas entrenando tres clasificadores para cada pareja, obtenemos en los sujetos que sí que responden al tratamiento de la señal unos porcentajes de acierto superior al 72 %, llegando a tener picos del 80 %, lo que nos quiere decir que el procesado es correcto en los casos de los sujetos "*responders*" y que con investigaciones más exhaustivas y el estudio de las señales y filtros más complejos se conseguirán en el futuro unos porcentajes aún mejores, lo cuál sentará las bases de una integración definitiva de las prótesis robóticas, de manera más íntima, en las personas con miembros amputados, así como unas terapias de rehabilitación personalizadas.

Por otro lado, el caso de clasificar las tres clases a la vez, este es un proyecto pionero en el campo de investigación, pues no había nada de importancia publicado hasta la fecha. Como vemos en los resultados el porcentaje de aciertos para los "responders" sufre un bajón de un 10 % pero aún así está por encima del 60 % llegando incluso a obtener un 70 % en momentos puntuales.

Este proyecto viene a demostrar que seleccionando las características de la señal de EEG, es razonable pensar que se pueden llegar a alcanzar cotas de un 70 % de ejemplos bien clasificados, lo que hoy por hoy es un buen resultado en este campo de investigación, porque es una ciencia relativamente nueva y en la que continuamente se están descubriendo nuevos datos. El seguir estudiando en este campo para la mejora de las características servirá para en un futuro ser capaces de personalizar la prótesis, ya que ésta adaptará los parámetros de la misma al amputado, así como tener unos mejores porcentajes en la clasificación hará que las propias prótesis respondan mejor a las intenciones de sus usuarios, incrementando así sus prestaciones.

Tanto la investigación llevada a cabo en la selección de características, como los resultados y conclusiones obtenidos, fueron plasmados en un artículo que fue enviado y aprobado para su presentación en la conferencia *IEEE EMBC (Engineering in Medicine and Biology Conference)* en Agosto de 2011.

## 7.2. Trabajo futuro

El trabajo a corto y medio plazo sobre este tema, tanto por el Grupo de Robótica de la Universidad de Zaragoza, como *BitBrain Technologies*, tiene tres vertientes fundamentales: la selección automática de características, eliminación de las marcas de la señal y la clasificación de la señal a lo largo del tiempo.

El primer aspecto de futuro consistirá en reducir la intervención del terapeuta a la hora de seleccionar las características de manera visual o numérica, como realizamos en la actualidad, para ello se buscará la clasificación y selección de las características más importantes de la manera más automáticamente posible, así que de la propia obtención de la señal ya habrán descartado las propiedades menos relevantes de la misma, que minan la capacidad de clasificación, al ser comunes para los tres estados de la señal y sólo aportan redundancia en los datos.

El segundo, la eliminación de las marcas de la señal, consistirá en eliminar la marca

que presenta la señal en la que indicamos que empieza el movimiento y que está marcado como instante cero, a partir del cuál las marcas temporales son positivas mientras que antes lo han sido negativas. En esto hay que investigar más para poder ser capaces, a partir del estudio de la propia forma fisiológica de la señal, ésta nos indique cuál es el momento exacto en el que se empieza a ejecutar el movimiento, y no recurrir a sensores colocados en los brazos.

El último punto de investigación futura trata sobre la clasificación de la señal a lo largo del tiempo. En este proyecto, la señal se separaba en los tres estados cogiendo 300 ms de tiempo para cada uno de ellos, pero en un futuro, se investigará en que a partir de la señal continua ser capaces de decir en cuál de los tres estados se encuentra la señal, para lo cuál se empezó a trabajar en el campo de los "Modelos Ocultos de Markov" para este mismo proyecto, pero por falta de tiempo no se consiguieron resultados concluyentes y por eso no se ha reflejado en esta memoria.

A título personal, considero que en los experimentos, el hecho de que al mover el brazo se tuviera que volver luego a la posición de origen puede provocar que el estado de ejecución de movimiento de ida se solape con la intención del movimiento de vuelta del brazo haciendo que la clasificación del estado de ejecución del movimiento no sea tan precisa como debiera ser. En este tema, sería conveniente realizar nuevos experimentos que obligaran a mantener la mano en el destino una vez que se haya efectuado el movimiento.



# Bibliografía

- [1] K. P. Tee, C. Guan, K. Keng Ang, K. Soon Phua, C. Wang, H. Zhang. "Augmenting cognitive processes in robot-assisted motor rehabilitation", *Proceedings of the 2nd Biennial IEEE/RAS-EMBS International Conference on Biomedical Robotics and Biomechatronics*, Scottsdale, USA, 2008.
- [2] G. Pfurtscheller, F. Lopez da Silva. "Event-related synchronization", *Handbook of Electroencephalography and Clinical Neurophysiology*, 1999
- [3] M. Kutas, E. Donchin "Preparation to respond as manifested by movement-related brain potentials", *Brain Research*, 1980, número 95
- [4] C. Nauper, G. Pfurtscheller. "Event-related dynamics of cortical rhythms: frequency-specific features and functional correlates", *International Journal of Psychophysiology*, 2001, págs. 41-58
- [5] Valerie Morash, Ou Bai, Stephen Furlani, Peter Lin, Mark Hallet. "Classifying eeg signals preceding right hand, left hand, tongue and right foot movements and motor imageries", *Clinical Neurophysiology*, vol. 119, no. 11, págs. 2570 - 2578, 2008
- [6] B. O. Peters, G. Pfurtscheller, G. Edlinger. "Automatic differentiation of multichannel eeg signals", *IEEE Transactions on Biomedical Engineering*, vol. 48, no. 1, 2001
- [7] B. Blankertz, G. Dornhege, C. Schafer, R. Krepki, J. Kohlmorgen, K. R. Muller, F. Losch, V. Kunzmann, G. Curio. "Boosting bit rates and error detection for the classification of fast-paced motor commands based on single-trial eeg analysis", *IEEE Transactions Neural Systems Rehabilitation Engineering*, vol. 11, no. 127, 2003
- [8] M. Krauledat, G. Dornhege, B. Blankertz, F. Losch, G. Curio, K. R. Muller. "Improving speed and accuracy of brain-computer interfaces using readiness potential features", *Engineering in Medicine and Biology Society*, págs. 4511 - 4515, 2004
- [9] Everitt, B. S. "Cambridge Dictionary of Statistics", *Cambridge University Press*, 2<sup>a</sup> ed., 2002

- 
- [10] Benjamin Blankertz, Ryota Tomioka, Steven Lemm, Motoaki Kawanabe, Klaus-Robert Müller. "Optimizing Spatial Filters for Robust EEG Single-Trial Analysis", *IEEE signal processing magazine*, Vol. XX, 2008
- [11] Paul L. Nunez, Ramesh Srinivasan, Andrew F. Westdorp, Ranjith S. Wijesinghe, Don M. Tucker, Richard B. Silberstein, Peter J. Cadusch "EEG coherency I: statistics, reference electrode, volume conduction, Laplacians, cortical imaging, and interpretation at multiple scales", *Electroencephalography and clinical Neurophysiology*, no. 103, págs. 499 - 515
- [12] Herbert Ramoser, Johannes Müller-Gerking, and Gert Pfurtscheller. "Optimal Spatial Filtering of Single Trial EEG During Imagined Hand Movement", *IEEE Transactions on rehabilitation engineering*, vol. 8, no. 4, 2000
- [13] G. Pfurtscheller, C. Neuper "Event-related synchronization of mu rhythm in the EEG over the cortical hand area in man", *Neuroscience Letters*, vol. 147, no. 1, págs. 93 - 96, 1994
- [14] S. Waldert, H. Preissl, E. Demandt, C. Braun, N. Birbaumer, A. Aertsen, C. Mehring. "Hand movement direction decoded from meg and eeg", *J. Neuroscience*, vol. 28, no. 4, págs. 1000 - 1008, 2008
- [15] Carmen Vidaurre. "Clasificación de componentes frecuenciales", Machine Learning Laboratory, Berlin Institute of Technology.
- [16] Benjamin Blankertz, Steven Lemm, Matthias Treder, Stefan Haufe, Klaus-Robert Müller. "Single-trial analysis and classification of ERP components - A tutorial", *NeuroImage*. 2010
- [17] J. B. Copas "Regression , prediction and shrinkage", *Journal of the Royal Statistical Society. Series B (Methodological)*, vol. 45, no. 3, págs. 311 - 354, 1983
- [18] Jerome H. Friedman. "Regularized Discriminant Analysis", *Journal of the American Statistical Association*, vol. 84, no. 405, págs. 165 - 175, 1989.
- [19] Jia Li. "Linear Discriminant Analysis", Department of Statistics, The Pennsylvania State University.
- [20] Jia Li. "Regularized Discriminant Analysis and Reduced-Rank LDA", Department of Statistics, The Pennsylvania State University.
- [21] Christopher M. Bishop. "Machine Learning and Pattern Recognition", Ed. Springer, 2ª ed., págs 101-135

- 
- [22] Julianne Schäfer, Korbinian Strimmer. "A Shrinkage Approach to Large-Scale Covariance Matrix Estimation and Implications for Functional Genomics", *Statistical Applications in Genetics and Molecular Biology*, vol. 4, art. 32, 2005.
- [23] Eduardo López-Larraz, Iñaki Iturrate, Luis Montesano, Javier Mínguez "Real-Time Recognition of Feedback Error-Related Potentials during a Time-Estimation Task", *International Conference of the IEEE Engineering in Medicine and Biology Society*, 2010.