

Proyecto Final de Carrera
Ingeniería de Telecomunicación
Curso 2010-2011

Decodificación de los objetivos finales (3D) del movimiento del brazo en tareas de alcance a partir de potenciales de movimiento anticipatorio para EEG Brain Computer Interface

Eduardo Mariano Horna Prat

Septiembre de 2011

Director: Javier Mínguez Zafra
Co-director: Luis Montesano

Departamento de Informática e Ingeniería de Sistemas
Escuela de Ingeniería y Arquitectura
Universidad de Zaragoza

Por ti, que viste empezar mi sueño
y ahora vives en mí

Decodificación de los objetivos finales (3D) del movimiento del brazo en tareas de alcance a partir de potenciales de movimiento anticipatorio para EEG Brain Computer Interface

RESUMEN

La recuperación y rehabilitación de personas con deficiencias motoras ha sido objeto de numerosas investigaciones desde diversos campos de la ciencia. Dentro de los sistemas BCI (Brain Computer Interface) se han desarrollado estudios enfocados a la recuperación de la habilidad motora del brazo a través de la información extraída del EEG de manera no invasiva. Gracias a este tipo de sistemas podemos establecer un canal de comunicación entre el cerebro de un sujeto y una computadora para realizar tareas controladas directamente por la mente. En este trabajo se estudia la capacidad de decodificar los puntos objetivo del movimiento del brazo en un entorno 3D a través de potenciales EEG anticipatorios al movimiento.

Hasta el momento la mayoría de investigaciones se han centrado en el ámbito de las 2D (alcanzar en un plano) o en 3D (con profundidad) pero con movimientos no autoiniciados (respuestas a estímulos visuales). Los seres humanos nos desenvolvemos en un entorno en tres dimensiones, por lo que resultaría interesante poder conseguir una decodificación de la intención de alcanzar un punto en un entorno 3D (no sólo un plano sino también con profundidad) y además que este movimiento sea autoiniciado por el usuario, lo que supondría una situación más realista de cómo actúa una persona sin deficiencia motora en el brazo, ya que la intención de mover el brazo no responde a un estímulo sino que depende únicamente del deseo del sujeto de mover la extremidad.

Con este objetivo se propone desarrollar un sistema que permita identificar el objetivo final del movimiento del brazo de un sujeto entre un conjunto finito de 8 puntos objetivo en un espacio 3D utilizando para ello el EEG grabado simultáneamente con las tareas de alcance del brazo a seis voluntarios. La señal EEG previa al inicio del movimiento será en primer lugar filtrada, para una posterior extracción de características que nos permita una clasificación final del punto objetivo al que el sujeto movía el brazo. Esta información podría ser utilizada en el campo de la robótica (brazo robótico) o de la neurorehabilitación para mejorar la capacidad de movimiento de personas con alguna deficiencia motora del brazo.

La eficiencia del sistema será evaluada con los mismos datos *off-line* tomados del EEG grabado a los distintos sujetos que se sometieron al experimento llevado a cabo en la Universidad de Zaragoza, y mediante la técnica de *cross-validation*.

Índice

1. Introducción	1
1.1. Contexto	1
1.2. Estado del arte	1
1.3. Motivación	2
1.4. Objetivo y Alcance del proyecto	2
1.5. Organización	4
1.6. Herramientas	4
2. Experimento y toma de datos	5
2.1. Introducción	5
2.2. Montaje experimental	5
2.3. Adquisición de los datos	7
2.4. Señal EEG	8
2.4.1. Origen fisiológico	8
2.4.2. Preprocesamiento de los datos	9
3. Filtrado	11
3.1. Introducción	11
3.2. Filtro bipolar	11
3.3. Suavizado y rectificado	13
3.4. Patrones Espaciales Comunes (CSP)	13

4. Características	15
4.1. Introducción	15
4.2. Cálculo de características	15
4.2.1. Modelo AR	16
4.2.2. Banco de filtros	17
4.2.3. Periodograma de la señal completa	19
4.2.4. Periodograma de la señal filtrada en ritmo <i>alpha</i>	20
4.2.5. Resampleo	20
4.2.6. Transformada discreta wavelet	21
4.2.7. Momentos de la densidad espectral de potencia	22
4.3. Organización y normalización	23
4.4. Búsqueda de las mejores características	24
5. Clasificación	27
5.1. Introducción	27
5.2. Clasificadores	27
5.2.1. Análisis de discriminación lineal (LDA)	28
5.2.2. Máquinas de soporte vectorial (SVM)	29
5.2.3. Clasificador agregado	31
5.3. Clasificación utilizada	33
6. Resultados	35
6.1. Cross-validation	35
6.2. Trabajo previo	36
6.3. Análisis de los resultados	39
7. Conclusiones y líneas futuras	43
A. Evolución temporal	47
A.1. Hitos durante el proyecto	47

A.2. Diagrama de Gantt	48
B. Sistema BCI	49
B.1. Introducción. Sistema 10-10	49
B.2. Artefactos	51
B.3. Infraestructura	53
B.3.1. Electrodo activos	53
B.3.2. Amplificador	54
B.3.3. Gorro	55
B.3.4. Geles	55
B.3.5. Otros	55
B.3.6. Software: BCI2000	56
C. Métodos matemáticos	57
C.1. Patrones espaciales comunes (CSP)	57
C.2. Método de Burg	58
C.3. Transformada wavelet discreta (DWT)	59
C.4. Análisis de componentes principales (PCA)	60

Índice de figuras

1.1. Ejemplo trabajos con alcance en 2D.	2
1.2. Esquema desarrollo del sistema	3
2.1. Montaje experimental	6
2.2. Secuencia de ejecución del experimento	6
2.3. Electrodo utilizados	7
2.4. Ventana de EEG utilizada	8
2.5. Muestra de señal EEG.	9
3.1. Test r2 filtro bipolar	12
4.1. Modelo AR	17
4.2. Banco de filtros	18
4.3. Potencias	19
4.4. Periodograma de la señal completa	20
4.5. Periodograma de la señal filtrada en alpha	21
4.6. Resampleo	21
4.7. Transformada discreta wavelet	22
4.8. Momentos del PSD	23
4.9. Organización y normalización	24
4.10. Evolución del algoritmo de selección de características	26
5.1. LDA biclase	28

5.2. Ejemplos LDA con datos sintéticos	29
5.3. SVM biclase linear	29
5.4. Ejemplos SVM con datos sintéticos	30
5.5. Clasificador agregado	32
6.1. Particionado para cross-validation	36
6.2. Esquema evolución del proyecto	37
6.3. Trayectorias grabadas por el sistema VICON	38
6.4. Datos estimados	39
6.5. Vistas de los puntos objetivo	40
A.1. Diagrama de Gantt del proyecto.	48
B.1. Posiciones según el Sistema Internacional 10-10	50
B.2. Montaje con el Sistema Internacional 10-10.	50
B.3. Posición electrodos para al adquisición de EOG	51
B.4. Artefacto por un movimiento muscular.	52
B.5. Artefacto por un parpadeo.	53
B.6. GAMMABox y electrodos	54
B.7. Amplificador	54
B.8. Gorro	55
C.1. Coeficientes DWT de un nivel	60
C.2. Coeficientes DWT de tres niveles	60

Índice de tablas

4.1. Tabla de ritmos cerebrales	18
6.1. Tabla de resultados trabajo previo	39
6.2. Resultados con 4 puntos objetivo fijos	40
6.3. Resultados con 4 puntos objetivo variables	41
6.4. 4 mejores puntos elegidos por sujeto	41
6.5. Resultados con 8 puntos objetivo	41

1. Introducción

1.1. Contexto

Este proyecto fin de carrera se ha llevado a cabo en colaboración con el Instituto de Investigación en Ingeniería de Aragón (I3A) y el Departamento de Informática e Ingeniería de Sistemas (DIIS) de la Universidad de Zaragoza. El desarrollo del proyecto se ha realizado dentro del grupo de investigación sobre Brain Computer Interfaces (BCI) dedicado al estudio de aplicaciones basadas en el procesamiento de la señal de EEG.

1.2. Estado del arte

Las interfaces cerebro-computador son una rama de investigación científica moderna, la cual evoluciona muy rápidamente ya que el número de grupos de investigación sobre la materia está creciendo día tras día. Con la ayuda de esta tecnología se están proponiendo sistemas que repongan habilidades con las que cuenta cualquier sujeto sano para personas con deficiencias neuro-motoras, ya sea por la pérdida de la extremidad, o un problema en el sistema nervioso entre cerebro y extremidad. Este trabajo se centra en el brazo derecho y está englobado en un proyecto ambicioso que soportaría la recuperación de una extremidad que operara de la misma forma que opera un brazo de una persona sin deficiencia motora.

Este proyecto estudia la decodificación de puntos finales de movimientos de alcance con el brazo derecho. Hasta el momento la mayoría de investigaciones se centraban en el ámbito de las 2D (alcanzar en un plano) o en 3D (con profundidad) pero con movimientos no autoiniciados. Como ejemplo de los primeros podemos poner los estudios [1] [2] donde un sujeto alcanzaba puntos en un plano que eran indicados mediante un estímulo visual. En el primer experimento se utilizaban 3 objetivos (centro, derecha, izquierda). La decodificación del objetivo a alcanzar se hacía mediante el estudio de los potenciales EEG de la corteza parietal posterior en la fase de planificación del movimiento. Se obtuvieron unos porcentajes de acierto del 80 %. En el segundo de ellos se alcanzaban 4 puntos (esquinas de la pantalla). Usando los potenciales EEG anticipatorios al movimiento, los resultados fueron de un 57 % de aciertos. Como ejemplo de movimiento no autoiniciado en 3D te-

nemos [2] donde el usuario alcanzaba uno de los 3 objetivos fijos en el espacio que le era indicado por la iluminación de un LED en el punto a alcanzar. Los resultados en este caso fueron de un 60 % de aciertos, de nuevo usando datos de planificación del movimiento.

1.3. Motivación

Si la intención futura es crear un brazo artificial que se comporte como uno humano se tiene que tener en cuenta las condiciones en las que opera el mismo.

La capacidad de alcanzar puntos en un plano es una gran avance, pero un brazo real alcanza puntos en un entorno 3D. Por lo tanto en este estudio se propone un entorno con 8 puntos objetivos distribuidos en el espacio. En segundo lugar los estudios anteriores tienen como máximo 4 puntos objetivo por lo que en este trabajo se busca ampliar la libertad de movimiento del sujeto, lo que implica una mayor dificultad de clasificación.

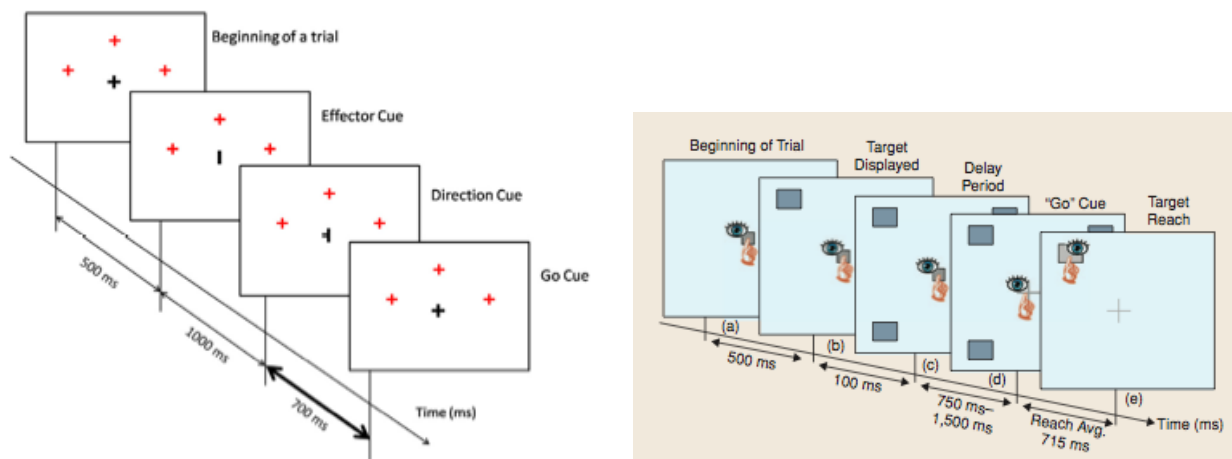


Figura 1.1: Experimento con 3 objetivos en un plano [1] (Izquierda). Experimento con 4 objetivos en un plano [2] (Derecha).

Por otro lado la decisión de mover el brazo es propia del sujeto por lo que tomar los datos como respuesta a un estímulo no es la situación común de un sujeto sano. Por ello en este trabajo se emplearán los potenciales EEG anticipatorios al movimiento ya que de esta manera sólo con pensar en querer mover el brazo hasta uno de los ocho puntos, el sistema será capaz de decidir cuál de ellos quería alcanzar el sujeto.

1.4. Objetivo y Alcance del proyecto

El objetivo de este proyecto fin de carrera es el desarrollo de un sistema que nos permita decodificar la intención de movimiento del brazo para alcanzar uno de los 8

puntos objetivo a través del análisis de la señal EEG registrada del sujeto y determinar de este modo hacia qué punto quiere dirigir el brazo el usuario.

Para ello se llevará a cabo un proceso de tratamiento de la señal que nos permitirá una clasificación más precisa del punto elegido por el sujeto. En este proceso se utilizarán técnicas de filtrado espacial [3] [4] así como la extracción de características relevantes de la señal EEG [5]. A continuación se diseñará un clasificador que utilice la información anterior para determinar el punto objetivo que se intenta alcanzar. Por último se validará el sistema para comprobar la eficiencia del mismo.

Este proceso se expone en la figura 1.2 donde se muestra que la toma de datos de la señal EEG no forma parte de este proyecto sino que fue realizada como parte de otro experimento llevado a cabo en la Universidad de Zaragoza. Las distintas partes del sistema serán explicadas a lo largo de esta memoria del modo comentado en el apartado 1.5:

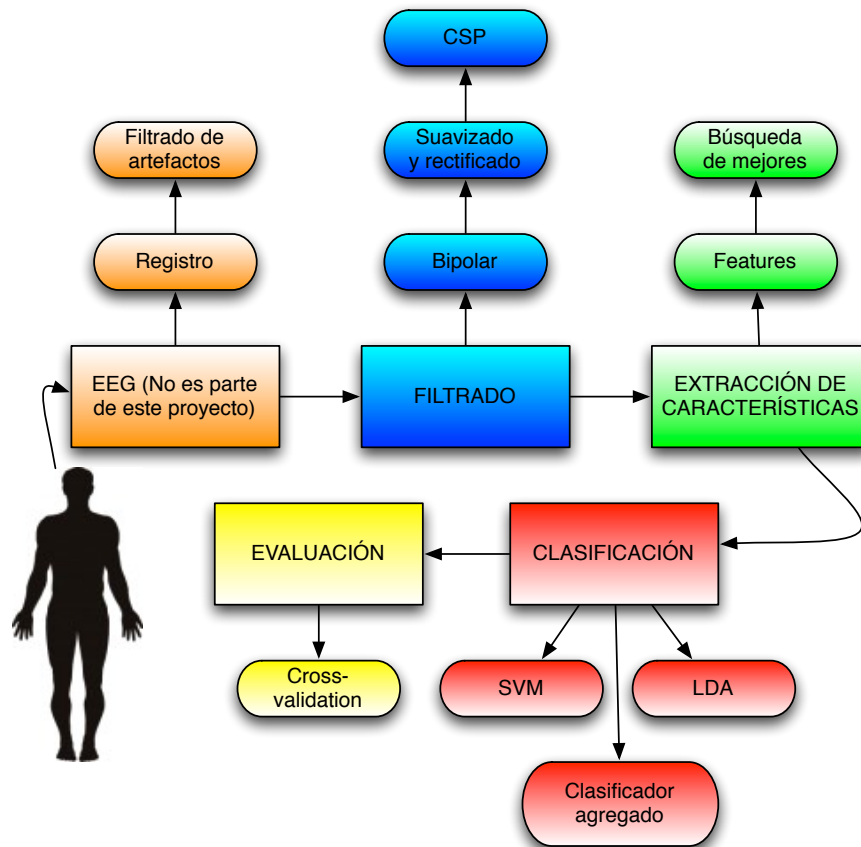


Figura 1.2: Partes en las que se divide el sistema de decodificación del punto objetivo del movimiento de alcance diseñado.

1.5. Organización

Esta memoria esta organizada en siete capítulos, de los cuales este primero es el de introducción donde se presenta la motivación y objetivo del proyecto. A partir del capítulo 2 y hasta el capítulo 6 se explicarán de forma detallada cada una de las partes expuestas en la figura 1.2:

- **Capítulo 2 Experimento y toma de datos:** en esta sección se explicará el experimento llevado a cabo para la toma de datos así como el preprocesado ejecutado anteriormente a la realización de este proyecto. También se comentan los conceptos básicos de la señal EEG registrada.
- **Capítulo 3 Filtrado:** en el mismo se presentan los diferentes filtros utilizados para adecuar la señal para su posterior tratamiento.
- **Capítulo 4 Características:** en este apartado se presenta la extracción, organización y normalización de las características de la señal previamente filtrada que serán utilizadas para la posterior clasificación.
- **Capítulo 5 Clasificación:** se presentan los métodos de clasificación utilizados tanto para nuestro sistema como para un apartado previo al proyecto que sirvió como introducción a la clasificación de datos.
- **Capítulo 6 Resultados:** por último se presenta el método de evaluación de los resultados del proyecto (incluido el trabajo previo) así como una discusión acerca de los mismos

Por último para concluir la memoria se presentan en el capítulo 7 las conclusiones del estudio así como las propuestas de posibles lineas futuras para ahondar en el problema.

1.6. Herramientas

Para la ejecución del presente proyecto se utilizó la herramienta matemática MATLAB[®] desarrollada por Mathworks. Los datos con los que se trabajó ya estaban registrados en varios ficheros .mat a partir de las cuales se trabajó. El registro de los datos es explicado en el capítulo 2 de esta memoria.

2. Experimento y toma de datos

2.1. Introducción

En este capítulo se explica el experimento que se llevó a cabo para la obtención de los datos con los que se trabaja en el proyecto, la adquisición de los mismos y se describe la señal encefalográfica con la que se trabajará. En la sección 2.2 se presenta el montaje experimental, explicando el procedimiento que siguieron los sujetos para la toma de los datos que posteriormente se han analizado. Los medios utilizados para la adquisición de la señal se encuentran en la sección 2.3. Por último se hace un resumen de la señal EEG, comentando su naturaleza y origen fisiológico así como sus características temporales y frecuenciales en la sección 2.4.1 y el preprocesamiento de la señal en 2.4.2.

2.2. Montaje experimental

Siete hombres diestros de la Universidad participaron voluntariamente en los experimentos (con edades comprendidas entre los 25 y 32 años) después de que el protocolo fuera aprobado por el Comité de Revisión Institucional de la Universidad de Zaragoza. Este experimento fue realizado antes del comienzo de este proyecto.

Los sujetos se sentaron en una silla confortable delante del montaje experimental (Figura 2.1). Como se puede ver, el montaje contaba con una serie de posiciones fijas y conocidas en el espacio (3D) que estaban divididas en 8 puntos objetivo y en un punto inicial o de reposo. La mínima y la máxima distancia desde el punto inicial hasta el punto objetivo más cercano y más lejano era de 10 cm. y 50 cm. respectivamente. El proceso era el siguiente:

- Antes de iniciar el movimiento el sujeto hacía una selección mental durante aproximadamente 2 segundos (preparación del movimiento o movimiento anticipatorio).
- A continuación los sujetos recibieron la instrucción de mover el brazo derecho desde este punto inicial fijo hasta un punto objetivo entre los ocho posibles, siendo este movimiento autoiniciado por el sujeto (sin estímulo externo).

- Por último el sujeto colocaba de nuevo el brazo en el punto inicial fijo.




Figura 2.1: Sujeto sentado frente al montaje experimental

Este proceso se desarrollaba cada 7.5 segundos en media (mínimo 2.8 y máximo 9.7 segundos). Como veremos en la sección 2.4 la amplitud de la señal EEG es muy pequeña por lo que se ve afectada considerablemente por parpadeos o movimientos musculares (ver Anexo B.2). Por ello durante la operación de alcanzar el punto objetivo, se les pidió a los sujetos que mantuvieran una postura natural, relajada y constante; para minimizar el parpadeo, los sujetos mantenían la vista fija en el punto correspondiente del montaje. Durante el resto del tiempo se les permitía parpadear y relajarse.

El experimento se llevó a cabo en cinco bloques de cinco minutos cada uno, donde los sujetos ejecutaron alrededor de 130 operaciones de alcanzar uno de los 8 puntos objetivo (al final del EEG registrado se quedó con un mínimo de 75 realizaciones y un máximo de 196, después de eliminar los ejemplos no válidos). En la figura 2.2 podemos observar la secuencia que se repitió durante el experimento.

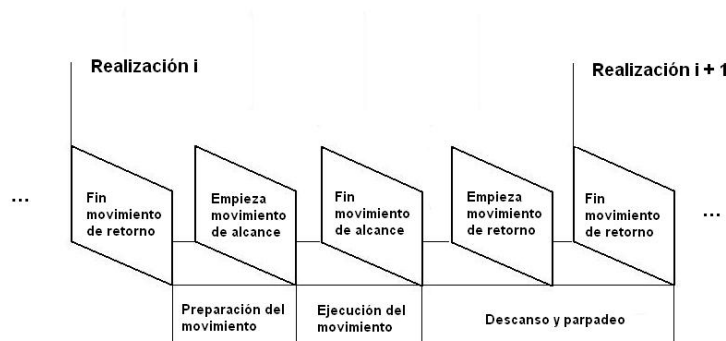


Figura 2.2: Secuencia temporal de la ejecución del movimiento

2.3. Adquisición de los datos

La actividad EEG fue registrada con un sistema gTec (2 amplificadores sincronizados gUSBamp) con 28 electrodos distribuidos de acuerdo con el sistema internacional 10/10 (Figura 2.3), la tierra en FPz y la referencia en el lóbulo de la oreja izquierda. También se tomaron los datos del EOG vertical y horizontal. Las señales EEG y EOG fueron digitalizadas con una frecuencia de muestreo de 256 Hz. Además se eliminó el efecto de la corriente eléctrica con un filtro elimina-banda entre 49 y 51 Hz. y los datos se filtraron paso-bajo con una frecuencia de corte de 60 Hz. Se puede encontrar más información acerca de los aparatos utilizados en el anexo B.3 y sobre el sistema internacional 10/10 y EOG en el anexo B.1




Figura 2.3: Mapa craneal con la posición de los electrodos utilizados para la adquisición de la señal EEG

Simultáneamente, los datos cinemáticos 3D del brazo fueron registrados con un sistema de captura de movimiento VICON basado en video que guardaba las posiciones en el espacio de los distintos marcadores pegados al cuerpo como se puede ver en la figura 2.1. Estos datos de las posiciones sólo serán utilizados para el trabajo previo al propio proyecto explicado en esta memoria.

Aparte de las medidas de EEG y de movimiento, el sistema también registraba marcadores temporales correspondientes al principio y al final de cada acción de alcanzar un punto objetivo. Esta información se obtuvo haciendo uso de botones en los puntos inicial y objetivo y fue sincronizada con las medidas del EEG. Gracias a estos marcadores podemos elegir los datos de todo el registro de EEG con los que queremos trabajar. En este trabajo se utilizó una ventana de 300 milisegundos justo antes del comienzo del movimiento del brazo (Figura 2.4). De esta forma tomamos datos de preparación de movimiento o movimiento anticipatorio para introducirlos a nuestro sistema. Trabajar con estos datos nos permite simular lo que sería una situación real donde un sujeto pensaría en mover el brazo hasta un punto y sólo con esa información del EEG seríamos capaces de decodificar el punto objetivo que se quería alcanzar.

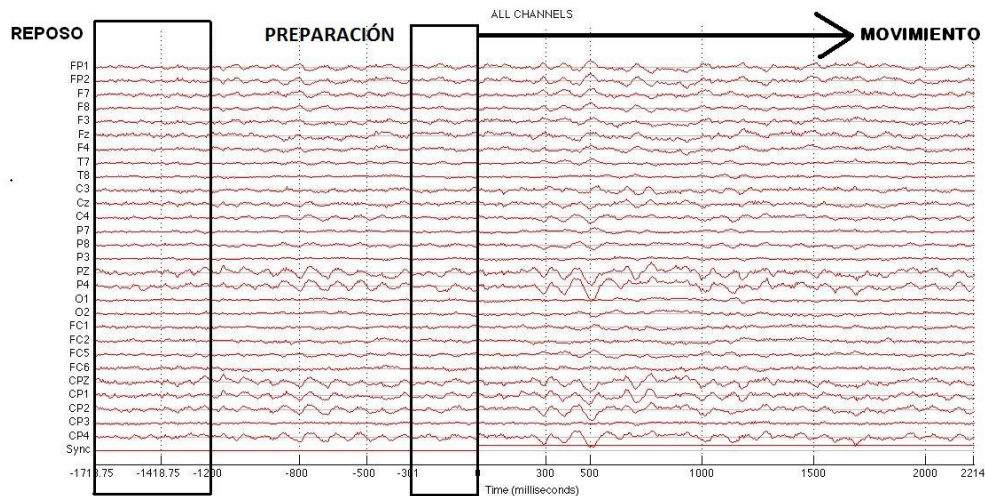


Figura 2.4: Ventana de datos utilizados durante el desarrollo del proyecto

2.4. Señal EEG

2.4.1. Origen fisiológico

El electroencefalograma (EEG) consiste en el registro no invasivo de la actividad eléctrica cerebral mediante una serie de electrodos colocados en la superficie del cuero cabelludo. Al conjunto de la actividad eléctrica se le conoce como ritmo debido a su comportamiento oscilatorio. Concretamente la actividad de una sola neurona cortical no puede ser medida debido al grosor de las capas de tejido (fluidos, huesos y piel) que componen la corteza cerebral y que provocan una atenuación de la señal propagada por el electrodo. Sin embargo la actividad conjunta de millones de neuronas corticales, localizadas a una profundidad de varios milímetros, producen un campo eléctrico suficientemente fuerte para ser medido en la superficie cerebral, siendo esta profundidad dependiente de la potencia de la fuente neuronal. El campo eléctrico es principalmente generado por corrientes que fluyen durante excitaciones sinápticas¹ de las dendritas², la excitación post-sináptica. La diversidad de ritmos EEG es inmensa y depende, entre otras cosas, del estado mental del sujeto (grado de atención, de relajación, etc). Los ritmos están convencionalmente caracterizados por:

- **La amplitud de EEG:** está relacionada con el sincronismo con el cual las neuronas de la corteza cerebral interaccionan. Una excitación sincronizada produce una señal

¹Sinapsis: unión intercelular producida por una descarga química que origina una corriente eléctrica en la membrana de la célula sináptica (emisora) una vez que este impulso alcanza el extremo del axón la propia neurona segrega neurotransmisores.

²Dendrita: Prolongación ramificada de una célula nerviosa, mediante la que esta recibe estímulos externos

de mayor amplitud medible en el cuero cabelludo ya que las señales originadas por cada neurona se suman de forma coherente en fase produciendo como resultado una señal de amplitud elevada. Por el contrario, una excitación asíncrona de las neuronas provoca un EEG irregular de baja amplitud. La amplitud es variable, de 20-60 μV (50 μV por término medio).

- **La frecuencia de EEG:** viene definida por el comportamiento rítmico de las interacciones coordinadas de activación de las neuronas de la corteza. [6]

En la actualidad, el registro de EEG se lleva a cabo mediante la colocación de un gorro sobre el cuero cabelludo, en el cual se colocan un conjunto de electrodos. La disposición de los electrodos sobre el cuero cabelludo sigue el estándar descrito por el Sistema Internacional 10-10 o 10-20, ver en anexo B.1. Cada par de electrodos registra las variaciones de potencial eléctrico definiendo un canal de EEG. Cada una de estas señales son amplificadas mediante el uso de una amplificador diferencial previo a la etapa de digitalización. La figura 2.5 representa una muestra de encefalograma compuesta por 16 canales. Tal y como se observa, la señal es segmentada en fragmentos temporales denominados *epochs* (divididos por líneas verticales en la figura).

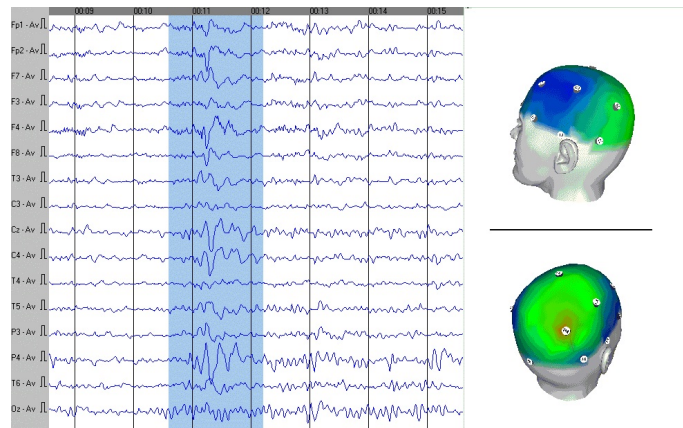


Figura 2.5: (Izquierda) Ejemplo de señal EEG adquirida sobre 16 posiciones del cuero cabelludo. Cada fila representa un canal. (Derecha) Representación visual en forma de mapa de color de la zona sombreada en la imagen izquierda

2.4.2. Preprocesamiento de los datos

Todas las realizaciones fueron visualmente inspeccionadas y se descartaron aquellas que a simple vista se observaban ruidosas. La señal EEG puede ser fácilmente contaminada ya que como hemos comentado en la sección anterior se trata de una señal muy débil. Para eliminar los artefactos (posibles artefactos explicados en anexo B.2) y actividad que no pertenezca a la señal EEG se utilizó el procedimiento de Análisis de Componentes Independientes (ICA *Independent Component Analysis*) el cual busca las componentes

independientes en las que se puede separar una señal [7]. Para ello se concatenó todas las realizaciones de EEG y las componentes ICA fueron calculadas mediante el algoritmo *fastICA* [8]. A continuación fue dibujada la distribución de cada componente sobre el cráneo y las señales eléctricas generadas. Todas las componentes ICA que generaban actividad cerebral no eléctrica fueron indentificadas por inspección visual y no fueron consideradas para devolver los datos libres de artefactos. Matemáticamente se puede expresar de este modo:

$$ICA_{comp} = W * EEG$$

$ICA'_{comp} = ICA_{comp}$ *sustituyendo por ceros las filas que no representan señales EEG*

$$EEG_{filtrado} = W^{-1} * ICA'_{comp}$$

Este proceso fue realizado antes de la ejecución de este proyecto por lo que los datos con los que se trabajó en el mismo fueron los que resultaron después de utilizar el procesado ICA.

3. Filtrado

3.1. Introducción

El esquema general de los sistemas cerebro computador como hemos comentado antes se puede resumir en preprocesado de la señal, extracción de características y clasificación. En el presente capítulo se exponen los diferentes filtros por los que pasa la señal, es decir, la parte de preprocesado de la señal anterior a la extracción de características

Está dividido en tres partes que coinciden con los tres filtros que son realizados en el procesamiento de los potenciales de EEG. En la sección 3.2 se presenta qué es un filtro bipolar, la elección del mismo y su utilidad. A continuación se comenta el filtro de suavizado y rectificado en la sección 3.3. En el último subapartado de este capítulo se explicarán los filtros espaciales CSP (Common Spatial Pattern) y su utilización en este proyecto.

3.2. Filtro bipolar

En este proyecto se trabaja con datos de movimiento del brazo derecho. Se conoce de estudios previos que la actividad cerebral motora del brazo derecho del cuerpo se centra en torno al electrodo C3 [9] que se encuentra situado en el hemisferio opuesto a la extremidad si se trata de una persona contralateral (la mayor parte de las personas) o en torno al electrodo C4, en el hemisferio derecho, si se trata de un sujeto ipsilateral.

Por ello a la hora de plantear el filtrado de la señal antes de la extracción de características, se valoró la idea de colocar un filtro bipolar con respecto a dicho electrodo. Básicamente el filtrado bipolar consiste en referenciar el resto de canales con respecto al electrodo elegido. Esta técnica es utilizada en sistemas BCI y puede constituir una mejora de la calidad de las características calculadas a posteriori. El proceso que se llevó a cabo en los datos fue el siguiente: a cada canal de cada realización se le sustrajo el valor de la señal EEG del electrodo C3. Para cada realización:

Sea X_{EEG} la señal libre de artefactos que tendrá un tamaño de 28×78 (28 filas correspondientes a cada uno de los canales y 78 muestras debido a que se toma una

ventana de 300ms. y se muestrea con una frecuencia de 256 Hz. $\rightarrow 0,3 * 256 \simeq 78$), sea X_{C3} una matriz de 28 filas (tantas como canales) con la señal del electrodo C3 en todas ellas (78 muestras):

$$X_{bip} = X_{EEG} - X_{C3}$$

Por lo tanto el resultado será la señal filtrada X_{bip} que tendrá un tamaño de 28×78 , pero que obviamente contendrá una fila de ceros que no aportan nada de información. Por lo tanto dicha fila será eliminada y quedará entonces una matriz de 27×78 . Podemos comprobar el efecto de este filtro usando para ello el test r^2 , también conocido como coeficiente de determinación, que nos permite conocer una idea de la proporción de variabilidad del conjunto de datos. Existen varias definiciones del coeficiente de determinación. En el presente proyecto se tomará como el cuadrado del coeficiente de correlación:

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}}$$

Como ejemplo podemos mostrar la figura 3.1 donde se observa cómo después de utilizar el filtro bipolar especificado aumentamos la separabilidad del periodograma de los datos que se dirigen a dos puntos objetivos distintos, apreciando la dificultad del problema que intentamos resolver dando lugar a bajos valores de r^2 que aumentamos al utilizar el filtro. Como veremos en el capítulo 4 el periodograma es una de las características que queremos calcular.

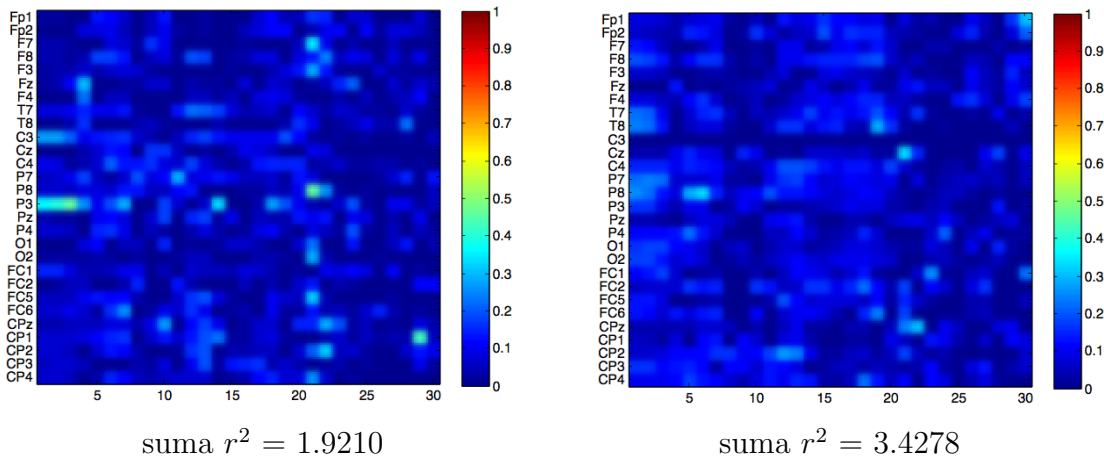


Figura 3.1: Test r^2 antes y después del filtro bipolar en C3 con el periodograma de la señal de los datos de dos puntos objetivo distintos

3.3. Suavizado y rectificado

Como parte del preprocesado de la señal se llevan a cabo otras dos operaciones de preprocesado. En primer lugar se hacen pasar los datos por un filtro de media móvil que produce un efecto de suavizado en la señal que ha sido registrada y nos permite tener una señal más limpia que la que teníamos en un principio.

Sea $X_{suav} = suavizado(X_{bip})$, donde suavizado significa para cada canal de cada realización:

$$\begin{aligned} X_{suav}(1) &= X_{bip}(1) \\ X_{suav}(2) &= (X_{bip}(1) + X_{bip}(2) + X_{bip}(3))/3 \\ X_{suav}(3) &= (X_{bip}(1) + X_{bip}(2) + X_{bip}(3) + X_{bip}(4) + X_{bip}(5))/5 \\ X_{suav}(4) &= (X_{bip}(2) + X_{bip}(3) + X_{bip}(4) + X_{bip}(5) + X_{bip}(6))/5 \\ &\dots \end{aligned}$$

Por otro lado se procede a la rectificación de la señal de forma que en el futuro podamos trabajar tanto como la señal no rectificada, es decir X_{suav} como con la señal rectificada X_{rect} . Este filtro de rectificación simplemente consiste en tomar el valor absoluto de la señal.

$$X_{rect} = |X_{suav}|$$

3.4. Patrones Espaciales Comunes (CSP)

Los patrones espaciales comunes han sido objeto de numerosos estudios en los últimos años [3] [4] [10]. Se ha demostrado su utilidad en diversas aplicaciones de interfaces cerebro-computador relacionadas con el movimiento. Por ello se ha considerado la posibilidad de implementar un filtro CSP en este proyecto. Con este tipo de filtro espacial se pretende maximizar la varianza de los datos pertenecientes a una clase al mismo tiempo que se minimiza la varianza de las otras clases. De esta forma se pretende conseguir una mejor diferencia estadística entre los datos de las clases que se pretende separar en la futura clasificación. En el presente proyecto se cuenta con más de dos clases (cada uno de los puntos objetivo es una clase) por lo que el algoritmo usa la técnica de uno contra el resto. La explicación del método se encuentra ampliada en el anexo C.1

$$\text{Sea } X_{rect} = C * X_{CSP} \Rightarrow X_{CSP} = C^{-1} * X_{rect}$$

X_{CSP} tiene un tamaño de 27×78 y está ordenada desde la fila con mayor varianza entre las clases (fila 1) hasta la que presenta una menor varianza (fila 27).

4. Características

4.1. Introducción

Una vez que la señal ha sido registrada y convenientemente filtrada se procede al cálculo de las características de la misma que permitirán posteriormente proceder a una clasificación para determinar los puntos objetivos a los que se dirigía el sujeto en cada una de las realizaciones. Esta sección va estar dividida en tres partes. En primer lugar (apartado 4.2) se comentarán cada una de los 8 bloques de características que son extraídas de la señal EEG explicando el motivo de su cálculo y la forma de hacerlo. Posteriormente se expondrá la forma en la que se estructuran los datos obtenidos del cálculo de las características para su normalización (sección 4.3). Por último, en la sección 4.4, se comentará el proceso mediante el cual se realizó una búsqueda automática de las mejores características entre todas las calculadas.

4.2. Cálculo de características

Una vez que los datos EEG han sido filtrados tal como se indicaba en el capítulo anterior empieza la tarea de procesamiento de la señal para conseguir extraer la información relevante que transporta el EEG. Esta es una de las tareas principales en estos tipos de sistemas ya que para afrontar problemas con interfaces cerebro-computador se presupone que la señal EEG contiene la información que queremos obtener pero debemos ser capaces de aislarla adecuadamente. Por ello la literatura acerca de extracción de características es amplia y sigue siendo objeto de numerosos estudios [5] [2] [11]. En este trabajo se eligió la extracción de ocho bloques de características diferentes que permitieran tener una información amplia acerca de la señal estudiada. Para ello se propuso una mezcla de características que comprendiesen la exploración del EEG tanto desde el dominio temporal como desde el frecuencial además de la obtención de información temporal-frecuencial. Con la obtención de estos conjuntos de características se pretende conseguir los datos necesarios y relevantes, es decir, extraer la información necesaria para una posterior clasificación correcta de los objetivos finales que es lo que se busca en este proyecto.

Por lo tanto se procederá a continuación a explicar cada una de estas ocho grupos de

características que son extraídas de la señal EEG ya debidamente filtrada y preprocesada.

4.2.1. Modelo AR

El modelo autoregresivo (*autoregressive model*(AR)) es también conocido en la teoría del diseño de filtros como un filtro de respuesta impulsional infinita (IIR) o como un filtro todo polos y es a veces denominado modelo de máxima entropía en aplicaciones físicas. La definición que se utilizará para nuestros cálculo viene determinada por la ecuación:

$$X_t = \sum_{i=1}^N \varphi_i X_{t-i} + \epsilon_t$$

donde los valores que nos interesan vienen marcados por los φ_i 's los cuales son denominados coeficientes de regresión, X_t se corresponderá con cada uno de los canales de cada una de las realizaciones del sujeto tratado y N es el orden del modelo que generalmente es mucho menor que la longitud de la serie. El término de ruido o residuo (ϵ_t) es casi siempre tomado como un ruido blanco gaussiano.

Si expresamos la ecuación anterior con palabras podemos decir que con un modelo AR obtenemos el término actual de la serie como una suma lineal ponderada de los valores previos de la serie. Estos pesos con los que ponderamos son los coeficientes de regresión. En la expresión anterior asumimos que las series (canales) tienen media zero por lo que no es necesario un coeficiente φ_0 delante del sumatorio.

Para calcular los coeficientes se utilizará el método de Burg que es explicado en el anexo C.2

Utilizaremos este modelo para la obtención de dos características que serán los modelos AR de orden 3 y de orden 5 de cada uno de los canales.

$$X_t = \sum_{i=1}^3 \varphi_i X_{t-i} + \epsilon_t$$



$$[\varphi_1^{AR3}, \varphi_2^{AR3}, \varphi_3^{AR3}]$$

$$X_t = \sum_{i=1}^5 \varphi_i X_{t-i} + \epsilon_t$$

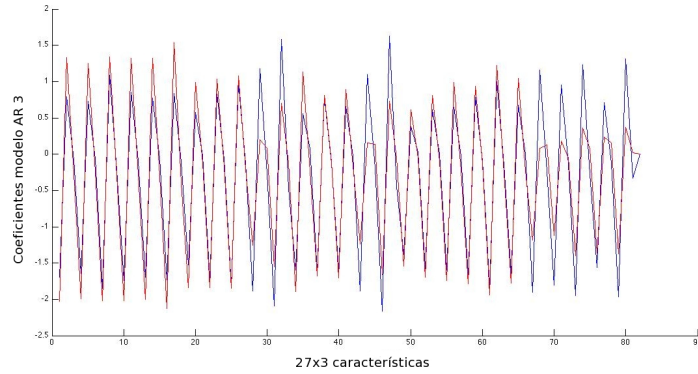


$$[\varphi_1^{AR5}, \varphi_2^{AR5}, \varphi_3^{AR5}, \varphi_4^{AR5}, \varphi_5^{AR5}]$$


Por lo tanto observamos que para cada canal de cada una de las realizaciones vamos a obtener un conjunto de tres características que corresponden con las obtenidas en el modelo AR de orden 3 y otro vector de cinco características correspondiente con el modelo de orden 5. La elección de estos órdenes para los modelos se debe a lo leído en la literatura

acerca de la extracción de características. El tamaño final para cada realización de cada sujeto será de 27×3 en el caso del modelo AR 3 y de 27×5 en el caso del de orden 5. Hay que recordar que no tenemos 28 canales ya que al pasar el filtro bipolar hemos eliminado la fila que quedaba a ceros.

Si representamos gráficamente esta característica (figura 4.1) podemos observar cómo conseguimos una diferenciabilidad entre los puntos objetivo. No hay que olvidar que es nuestro objetivo final y el porqué de la extracción de las características.



a)



b)

Figura 4.1: Representación gráfica de los coeficientes (27×3) o (27×5) extraídos del modelo AR (de orden 3 a), de orden 5 b)) de dos realizaciones del sujeto 5 dirigidas a puntos objetivo distintos

4.2.2. Banco de filtros

La actividad eléctrica cerebral es normalmente conocida como ritmo porque las señales medidas a menudo presentan un comportamiento oscilatorio y repetitivo como hemos podido comprobar en la figura 2.5. Los ritmos cerebrales son normalmente clasificados en cinco bandas de frecuencia diferentes. No es la única clasificación pero es la más utilizada por su utilidad clínica. Esta clasificación es la siguiente:

Ritmo	Frecuencias
Delta	< 4 Hz.
Theta	4-7 Hz.
Alpha	8-13 Hz.
Beta	14-30 Hz.
Gamma	> 30 Hz.

Tabla 4.1: Tabla de ritmos cerebrales

Para calcular el vector de características resultante, la señal (cada uno de los canales de todas las realizaciones) es filtrada por un banco de filtros cuyas frecuencias se corresponden con los ritmos cerebrales. Por lo tanto se obtienen cinco señales a la salida del banco de filtros. Una vez que tenemos estas cinco series de datos se calculó su potencia de acuerdo a la ecuación:

$$P_i = \frac{1}{N_i} \sum_{i=1}^{N_i} x_i^2 \quad i = \delta, \theta, \alpha, \beta, \gamma$$

De este modo se obtiene un vector de cinco características para cada uno de los canales lo que supone un tamaño total para cada realización de 27×5 . En la figura 4.2 podemos observar un ejemplo de las señales filtradas y cómo se calcula el vector correspondiente de características que se utilizarán para la clasificación. Podemos observar también en la figura 4.3 la diferencia entre puntos objetivo que presenta esta característica.

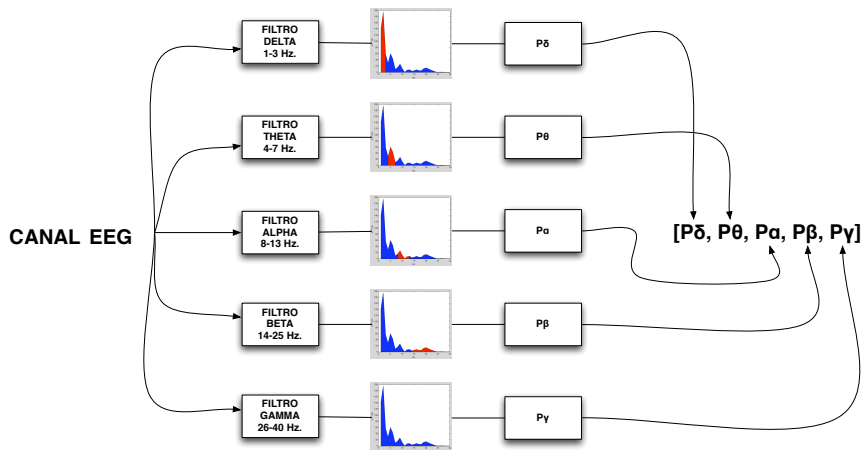


Figura 4.2: Esquema para el cálculo de las 5 características extraídas para cada canal del EEG en el banco de filtros




Figura 4.3: Representación gráfica de las potencias (27×5) extraídas del banco de filtros de dos realizaciones del sujeto 5 dirigidas a puntos objetivo distintos

4.2.3. Periodograma de la señal completa

El periodograma es una estimación de la densidad espectral de una señal o en otras palabras representa una medida de la contribución de cada frecuencia a la potencia de la señal. Es una característica que nos proporciona información en el dominio frecuencial. Existen varios métodos para el cálculo de un periodograma. En este estudio se trabaja con la siguiente expresión:

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

Se calculó para cada canal su periodograma con 128 puntos los cuales representaban desde la frecuencia 0 hasta la frecuencia 128 Hz. Como la información relevante del EEG se encuentra emplazada en valores frecuenciales por debajo de los 30 Hz. se eligió este valor como umbral para la obtención del vector de características. Como podemos ver en la figura 4.4 existe una separabilidad entre los distintos puntos objetivo.

Por lo tanto una vez que hemos cortado el periodograma obtenemos por cada canal un vector de 30 características lo que supone un tamaño final de 27×30 para cada una de las realizaciones de cada uno de los sujetos.

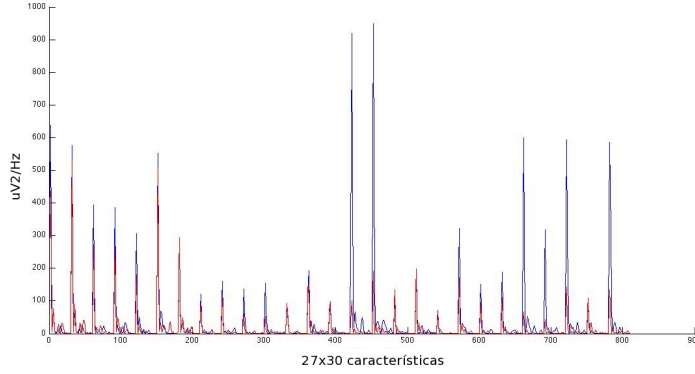


Figura 4.4: Representación gráfica de las muestras (27×30) extraídas del periodograma de dos realizaciones del sujeto 5 dirigidas a puntos objetivo distintos

4.2.4. Periodograma de la señal filtrada en ritmo *alpha*

Son numerosos los estudios que se dedican a evaluar la relación entre el ritmo cerebral *alpha* y el movimiento del brazo o la intención de movimiento del mismo [12] [13]. Los resultados conducen a la conclusión de que se producen cambios en dicho ritmo ya sea en la preparación como en el movimiento. Se puede producir una desincronización en la actividad cerebral lo que se refleja en un cambio en dicho ritmo, que como se indica en la tabla 4.1, se sitúa entre los 8 Hz. y los 13 Hz.

Por ello se consideró la extracción del periodograma de la señal filtrada en dicho ritmo que nos permite conseguir la información frecuencial en las mencionadas frecuencias. La expresión que se utilizó para el cálculo del periodograma es la mencionada en el apartado 4.2.3:

$$S(f) = \frac{1}{F_s N_\alpha} \left| \sum_{n=1}^{N_\alpha} x_{\alpha n} e^{-j(2\pi f / F_s)n} \right|^2$$

Del mismo modo que antes se compone un vector con los primeros 30 valores correspondientes a las frecuencias menores de 30 Hz. El tamaño de los datos extraídos de cada realización será por lo tanto de 27×30 . En la figura 4.5 podemos ver un ejemplo de dos periodogramas de la señal filtrada en ritmo *alpha* correspondientes a dos objetivos diferentes.

4.2.5. Resampleo

La señal EEG limpia de artefactos y preprocesada constituye el punto de partida para el cálculo de todas las características y contiene toda la información disponible del estado cerebral del sujeto. Sin embargo la dimensionalidad de la señal es elevada por lo que se

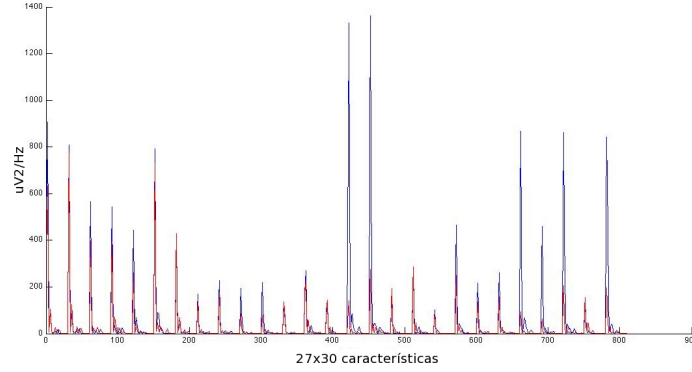


Figura 4.5: Representación gráfica de las muestras (27×30) extraídas del periodograma de la señal filtrada en ritmo alpha de dos realizaciones del sujeto 5 dirigidas a puntos objetivo distintos

propone una característica que conserve la información en el dominio del tiempo y que consiste en el *resampleo* de cada uno de los canales de forma que tengan únicamente diez muestras. Para ello se procede a una interpolación y diezmado adecuado para que la señal final tenga una longitud de diez muestras.

El vector formado por esta característica constará de diez muestras por canal formando una matriz por cada realización de tamaño 27×10 . En la figura 4.6 podemos observar la diferencia entre el vector obtenido para dos realizaciones que se dirigen a puntos objetivo distintos.




Figura 4.6: Representación gráfica de las muestras de la señal (27×10) resampleada de dos realizaciones del sujeto 5 dirigidas a puntos objetivo distintos

4.2.6. Transformada discreta wavelet

Hasta el momento las características extraídas pertenecían al dominio frecuencial o temporal por lo que se propuso obtener una característica que combinase ambas informaciones. Para ello se hizo uso de la transformada discreta wavelet que es un caso especial de

transformada de Fourier a partir de series ortogonales llamadas wavelets. La transformada se calcula por lo tanto a partir de versiones trasladadas y dilatadas de dicha wavelet en el dominio analógico. Para su conversión al mundo digital se hace uso de la transformada discreta wavelet, que calcula una serie de coeficientes como se explica en el anexo C.3 a partir de una serie de filtros en cascada. En este proyecto se hará uso de la transformada de una dimensión y tres niveles.

Una vez que se tiene calculada la transformada discreta wavelet, se resamplea a 10 muestras con el fin de reducir el número de características calculadas. Por lo tanto se obtendrá un vector de 10 características por cada canal, es decir para cada realización una matriz de 27×10 características. En la figura 4.7 podemos ver las características obtenidas para dos realizaciones que se dirigen a puntos distintos.




Figura 4.7: Representación gráfica de los coeficientes (27×10) extraídos de la transformada discreta wavelet de dos realizaciones del sujeto 5 dirigidas a puntos objetivo distintos

4.2.7. Momentos de la densidad espectral de potencia

Por último se calculan unas características relacionadas con la densidad espectral de potencia (PSD). Estas son los momentos de primer y segundo orden de la PSD que responden a las siguientes expresiones respectivamente:

$$M_1 = \frac{\sum_{i=1}^N f_i * PSD(i)}{\sum_{i=1}^N PSD(i)} \quad M_2 = \frac{\sum_{i=1}^N (f_i - \bar{f}) * PSD(i)}{\sum_{i=1}^N PSD(i)}$$

De las expresiones anteriores obtenemos dos valores por cada canal por lo que tenemos en cada realización una matriz de características de tamaño 27×2 . Podemos ver en la gráfica 4.8 las características encontradas para dos realizaciones que se dirigen a puntos objetivo distintos.

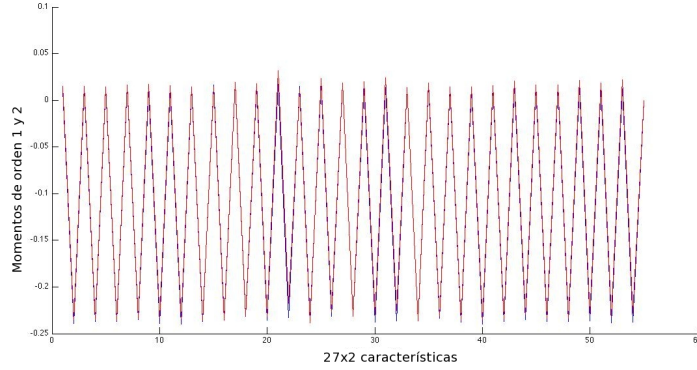


Figura 4.8: Representación gráfica de los momentos de orden 1 y 2 (27×2) de dos realizaciones del sujeto 5 dirigidas a puntos objetivo distintos

4.3. Organización y normalización

Después de calcular los ocho bloques de características mencionados anteriormente para cada uno de los 27 canales resultantes del filtro bipolar y para todas las realizaciones, se organizará como explicaremos a continuación para tener una matriz de características adecuada para su posterior normalización y la clasificación final. Todos los bloques de características serán ordenados de la misma forma de modo que el método se aplicará a cada una de ellos de forma similar. La explicación de forma gráfica se encuentra en la figura 4.9

Sea un sujeto con R número de realizaciones registradas, es decir un sujeto que ha realizado R procesos de preparación y alcance de un punto objetivo como está explicado en la sección 2.2. Por otro lado sea una característica calculada que nos da como resultado un vector de N valores por cada canal de cada realización por lo que el bloque de características tendrá un tamaño de $27 \times N$ en cada realización.

Lo que se quiere obtener al final es una clasificación de las realizaciones ya que se busca asociar a cada realización un punto objetivo, es decir se intenta decodificar a qué punto final se intentaba mover el brazo a partir de unos potenciales EEG a los que se les ha extraído la información pertinente. Por ello la primera reorganización que se realiza es la de colocar las características que corresponden a cada realización en un sólo vector. Se concatenan, por tanto, cada una de las 27 filas del bloque de características de cada realización de forma que obtenemos un vector de tamaño $1 \times (27 * N)$ muestras.

A continuación se procede a colocar cada uno de estos vectores uno debajo de otro hasta formar una matriz de características de tamaño $R \times (27 * N)$ que será la forma que estamos buscando para cada grupo de características. En esta nueva matriz cada fila representará la información de todos los canales de una realización y cada columna tendrá información similar (mismo canal) de cada una de las realizaciones. Actuando del mismo modo para los ocho bloques de características tendremos ocho matrices con

el mismo número de filas (R =realizaciones) y el número de columnas dependiente del tamaño de las muestras extraídas en cada canal ($27 \times N$).

Una vez que la información extraída del EEG ha sido organizada de esta manera, será normalizada por columnas debido a lo que hemos comentado anteriormente de que cada columna contiene la información semejante de cada realización. Es importante este proceso de normalización debido a la distinta naturaleza de los bloques de características que hemos obtenido y es una forma de evitar que posibles valores muy grandes o muy pequeños distorsionen o influyan en la clasificación posterior. La normalización elegida es $N \sim (0,1)$ de forma que al valor máximo de cada columna se le asigna el valor 1 y al valor mínimo se le asigna el valor 0. Los valores son calculados de acuerdo a la expresión:

$$valor_{norm} = \frac{valor_{a \text{ calcular}} - valor_{mínimo}}{valor_{máximo} - valor_{mínimo}}$$

(1) Bloque una realización

(2) Vector por cada realización

$$\begin{pmatrix} \alpha_{11} & \cdots & \alpha_{1N} \\ \vdots & \ddots & \vdots \\ \alpha_{271} & \cdots & \alpha_{27N} \end{pmatrix} \Rightarrow [\alpha_{11}, \alpha_{12}, \dots, \alpha_{1N}, \alpha_{21}, \dots, \alpha_{2N}, \dots, \alpha_{271}, \dots, \alpha_{27N}]$$

$$\Downarrow$$

$$\begin{matrix} 1 \\ 2 \\ \vdots \\ R \end{matrix} \begin{pmatrix} 0 & 1 & \cdots & 0,3 \\ 0,2 & 0 & \cdots & 1 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 0,7 & \cdots & 0 \end{pmatrix} \Leftarrow \begin{pmatrix} \alpha_{11} & \cdots & \alpha_{27N} \\ \beta_{11} & \cdots & \beta_{27N} \\ \vdots & \ddots & \vdots \\ \gamma_{11} & \cdots & \gamma_{27N} \end{pmatrix} \begin{matrix} \text{Realización 1} \\ \text{Realización 2} \\ \vdots \\ \text{Realización R} \end{matrix}$$

(4) Bloque normalizado

(3) Bloque R realizaciones

Figura 4.9: Proceso de organización y normalización de un bloque de características

4.4. Búsqueda de las mejores características

Después de calcular las características, organizar los distintos bloques y normalizarlos se procede a una selección de las características que van a ser utilizadas por el clasificador. Hay que considerar que no todas las *features* calculadas nos proporcionan una información relevante que nos permite una buena separabilidad entre las distintas clases o puntos objetivo. Como mencionamos al principio del capítulo la búsqueda de buenas características es objeto de numerosos estudios y los grupos de investigación BCI siguen trabajando en el desarrollo de algún sistema de selección automática de características. El problema

es muy complejo debido a la alta variabilidad de la señal EEG, que depende fuertemente del sujeto estudiado e incluso del estado del mismo en el momento del experimento.

Los ocho bloques de características ordenados y normalizados se concatenan para formar la matriz final de características que tendrá un tamaño de $R \times 2565$ (El cálculo es el resultado de concatenar $R \times (27 \times 3) + R \times (27 \times 5) + R \times (27 \times 5) + R \times (27 \times 30) + R \times (27 \times 30) + R \times (27 \times 10) + R \times (27 \times 10) + R \times (27 \times 2)$). La alta dimensionalidad de esta matriz y la presencia de características que pueden no mejorar la clasificación invitan a utilizar algún método para seleccionar aquellas más relevantes. En este proyecto se propone la utilización de la técnica de *cross-validation*. Esta técnica se encuentra explicada en la sección 6.1 porque es también la técnica con la que se evaluarán los resultados.

El proceso de selección de mejores características se comienza tomando los datos de entrenamiento de cada una de las particiones que hemos obtenido al hacer *cross-validation* para evaluar nuestro sistema (como se comenta en la sección 6.1). Utilizando estos datos de entrenamiento se procede de nuevo a hacer un particionado k-fold en 10 conjuntos de datos de entrenamiento y test. Para cada una de las primeras particiones (las de evaluación del sistema) se sigue el siguiente proceso: se toma una columna de la matriz de características explicada en el párrafo anterior y se calcula el porcentaje de aciertos en la segunda *cross-validation* utilizando para entrenar el clasificador únicamente esa característica (columna de la matriz de características). Cuando se han calculado todas las columnas una a una y se ha obtenido el resultado de clasificar con cada una de ellas (en la segunda *cross-validation*), se toma el siguiente conjunto de entrenamiento (de la *cross-validation* de evaluación) y se procede del mismo modo. Cuando se tienen los diez resultados, se calcula la media y se elige aquella característica que proporcione mayor porcentaje de acierto en media. Esta columna es retirada de la matriz de características y comienza a formar parte de lo que denominaremos matriz de características seleccionadas, que tendrá un tamaño de $R \times 1$. El siguiente paso es repetir este proceso pero probando a clasificar en la *cross-validation* segunda con cada una de las combinaciones que resultan de usar la característica que ya tenemos seleccionada con cada una de las restantes. La combinación de dos características que resulte en un mayor porcentaje de aciertos en media será la nueva matriz de características seleccionadas, que ya tendrá un tamaño de $R \times 2$. El proceso se repite añadiendo de una en una las restantes para clasificar con 3 columnas y así sucesivamente. La condición de parada del algoritmo se produce cuando al añadir una nueva característica de las que todavía quedaban no supone un incremento en el número de aciertos. Las características elegidas serán las utilizadas para introducirlas al clasificador y conformarán nuestra matriz de características seleccionadas. Este proceso se puede ver explicado en el algoritmo 1.

A continuación podemos ver una gráfica de la evolución del algoritmo. Cada vez que encontramos una nueva característica a añadir a nuestra matriz de características seleccionadas, es porque el resultado de concatenar ésta con las anteriores disminuye el porcentaje de error de nuestro algoritmo de búsqueda. Cuando al añadir una nueva característica incrementa el porcentaje de fallos se detiene el algoritmo (figura 4.10).

Algorithm 1 Algoritmo de selección de características

```

particionado  $k - fold$  10 (para nuestra evaluación (primero))
tomamos los conjuntos de entrenamiento
while mejor porcentaje de aciertos nuevo > mejor porcentaje de aciertos anterior do
  for  $i = 1 \rightarrow$  número de conjuntos de entrenamiento do
    particionado  $k - fold$  10 (para nuestra selección de características (segundo))
    for  $j = 1 \rightarrow$  número de particiones do
      for  $k = 1 \rightarrow$  número de columnas restante de la matriz de características do
         $aciertos(j, k) =$  cálculo aciertos con característica  $k$  para cada particion  $j$ 
      end for
    end for
     $aciertos(i, k) =$  media ( $aciertos(j, k)$ ) (por columnas)
  end for
   $aciertos\ finales =$  media ( $aciertos(i, k)$ ) (por columnas)
   $nueva\ mejor\ característica = (k == \max(aciertos\ finales))$ 
   $mejor\ porcentaje\ de\ aciertos\ anterior =$  mejor porcentaje de aciertos nuevo
   $mejor\ porcentaje\ de\ aciertos\ nuevo = \max(aciertos\ finales)$ 
   $matriz\ mejores\ características = [matriz\ mejores\ características \& nueva\ mejor\ característica]$ 
end while

```

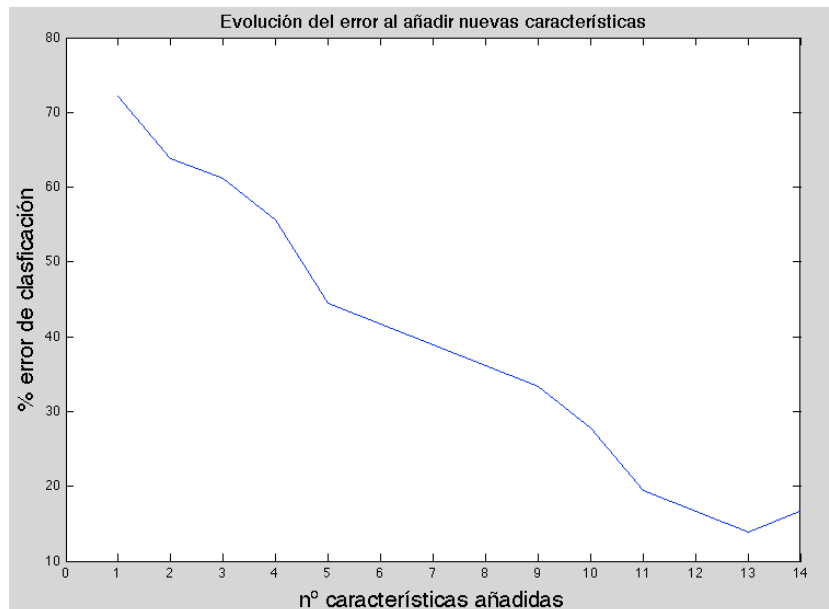


Figura 4.10: Evolución del algoritmo de selección de mejores características

5. Clasificación

5.1. Introducción

En el presente capítulo se presenta el problema de la clasificación. El objetivo del proyecto es decodificar el punto objetivo al que se dirige el sujeto por lo que se necesita un método para determinar, a partir de las características extraídas anteriormente, cuál es dicho punto. Por lo tanto necesitamos un método para clasificar esta información.

El capítulo estará dividido en dos secciones. En la primera de ellas (sección 5.2) se aborda el problema de la clasificación y se exponen ejemplos simples con tres métodos de clasificación distintos: Análisis de discriminación lineal (LDA), máquinas de soporte vectorial (SVM) y con un clasificador agregado diseñado para este proyecto. Por último en la sección 5.3 se presenta la forma en la que se utiliza la clasificación en el presente proyecto.

5.2. Clasificadores

El objetivo de los sistemas BCI es traducir la actividad cerebral en órdenes para un computador. Para conseguirlo se hace uso de algoritmos de clasificación como técnica ampliamente utilizada. Estos algoritmos son utilizados para identificar patrones de la actividad cerebral.

La forma de trabajar de estos algoritmos se divide en dos partes. En primer lugar el modelo debe ser entrenado, lo que significa que se introduce al algoritmo los datos de entrenamiento de forma que un modelo de clasificación es creado a partir de estos datos. Como veremos en los dos ejemplos siguientes la manera de hacerlo es diferente dependiendo del algoritmo empleado. Una vez que el modelo ha sido creado, en él está contenida la información de los diferentes grupos o clases así como las barreras de decisión que el algoritmo ha calculado a partir de la información que se le ha introducido. Esta información de entrenamiento está marcada o etiquetada, es decir, se le introduce tanto los datos para entrenar como la clase a la que pertenecen los mismos. De esta manera se puede proceder al siguiente paso o predicción. En esta parte se usa el modelo creado para predecir la clase

de un conjunto de datos de *test* del cual se desconoce a qué clase pertenecen. Se hace uso de las regiones de decisión calculadas en el modelo para clasificar los nuevos datos en una de las clases.

A continuación se expondrán los dos clasificadores más ampliamente utilizados en los trabajos con interfaces cerebro-computador [14] [15] y un clasificador agregado diseñado en este proyecto. Comentaremos brevemente su forma de calcular las barreras de decisión y lo ejemplificaremos con un caso creado con datos sintéticos.

5.2.1. Análisis de discriminación lineal (LDA)

El objetivo del LDA es usar crear un hiperplano que separe los datos que representan las diferentes clases. En el caso de tener dos, la clase del vector de características dependerá de en qué lado del hiperplano quede ese vector como se muestra en la figura 5.1




Figura 5.1: Visualización del hiperplano que separa las clases en el caso de un LDA biclase

LDA supone una distribución normal de los datos y una matriz de covarianza igual para ambas clases. El hiperplano es obtenido buscando la proyección que maximiza la distancia entre la media de las dos clases y minimiza la varianza entre las mismas. En el caso de ser un clasificador LDA multiclase como es nuestro caso, se utilizan varios hiperplanos. La estrategia que se utiliza en estos casos es la de *uno contra el resto* que consiste en separar una clase del resto de ellas.

Este algoritmo supone una carga computacional muy baja lo que es aconsejable para aplicaciones BCI. Además el clasificador es muy simple y se obtienen buenos resultados. Podemos observar dos ejemplos de clasificación con datos sintéticos de dos dimensiones creados a partir de una semilla y con estructura gaussiana con diferente varianza para un mejor entendimiento de su funcionamiento:

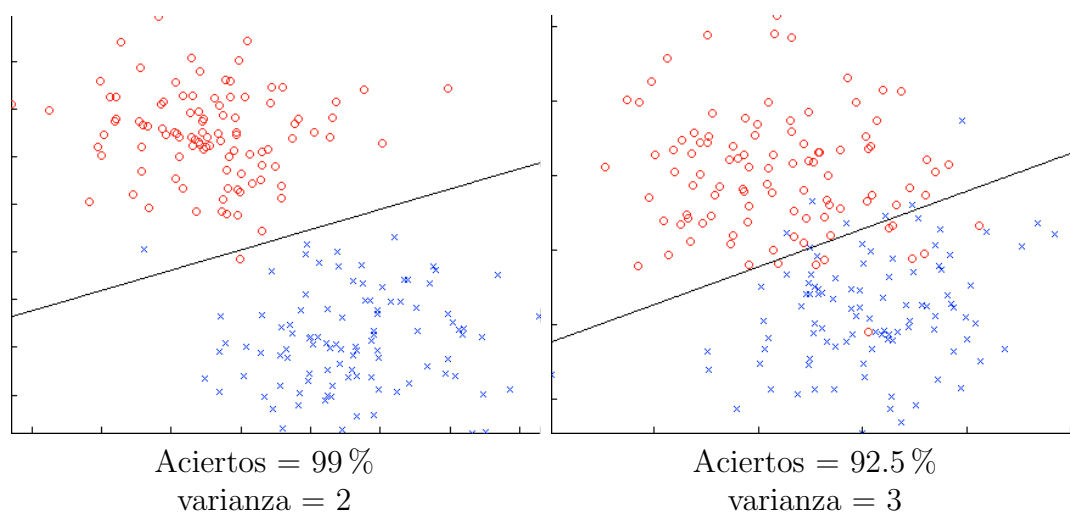


Figura 5.2: Ejemplo del comportamiento del clasificador LDA

5.2.2. Máquinas de soporte vectorial (SVM)

Una máquina de soporte vectorial (SVM) también utiliza hiperplanos discriminantes para identificar las clases. Sin embargo el hiperplano seleccionado es aquel que maximiza los márgenes, es decir, la distancia entre los puntos de entrenamiento más próximos. Se puede ver en la figura 5.3 la diferencia con el anterior clasificador.




Figura 5.3: Visualización del hiperplano que separa las clases en el caso de un SVM biclase lineal

Este tipo de clasificadores permiten la posibilidad de crear barreras de decisión no lineales. En nuestro trabajo haremos uso de esta opción. Incrementando un poco la complejidad del algoritmo es posible utilizar una función *kernel* que mapea los datos en un espacio de muy alta dimensionalidad. El *kernel* utilizado en nuestro caso es una función de base gaussiana (RBF) del tipo:

$$K(x, y) = e^{\frac{-\|x-y\|^2}{2\sigma^2}}$$

Este tipo de clasificadores mejoran con respecto a LDA en su insensibilidad ante el sobre-entrenamiento que puede provocar que el algoritmo aprenda una clase que no es correcta. Así que no presenta problema si se trabaja con una alta dimensionalidad de los datos pero cuenta con la desventaja de un coste computacional mayor y, por lo tanto, una ejecución más lenta.

A continuación exponemos un ejemplo de clasificación biclase con los mismos datos del apartado anterior tanto con kernel lineal como gaussiano para observar cómo se comporta el clasificador.

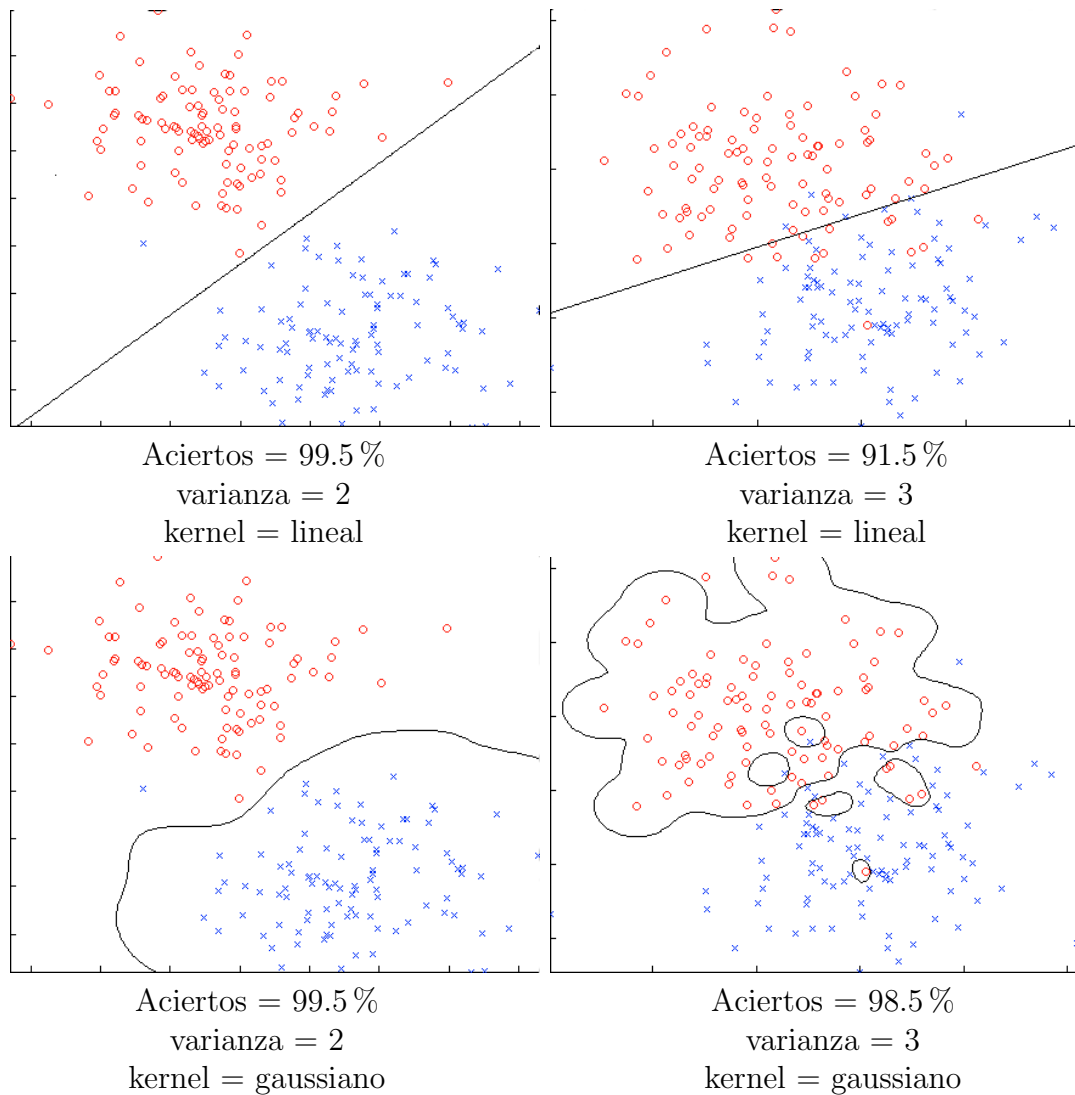


Figura 5.4: Ejemplo del comportamiento del clasificador SVM con distintos kernel

5.2.3. Clasificador agregado

La idea de un clasificador agregado es combinar varias máquinas de aprendizaje para formar un sólo clasificador que calcule la salida a partir de la información que le llega de cada una de ellas. En otras palabras, se trata de combinar una serie de clasificadores simples para formar un clasificador más complejo y que se aproveche de la información de los clasificadores simples. El tiempo de computación por lo tanto es mayor.

En el presente trabajo se propuso diseñar un clasificador agregado de acuerdo a las características del problema, es decir, teniendo en cuenta que se desean clasificar 8 puntos objetivos. El clasificador simple utilizado en esta tarea será una máquina de soporte vectorial (SVM) biclase con un kernel gaussiano. A continuación explicaremos el proceso mediante el cual se combinan estos clasificadores SVM biclase para formar nuestro clasificador agregado:

- Existen 35 posibilidades diferentes de dividir los 8 puntos objetivo en dos grupos de 4 puntos. Esto quiere decir que tendremos 35 clasificadores SVM biclase diferentes.
- Como $8 = 2^3$ podemos construir un clasificador de 8 puntos a partir de 3 clasificadores biclase
- No todas las combinaciones de 3 clasificadores resultan en un clasificador de 8 clases unívoco. Existen 840 posibilidades de construir un clasificador unívoco tomando clasificadores biclase de 3 en 3 del grupo de 35. En el ejemplo siguiente se muestra un caso de clasificador unívoco y uno que no lo es:

Clasificador1 (C1) = 1 2 3 4 (Clase 0) - 5 6 7 8 (Clase 1)

Clasificador2 (C2) = 1 2 5 6 (Clase 0) - 3 4 7 8 (Clase 1)

Clasificador3 (C3) = 1 4 5 7 (Clase 0) - 2 3 6 8 (Clase 1)

C1	C2	C3	
0	0	0	→ Punto objetivo 1
0	0	1	→ Punto objetivo 2
0	1	0	→ Punto objetivo 4
0	1	1	→ Punto objetivo 3
1	0	0	→ Punto objetivo 5
1	0	1	→ Punto objetivo 6
1	1	0	→ Punto objetivo 7
1	1	1	→ Punto objetivo 8

Clasificador de 8 clases unívoco construido a partir de 3 clasificadores biclase

Clasificador1 (C1) = 1 2 3 4 (Clase 0) - 5 6 7 8 (Clase 1)


Clasificador2 (C2) = 1 2 4 8 (Clase 0) - 3 5 6 7 (Clase 1)

Clasificador3 (C3) = 1 3 5 7 (Clase 0) - 2 4 6 8 (Clase 1)

C1	C2	C3	
0	0	0	→ Punto objetivo 1
0	0	1	→ Punto objetivo 2 o Punto objetivo 4
0	1	0	→ Punto objetivo 3
0	1	1	→ Ninguno
1	0	0	→ Ninguno
1	0	1	→ Punto objetivo 8
1	1	0	→ Punto objetivo 5 o Punto objetivo 7
1	1	1	→ Punto objetivo 6

Clasificador de 8 clases NO-unívoco construido a partir de 3 clasificadores biclase

Una vez que se tiene calculado el punto objetivo resultante de entre los 8 posibles con cada una de las 840 combinaciones válidas se procede a un sistema de votación. El punto objetivo más votado de entre las 840 posibilidades, es el punto decidido por el clasificador para esa realización. En la figura 5.5 podemos ver cómo con 3 clasificadores biclase se puede dividir el conjunto de datos (en el ejemplo datos sintéticos) en 8 clases. Cada color representa una clase y se pueden observar tres barreras de decisión. Se aplica el siguiente criterio: dentro de una barrera → clase 0 y fuera de una barrera → clase 1. Se referirá a las barreras como (R) roja, (A) azul y (V) verde.



Datos	R	A	V
Negro	0	0	0
Naranja	0	0	1
Amarillo	0	1	0
Granate	0	1	1
Verde	1	0	0
Azul claro	1	0	1
Azul oscuro	1	1	0
Rosa	1	1	1

Figura 5.5: Visualización las barreras de decisión de los 3 clasificadores biclase y cómo forman 8 regiones en el espacio

El algoritmo de diseño del clasificador agregado se expone a continuación:

Algorithm 2 Clasificador agregado

```

for clasificador SVM biclase = 1  $\rightarrow$  35 do
  clasificación entre clase 0 o 1
end for
for clasificador unívoco = 1  $\rightarrow$  840 do
  traducción a clasificación de 8 clases
end for
punto objetivo final = moda (840 puntos decididos)
  
```

5.3. Clasificación utilizada

En el presente proyecto y para el problema de la clasificación de puntos objetivo se utilizará un clasificador SVM multiclase con kernel gaussiano, ya que como se ha comentado con anterioridad es uno de los dos clasificadores más utilizados en los estudios de interfaces cerebro-computador. Por una razón de tiempo se decidió utilizar únicamente uno de los tres tipos de clasificador para la obtención de los resultados finales. Se realizaron unas pequeñas pruebas para descartar aquellos que dieran peor resultado de clasificación. El hecho de la alta dimensionalidad de los datos, que supone un problema con los clasificadores LDA ya que se puede producir un sobre-entrenamiento que falsee los resultados, se evita con la selección de características. Por lo tanto la razón por la que se excluyó es debido a que los primeros test dieron resultados de clasificación por debajo de los SVM. Por último comentar que los porcentajes de acierto con el clasificador agregado eran similares a los del SVM multiclase pero por motivos obvios de coste computacional muy elevado se optó finalmente por elegir el SVM multiclase como clasificador para la evaluación del proyecto. El clasificador LDA se utilizó en un trabajo previo al estudio que sigue esta memoria y que se comentará en el siguiente capítulo junto a sus resultados (sección 6.2).

Para realizar la clasificación se parte de la matriz que obtuvimos como resultado de la búsqueda de mejores características, es decir, una matriz en la que cada fila representa una realización y cada columna representa una de las mejores características para clasificar. A cada una de estas fila se le asigna una etiqueta que corresponderá con el número del punto objetivo que se alcanzaba en dicha realización. En el siguiente capítulo se verá cómo se realiza la validación del sistema así como los resultados del proyecto.

6. Resultados

En este capítulo se presentarán los resultados obtenidos en el proyecto así como el método utilizado para la obtención de los mismos. Los resultados expresarán el número de aciertos en la predicción del punto objetivo a alcanzar después de tratar adecuadamente la señal EEG.

En el primer apartado (sección 6.1) se explicará el método de la *cross – validation* o la forma de calcular los porcentajes de acierto. En el segundo apartado (sección 6.2) se presentan los resultados de un trabajo previo a lo comentado hasta ahora en la memoria pero que se utilizó como aproximación a los clasificadores y con el que se llegó a unos resultados que confirmaban el trabajo de otra investigación. En la tercera parte (sección 6.3) se expondrán y analizarán los resultados obtenidos para cuatro y para ocho puntos objetivos. Los resultados se calcularon tanto para el caso de tener 4 puntos objetivo (de forma que se pueda hacer una comparación con la literatura) como para 8 puntos. También se evaluó los resultados con los datos de movimiento (no anticipatorios) para analizar los resultados.

6.1. Cross-validation

El hecho de tener un número de realizaciones bastante limitado para cada sujeto supone un problema en cuanto a la buena actuación del entrenamiento del clasificador. El tener pocos datos para trabajar obliga a buscar otra forma de evaluar los resultados que nos permita sacar el máximo rendimiento de los datos de los que disponemos. La técnica del *cross – validation* consiste en dividir de forma aleatoria el conjunto de datos etiquetados del que disponemos en dos partes: una es usada para entrenar el clasificador (datos de entrenamiento) y el otro sirve para evaluar la precisión del clasificador. Es completamente indispensable que ningún dato de test esté incluido en los datos de entrenamiento ya que esto supone un error y los valores obtenidos pueden verse afectados gravemente.

Con este método buscamos una generalización de los resultados de forma que pese a disponer de los datos EEG de un número limitado de realizaciones del experimento podemos sacar una conclusión general de cómo se comportaría nuestro sistema. Por ello en el proyecto se utiliza lo que se conoce como k-fold cross-validation que consiste en

dividir el conjunto de datos que tenemos en k conjuntos de entrenamiento y validación de forma que cada una de las realizaciones iniciales sólo esté presente en uno de los k grupos de validación.

```

K-fold cross validation partition
      N: 196
NumTestSets: 10
TrainSize: 177 176 176 176 176 176 176 177 177 177
TestSize: 19 20 20 20 20 20 20 19 19 19

```

Figura 6.1: Ejemplo de particionado para realizar cross-validation

6.2. Trabajo previo

Cuando se comenzó el presente proyecto existía un trabajo en curso en el grupo de Brain Computer Interfaces mediante el cual se buscaba decodificar las posiciones (x,y,z) de la trayectoria del brazo a partir de la señal EEG en las tareas de alcance. El problema es muy complejo y los resultados de decodificación que se obtenían eran muy ruidosos. Por ello se planteó la idea de comprobar si al menos contenían la información para identificar el punto objetivo final con las trayectorias estimadas en esta investigación paralela. Con este objetivo y para familiarizarse con los algoritmos de clasificación y su forma de uso, se compaginó la tarea de documentación con unas pruebas de clasificación que utilizaban los datos registrados de movimiento por el sistema VICON y los datos estimados en la investigación del grupo. Se usó los datos correspondientes al dedo índice de la mano derecha del sujeto. Estos datos eran las posiciones (x,y,z) del dedo a lo largo del movimiento de alcance del punto objetivo. Los resultados que se obtuvieron para la clasificación de los puntos objetivo a partir de las trayectorias estimadas confirmaron que los resultados no eran aprovechables. Por ello se decidió buscar una nueva estrategia de clasificación, procesando la señal previamente del modo explicado en esta memoria y cuyos resultados se presentan en la siguiente sección. En la figura 6.2 se presenta con líneas rojas las partes desarrolladas durante el transcurso de este proyecto y en negro las partes que realizaron personas ajenas al presente trabajo.

Para comenzar a abordar el problema se diseñó un montaje ficticio con datos sintéticos. Se creó un banco de pruebas con un número de puntos objetivo variable entre uno y ocho. Las coordenadas (x,y,z) de estos puntos fueron elegidas al azar. Se simulaban unas trayectorias rectilíneas desde el punto $(0,0,0)$ hasta los puntos objetivo que eran muestreadas y repetidas para que sirvieran como entrenamiento para el clasificador. A estas trayectorias se les añadía ruido para contemplar un estado más realista del experimento. El resultado de estas simulaciones se presentaba en forma de matriz de confusión, la cual nos indicaba de una forma directa los fallos en la clasificación que se habían producido. Esta es una matriz cuadrada en la que cada fila representa la clase real del dato y las columnas representan la clase predicha de los mismos. Los elementos $c(i,j)$ representan el número de datos que son de una clase (i) y son predichas en una clase (j) . En el caso de 100 % de aciertos sólo la matriz diagonal tendría valores.

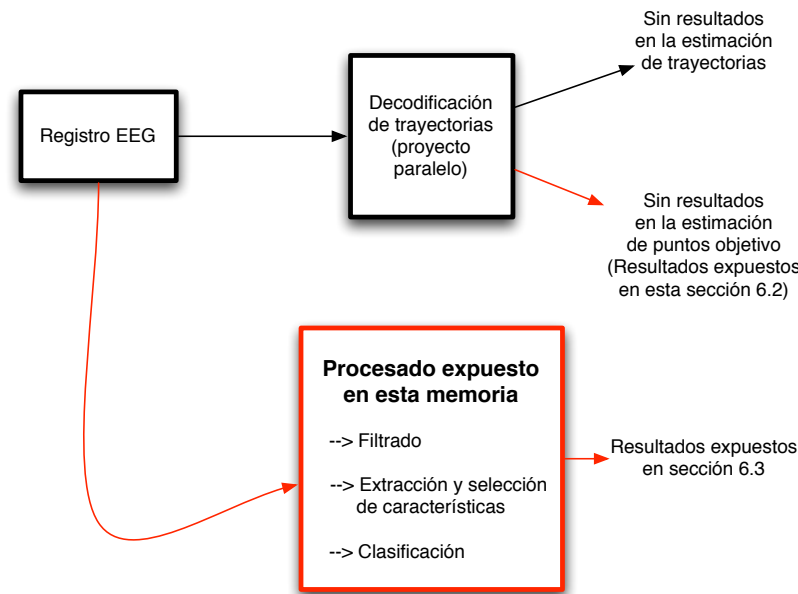


Figura 6.2: Esquema con las partes desarrolladas en este proyecto y partes ajenas al mismo

Se probó con un clasificador LDA (Linear Discriminant Analysis). Los resultados sin ruido eran clasificaciones perfectas y se comprobó que al aumentar la varianza del mismo los porcentajes disminuían. Como se puede leer en la literatura, no existe un clasificador mejor o peor, depende del problema al que nos enfrentemos y las características del mismo. Por lo que la elección de un clasificador LDA para estas pruebas es debido a su simplicidad, que ayuda a entender el problema de clasificación.

El siguiente paso fue adaptar el problema a los datos reales obtenidos en el experimento. Se utilizó la información de los puntos de inicio y fin de las trayectorias, así como los valores reales (puntos (x,y,z) de las trayectorias grabadas) y estimadas (puntos (x,y,z) estimados en el trabajo paralelo a este proyecto). Una vez representados los datos en el espacio se procedió a implementar el clasificador para poder discernir a cuál de las ocho puntos objetivo pertenecía cada uno de los puntos de la trayectoria. Se propusieron tres conjuntos de entrenamiento para el clasificador: el primero eran rectas que unían el punto de salida con los puntos objetivos del mismo modo que se hizo con los datos sintéticos. El segundo conjunto eran los propios datos reales como entrenamiento para el clasificador. En tercer lugar se propuso unir los puntos con unas parábolas, cuyos coeficientes eran calculados a partir de los datos reales. Las parábolas se probaron debido a la forma de los datos registrado por el sistema VICON que como se puede apreciar en la figura 6.3 tienen forma parabólica.

Antes de introducir los datos al clasificador se normalizaban y se pasaban por un algoritmo PCA (Principal Component Analysis) para reducir la dimensionalidad y que se encuentra explicado en el anexo C.4. Se realizaron tres tipos de pruebas con un clasificador LDA. Para realizar el primer test se utilizó cross-validation (explicada en la sección




Figura 6.3: Trayectorias registradas por el sistema VICON en las operaciones de alcance de los puntos objetivo

6.1) con un k-fold de 10 para cada uno de los sujetos. A continuación se utilizó unos datos de entrenamiento reales distintos a los de test en lo que es una aproximación realista del clasificador. Por último se probó con los datos estimados en el experimento. La tabla 6.1 (resultados de porcentaje de aciertos) recoge el resumen de los resultados obtenidos con un clasificador LDA y con distintos datos de entrenamiento:

- **K-fold 10** Entrenamiento haciendo uso de la técnica *cross-validation* que será comentada en el capítulo siguiente.
- **Entrenamiento (E) con datos distintos (!=) a los de test (T)** En este apartado lo que haremos será usar como datos de entrenamiento diferentes tipos de datos para intentar clasificar los datos reales (R) o los datos estimados (E) (en la tabla 6.1 indicados respectivamente como $E \neq T$ (R) y $E \neq T$ (E)):
 - **Rectas** Se usará como datos de entrenamiento puntos de las rectas que unen el punto inicial del movimiento con los puntos objetivo.
 - **Parábolas** Se usará como datos de entrenamiento puntos de parábolas que unen el punto inicial del movimiento con los puntos objetivo
 - **Reales** Se usarán parte de los datos reales grabados por el sistema VICON como entrenamiento.

6. Resultados

6.3 Análisis de los resultados

ME ¹	DE ²	Sujeto 1	Sujeto 2	Sujeto 3	Sujeto 4	Sujeto 5	Sujeto 6	Sujeto 7
K-fold 10	Reales	61.04	63.78	55.99	58.90	63.52	57.00	60.39
	Estimados	13.74	14.18	15.54	16.51	13.46	16.64	15.84
E!=T (R)	Rectas	41.15	43.95	38.48	38.87	40.56	44.97	44.54
	Parábolas	57.52	66.17	59.90	56.64	60.28	53.99	67.42
	Reales	60.97	69.21	62.77	59.73	63.97	46.13	44.54
E!=T (E)	Rectas	13.82	11.35	13.22	12.19	8.87	13.89	13.04
	Parábolas	13.15	13.20	13.32	12.59	8.97	11.26	12.91
	Reales	12.24	13.32	13.21	11.54	9.23	12.02	13.21

Tabla 6.1: Resultados de clasificación de los puntos en el espacio con distintos métodos de clasificación y distintos datos de entrenamiento y test

Como se puede observar en la tabla anterior los datos estimados nunca son clasificados sino que se obtiene unos valores de acierto aleatorio, es decir, los aciertos se deben a la probabilidad de acertar de forma aleatoria. Como se puede ver en la figura 6.4 los datos estimados no son viables para una correcta clasificación. Estos resultados corroboraban que la técnica para encontrar estos puntos estimados tampoco contenía suficiente información para extraer el punto objetivo.




Figura 6.4: Datos de las posiciones (x,y,z) estimadas a partir del EEG

6.3. Análisis de los resultados

Una vez que se tiene construido el sistema completo y hemos definido la forma de evaluarlo se procede a presentar los resultados de clasificación obtenidos. Se ha dividido la evaluación del sistema en una clasificación con 4 puntos objetivo y otra clasificación con los 8 puntos objetivo. Del mismo modo se han obtenido los resultados con la señal EEG previa al movimiento pero también se ha calculado el resultado con los datos posteriores

¹ME: Método de entrenamiento

²DE: Datos de entrenamiento

6. Resultados

6.3 Análisis de los resultados

al inicio del movimiento. Por último se ha evaluado la clasificación con y sin filtro CSP (Common Spatial Pattern).

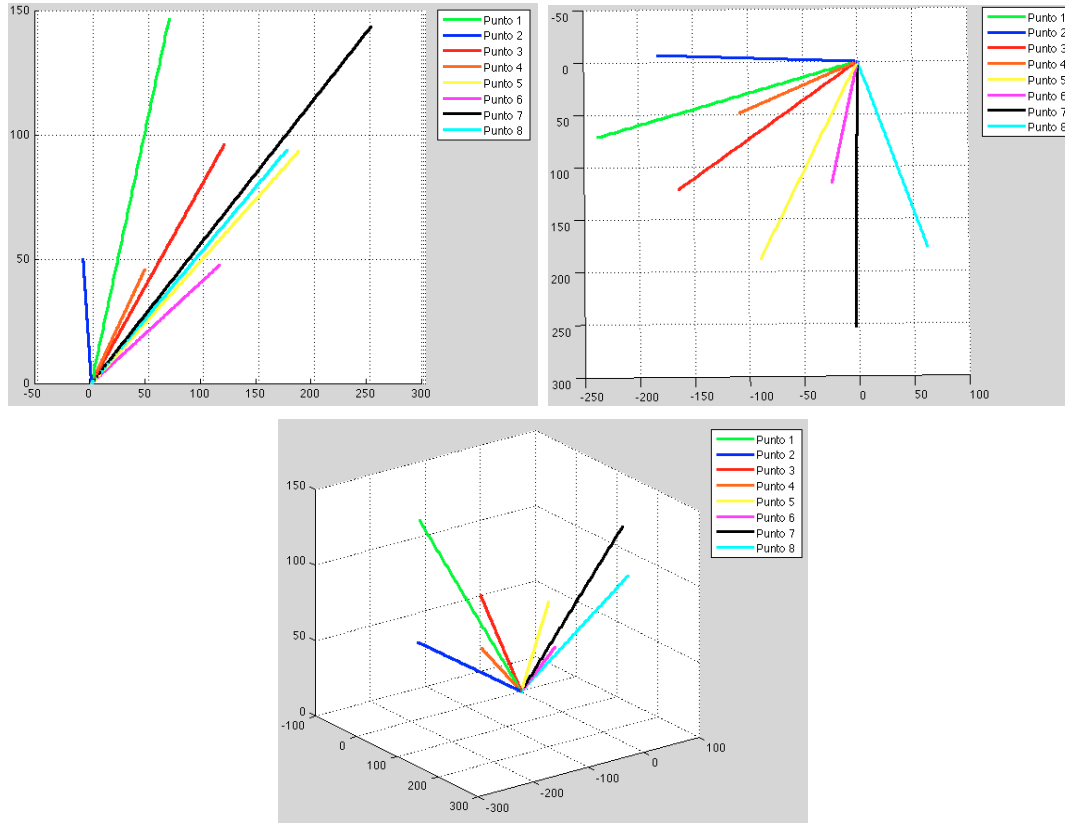


Figura 6.5: De izquierda a derecha y de arriba abajo: a) Vista lateral de la distribución de puntos. b) Vista aérea de la distribución de puntos. c) Vista tridimensional de la distribución de puntos

Los resultados numéricos obtenidos se refieren al porcentaje de aciertos en la predicción del punto objetivo que se deseaba alcanzar a partir de la información extraída del EEG por el sistema desarrollado.

En esta primera tabla 6.2 se presentan los resultados obtenidos en la decodificación de 4 puntos objetivo para cada sujeto. En este caso se han elegido 4 puntos comunes para todos los sujetos con la intención de mantener una uniformidad entre los sujetos (Puntos 1 3 5 7).

Datos	CSP	Sujeto 1	Sujeto 2	Sujeto 3	Sujeto 5	Sujeto 6	Sujeto 7
Movimiento	CON	27.32	60.75	25.30	37.45	26.34	23.64
	SIN	27.21	75.65	23.47	55.26	28.72	22.35
Preparación	CON	31.33	45.8	29.05	42.10	28.73	33.84
	SIN	28.34	67.21	24.97	50.63	23.25	27.73

Tabla 6.2: Resultados de clasificación con 4 puntos objetivo fijos

6. Resultados

6.3 Análisis de los resultados

Se plantea a continuación una tabla (tabla 6.3) donde se refleja la decodificación de 4 puntos, pero éstos son elegidos de forma individualizada para cada sujeto. La elección de los puntos se realizó a partir de la media del periodograma de los datos referentes a cada punto objetivo. Se seleccionó visualmente aquellos que presentaban una mayor separabilidad a simple vista. Esta medida, aunque no mantiene la uniformidad, nos puede dar una idea de la capacidad de discriminación que se puede alcanzar con 4 puntos a clasificar. En la tabla 6.4 se muestran los puntos elegidos para cada sujeto.

Datos	CSP	Sujeto 1	Sujeto 2	Sujeto 3	Sujeto 5	Sujeto 6	Sujeto 7
Movimiento	CON	24.35	56.64	47.69	74.23	56.32	40.23
	SIN	31.2	71.11	75.23	85.71	76.27	71.25
Preparación	CON	21.63	43.24	36.34	46.45	50.63	36.25
	SIN	30.12	65.23	35.46	57.14	70.57	38.15

Tabla 6.3: Resultados de clasificación con 4 puntos objetivo distintos entre sujetos (los mejores puntos)

Sujeto	Puntos elegidos
1	1 2 3 7
2	1 2 5 7
3	1 2 6 8
5	1 3 6 7
6	1 4 6 7
7	3 6 7 8

Tabla 6.4: Mejores puntos elegidos para cada sujeto

Por último en la tabla 6.5 tenemos los resultados para la clasificación de 8 puntos.

Datos	CSP	Sujeto 1	Sujeto 2	Sujeto 3	Sujeto 5	Sujeto 6	Sujeto 7
Movimiento	CON	12.74	22.83	14.23	25.56	14.81	13.84
	SIN	14.28	44.89	8.91	45.33	27.40	20.77
Preparación	CON	15.81	10.20	12.10	10.67	12.59	10.76
	SIN	11.96	34.69	17.83	37.23	30.37	14.32

Tabla 6.5: Resultados de clasificación con 8 puntos objetivo

Como se puede observar la clasificación de 8 puntos es un problema complejo. Únicamente los sujetos 2, 5 y 6 presentan una clasificación real ya que los otros valores son cercanos al valor de acierto aleatorio que para ocho puntos se sitúa en un 12,5 %, es decir, que por probabilidad y aunque no se procesaran los datos, existe una probabilidad de 1 sobre 8 de acertar. No existe posible comparación con la literatura ya que la clasificación de 8 puntos no ha sido llevada a cabo hasta el momento. En la tabla 6.3 se muestra como, con la excepción de algún sujeto, se consiguen valores que igualan los conseguidos en trabajos anteriores con la añadidura de que en este proyecto trabajamos con la intención del movimiento, que es un paso más ya que respondería a la forma de actuar de un sujeto

sano: pensar dónde se quiere mover el brazo bastaría para efectuar el movimiento. Por último comentar que la tabla 6.3 nos muestra las posibilidades del sistema si el problema o experimento se adecúa a cada sujeto y recordando que se trabaja en un espacio 3D y con movimientos autoiniciados sin estímulo externo a diferencia de los trabajos previos. Los resultados son esperanzadores con las posibilidades futuras de este tipo de ayudas a personas con deficiencias motoras.

7. Conclusiones y líneas futuras

En este proyecto fin de carrera se ha desarrollado un sistema basado en interfaces cerebro computador para la detección de la intención de movimiento del brazo de un sujeto hasta 8 puntos diferentes en el espacio a través del procesamiento de la señal encefalográfica (EEG). El problema abordado es de una complejidad alta tal y como se ve reflejado en los resultados obtenidos. Hay que decir que el trabajo realizado está por encima del estado del arte por lo que no se tienen referencias con la posibilidad de comparación de resultados.

Por un lado como se comentó en el capítulo 1 por ahora en la literatura se ha estudiado la posibilidad de decodificar el movimiento del brazo hasta un máximo de 4 puntos en el espacio y haciendo uso de datos de EEG durante el movimiento de la extremidad. En este proyecto hemos querido ir un paso más allá y evaluar la respuesta ante los datos EEG anteriores a la acción de alcance del brazo hasta uno de los puntos objetivo. Los resultados obtenidos son esperanzadores en cuanto que se consigue para algún sujeto valores buenos de clasificación. Uno de los grandes escollos de los interfaces cerebro computador es, sin contar la propia señal que de por sí es medida con gran atenuación y ruido debido a las capas que atraviesa hasta los electrodos, es la variabilidad de un sujeto a otro. Además la correcta realización de los experimentos es vital en el buen procesamiento posterior de la señal.

Teniendo en cuenta todo lo anterior, los resultados comentados en capítulo anterior son esperanzadores y demuestran las oportunidades que este tipo de sistemas ofrecen para la posible rehabilitación de pacientes con deficiencias motoras. Los sistemas BCI son una tecnología muy reciente, casi exclusivamente en fase de investigación en la actualidad pero con un futuro muy prometedor debido a sus amplísimas posibilidades. Por todo ello se abre un abanico de acciones futuras a realizar como las que se indican a continuación:

- Ampliación del número de sujetos para la comprobación de la efectividad del sistema desarrollado.
- Un estudio más detallado de las características utilizadas para la mejora de la posterior clasificación. La elaboración de un sistema de elección automática de características diferente al utilizado en este proyecto (a través de una *cross – validation*) es uno de los objetivos pendientes de los sistemas BCI.
- La posible realización de un experimento con 4 puntos objetivo, ya que la respuesta

7. Conclusiones y líneas futuras

cerebral será distinta al tener que elegir únicamente entre 4 puntos en vez de ocho. De esta manera se podría hacer una comparación más precisa con el estado del arte pero utilizando los datos de antes de mover el brazo.

- La realización del mismo problema pero online, es decir, un sistema que decodifique la intención en tiempo real y de esta manera poder probar físicamente la respuesta al sistema.

Bibliografía

- [1] Y. Wang and S. Makeig. Predicting intended movement direction using eeg from human posterior parietal cortex. In Dylan Schmorow, Ivy Estabrooke, and Marc Grootjen, editors, *Foundations of Augmented Cognition. Neuroergonomics and Operational Neuroscience*, volume 5638 of *Lecture Notes in Computer Science*, pages 437–446. Springer Berlin / Heidelberg, 2009.
- [2] P.S. Hammon, S. Makeig, H. Poizner, E. Todorov, and V.R. de Sa. Predicting reaching targets from human eeg. *Signal Processing Magazine, IEEE*, 25(1):69 –77, 2008.
- [3] B. Blankertz, R. Tomioka, S. Lemm, M. Kawanabe, and K.-R. Muller. Optimizing spatial filters for robust eeg single-trial analysis. *Signal Processing Magazine, IEEE*, 25(1):41 –56, 2008.
- [4] Q. Zhao and L. Zhang. Temporal and spatial features of single-trial eeg for brain-computer interface. *Computational Intelligence and Neuroscience*, 2007, 2007.
- [5] P.S. Hammon and V.R. de Sa. Preprocessing and meta-classification for brain-computer interfaces. *Biomedical Engineering, IEEE Transactions on*, 54(3):518 – 525, 2007.
- [6] Leif Sörnmo and Pablo Laguna. Bioelectrical signal processing in cardiac and neurological applications. 2005.
- [7] T. Jung S. Makeig, A. J. Bell and T. J. Sejnowski. Independent component analysis of electroencephalographic data. 1996.
- [8] H. Shen, S. Jegelka, and A. Gretton. Fast kernel-based independent component analysis. *IEEE Transactions on Signal Processing*, 57(9):3498–3511, 2009.
- [9] Jonathan R. Wolpaw and Dennis J. McFarland. Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans. *Proceedings of the National Academy of Sciences of the United States of America*, 101(51):17849–17854, 2004.

- [10] H. Ramoser, J. Muller-Gerking, and G. Pfurtscheller. Optimal spatial filtering of single trial eeg during imagined hand movement. *Rehabilitation Engineering, IEEE Transactions on*, 8(4):441 – 446, 2000.
- [11] R. Corralejo, R. Hornero, D. Álvarez, L.M. San José, and M. López. Extracción y selección de características en un sistema brain computer interface (bci) basado en ritmos sensoriomotores. 2010.
- [12] NE Crone, DL Miglioretti, B Gordon, JM Sieracki, MT Wilson, S Uematsu, and RP Lesser. Functional mapping of human sensorimotor cortex with electrocorticographic spectral analysis. i. alpha and beta event-related desynchronization. *Brain*, 121(12):2271–2299, 1998.
- [13] G. Pfurtscheller, C. Neuper, A. Schlogl, and K. Lugger. Separability of EEG signals recorded during right and left motor imagery using adaptive autoregressive parameters. *Rehabilitation Engineering, IEEE Transactions on*, 6(3):316–325, 1998.
- [14] F. Lotte, M. Congedo, A Lécuyer, F. Lamarche, and B Arnaldi. A review of classification algorithms for eeg-based brain-computer interfaces. *Journal of Neural Engineering*, 4(2):R1, 2007.
- [15] D. Garrett, D.A. Peterson, C.W. Anderson, and M.H. Thaut. Comparison of linear, nonlinear, and feature selection methods for eeg signal classification. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, 11(2):141 –144, 2003.