



Universidad
Zaragoza

Trabajo Fin de Grado

Análisis y clasificación de potenciales cerebrales relacionados con el movimiento en pacientes con lesión medular.

Autor

Carlos Bibián Nogueras

Directores

Eduardo López Larraz (Director)
Javier Civera Sancho (Ponente)

Escuela de Ingeniería y Arquitectura
Zaragoza, Septiembre de 2015



DECLARACIÓN DE AUTORÍA Y ORIGINALIDAD

(Este documento debe acompañar al Trabajo Fin de Grado (TFG)/Trabajo Fin de Máster (TFM) cuando sea depositado para su evaluación).

TRABAJOS DE FIN DE GRADO / FIN DE MÁSTER

D./D^a. Carlos Bibián Nogueras,

con nº de DNI 18056280-S en aplicación de lo dispuesto en el art.

14 (Derechos de autor) del Acuerdo de 11 de septiembre de 2014, del Consejo de Gobierno, por el que se aprueba el Reglamento de los TFG y TFM de la Universidad de Zaragoza,

Declaro que el presente Trabajo de Fin de (Grado/Máster)
Grado _____, (Título del Trabajo)

Análisis y clasificación de potenciales cerebrales relacionados con el
movimiento en pacientes con lesión medular.

_____ es de mi autoría y es original, no habiéndose utilizado fuente sin ser citada debidamente.

Zaragoza, 7 de Septiembre de 2015

Fdo: _____

A mi abuela, Elisa, que tanto empeño ha puesto en que este trabajo estuviese terminado.

Resumen

Las BMIs (interfaces cerebro máquina) ofrecen innumerables posibilidades en el campo de la rehabilitación y la compensación funcional en pacientes con problemas de movilidad, como pueden ser las víctimas de un accidente cerebrovascular o de una lesión medular. En este contexto, las BMIs pueden utilizarse para decodificar la intención de movimiento, incluso cuando el paciente no puede moverse, y utilizar esa información para controlar un dispositivo externo como un exoesqueleto o una prótesis.

Mediante técnicas no invasivas, como el electroencefalograma, se pueden adquirir las señales cerebrales para su posterior procesamiento. Una de estas señales cerebrales, que permite decodificar la intención de movimiento, son los MRCP o potenciales cerebrales relacionados con el movimiento. Sin embargo, en la bibliografía actual encontramos que se están utilizando una gran variedad de esquemas de decodificación, dentro de los cuales encontramos distintos filtros frecuenciales, espaciales y clasificadores.

El principal objetivo de este trabajo consiste en realizar un estudio de las distintas partes de un esquema de decodificación de intención de movimiento basado en MRCP, con el fin de evaluar el impacto en los resultados de decodificación de las diversas técnicas utilizadas en cada una de sus partes.

En primer lugar, utilizando unos datos de sujetos sanos, se ha realizado un análisis detallado de las distintas técnicas de filtrado frecuencial, filtrado espacial y algunos de los clasificadores más usados en este campo con el fin de obtener el esquema de decodificación que mejores resultados nos ofrece. En segundo lugar, dado que los usuarios finales de gran parte de las aplicaciones de BMI son pacientes, se ha evaluado el comportamiento del esquema de decodificación de intención motora elegido en la primera parte de este trabajo en dos poblaciones de pacientes con distinto tipo de patología: ictus y lesión medular.

Índice general

1. Introducción	1
1.1. Contexto y estado del arte	1
1.2. Objetivos	3
1.3. Organización de la memoria	3
2. Métodos	4
2.1. Introducción	4
2.2. Conjunto de datos a analizar	4
2.2.1. Datos de sujetos sanos	5
2.2.2. Datos de pacientes de ictus	5
2.2.3. Datos de pacientes con lesión medular	6
2.2.4. Estructura del ensayo a estudiar	6
2.3. Esquema de decodificación de intención motora	7
2.4. Filtrado frecuencial	9
2.4.1. Tipos de filtros frecuenciales	9
2.4.2. Técnicas del filtrado frecuencial	11
2.5. Filtros espaciales	11
2.5.1. CAR	12
2.5.2. LLSF	12
2.5.3. OSF	13
2.6. Clasificadores	14
2.6.1. LDA	14
2.6.2. SVM	15
2.6.3. Matched filter	15
2.7. Métricas	16
2.7.1. Grand average	16
2.7.2. Porcentaje de ensayos clasificados correctamente	16
2.8. Herramientas utilizadas y trabajo implementado	17
3. Resultados	18
3.1. Introducción	18
3.2. Estudio del filtrado frecuencial	18
3.2.1. Filtrado causal	18
3.2.2. Filtrado no causal	21

3.2.3. Comparación de los filtros	24
3.3. Análisis del filtrado espacial y clasificación	25
3.4. Evaluación en pacientes	27
4. Conclusiones y trabajo futuro	29
4.1. Conclusiones	29
4.2. Trabajo futuro	30
Anexos	37
A. Conjunto de datos a analizar	37
A.1. Datos de sujetos sanos	37
A.1.1. Sujetos	37
A.1.2. Protocolo del experimento	37
A.1.3. Adquisición de datos	38
A.2. Datos de pacientes de ictus	39
A.2.1. Pacientes	39
A.2.2. Protocolo del experimento	39
A.2.3. Adquisición de datos	39
A.3. Datos de pacientes de lesión medular incompleta	39
A.3.1. Pacientes	39
A.3.2. Protocolo del experimento	40
A.3.3. Adquisición de datos	40
B. Artefactos	41
C. Clasificador LDA	42
D. Clasificador SVM	44
E. Filtrado por hardware	45
F. Diagrama de Bode. Chebyshev II	46
G. Rizados filtro Elíptico	47
G.1. Filtrado causal	47
G.2. Filtrado no causal	48
H. Rizados filtro Chebyshev	49
H.1. Filtrado causal	49
H.2. Filtrado no causal	50

Índice de figuras

1.1. Esquema general de aplicaciones BMI.	1
1.2. Ejemplos de aplicaciones de una BMI.	2
2.1. Protocolo del ensayo.	5
2.2. Estructura del MRCP de un ensayo de un sujeto sano	6
2.3. Diagrama de bloques de una BMI	7
2.4. Proceso de extracción de características y clasificación.	9
2.5. Diferencias entre los filtros estudiados.	10
2.6. Canales utilizados en los filtros espaciales	13
2.7. MRCP con las zonas consideradas de ruido y señal utilizadas en el OSF.	14
2.8. Ejemplo de funcionamiento del matched filter en un ensayo.	16
2.9. Grand average y ensayos del MRCP. Canal Cz, sujeto 1.	17
3.1. Grandes averages de las distintas configuraciones del filtro Butterworth causal	19
3.2. Resultados de clasificación de los distintos filtros causales	20
3.3. Grandes averages de las distintas configuraciones del filtro Butterworth no causal	22
3.4. Resultados de clasificación de los distintos filtros causales	23
3.5. Grandes averages de los filtros elegidos.	24
3.6. Resultados de clasificación de los distintos filtros causales estudiados.	25
3.7. Respuesta en fase y frecuencia de los filtros elegidos.	25
3.8. Comparación entre los Grandes averages de los distintos filtros espaciales.	26
3.9. Comparación entre los distintos filtros espaciales y clasificadores.	26
3.10. Grandes averages de sujetos sanos y pacientes. Filtrado no causal	27
3.11. Evaluación del esquema en sujetos sanos y pacientes.	28
A.1. Montajes de EEG utilizados	38
C.1. Ejemplo del hiperplano de dos variables creado por LDA.	42
D.1. Ejemplo de funcionamiento de un clasificador SVM.	44
E.1. Respuesta del filtro Hardware y filtros estudiados	45

F.1. Diagrama de Bode de un Filtro Chebyshev II	46
G.1. Filtro elíptico causal. Rizados	47
G.2. Filtro elíptico causal. Rizados	48
H.1. Filtro Chebyshev causal. Rizados	49
H.2. Filtro Chebyshev no causal. Rizados	50

1. Introducción

1.1. Contexto y estado del arte

Las interfaces cerebro-computador (BMI, del inglés, brain-machine interface) son tecnologías que permiten la comunicación entre el cerebro y un dispositivo tecnológico. Éstas se dividen en dos grupos en función de la forma en la que obtienen la actividad cerebral: métodos invasivos, en los que se colocan electrodos sobre la corteza cerebral y métodos no invasivos, en los que se colocan sobre la superficie de la cabeza. Los primeros obtienen una señal más limpia al tomar los datos directamente del cerebro pero, debido al riesgo que supone la intervención quirúrgica necesaria y a las consideraciones éticas que conllevan, no son muy prácticos para muchas aplicaciones. Así pues, el hecho de que los métodos no invasivos no requieran de ningún tipo de cirugía hace posible validar sus innumerables aplicaciones de manera segura para el sujeto/paciente. Dentro de estos últimos la técnica más utilizada es la electroencefalografía, EEG, en la que los electrodos se colocan en la superficie del cuero cabelludo. Una vez obtenida, la actividad cerebral es procesada y transformada en comandos para el control de un dispositivo como un ordenador, un robot o una prótesis [1] [2] (Figura 1.1).

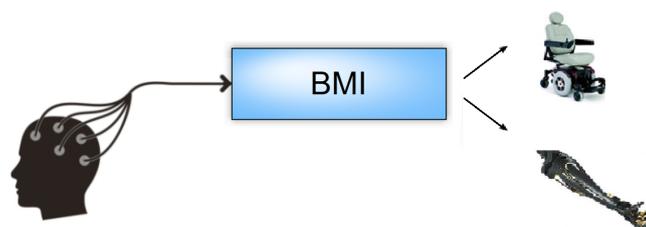


Figura 1.1: Esquema general de aplicaciones BMI.

Puesto que las BMIs constituyen una forma alternativa de comunicación entre el cerebro y el entorno, estas tecnologías ofrecen grandes posibilidades en el mundo de la rehabilitación y la compensación funcional en pacientes con problemas de movilidad, como pueden ser las víctimas de un accidente cerebrovascular (ictus) o de una lesión medular [1] [3] [4]. Estas aplicaciones basan su funcionamiento en obtener información de las señales cerebrales para que la BMI pueda conocer cuando el sujeto quiere ejecutar

un movimiento y dar la orden al periférico que controla (un exoesqueleto, por ejemplo) de realizar o completar dicho movimiento.

En la Figura 1.2a vemos un exoesqueleto controlado por una BMI y en la Figura 1.2b observamos a una BMI que ayuda al paciente a completar los movimientos de agarre en su mano izquierda mediante FES, estimulación eléctrica funcional [3]. En ambas figuras podemos apreciar como la señal es extraída mediante el gorro de EEG para ser procesada y transformada en comandos motores que finalmente son enviados tanto al exoesqueleto como a los electrodos que realizan la FES.



(a) Exoesqueleto controlado por BMI. (b) Compensación funcional mediante FES, controlada por BMI.

Figura 1.2: Ejemplos de aplicaciones de una BMI

Esta tarea de conocer cuando el sujeto quiere realizar un movimiento se puede realizar de diversas formas, como por ejemplo utilizando potenciales evocados (P300) o imaginación motora. Sin embargo, una de las principales formas de realizarlo es procesar las señales producidas por el cerebro de manera natural cuando se quiere realizar el movimiento, ya que permiten un control más sencillo e intuitivo para el sujeto [1]. Dentro de éstas se encuentran las sincronizaciones o desincronizaciones relacionadas con un evento, ERS/ERD (event-related synchronization/desynchronization) y los potenciales cerebrales relacionados con el movimiento, MRCP (motor-related cortical potentials).

Los ERS/ERD hacen referencia al incremento/decremento de la potencia en una determinada banda de frecuencia cuando se produce un evento, como puede ser un intento, una ejecución o una imaginación de movimiento. Éstos se miden en la banda de frecuencias de 8 entre a 30 Hz y son unas señales ampliamente estudiadas y utilizadas en este campo [5] [6]. Por su parte los MRCP consisten en cambios en la amplitud del EEG que se producen desde 1.5 segundos antes de la ejecución del movimiento y que se miden entre 0.1-1 Hz [7] [8]. Además existen estudios que sugieren que estas señales permiten una decodificación más precisa de la intención de movimiento [9].

Para extraer la actividad cerebral de interés, como podría ser el MRCP o el ERD/ERS, de la señal medida se aplica un filtro frecuencial. Además, con el fin de maximizar el ratio señal ruido se aplica un filtro espacial, que consiste en una combinación lineal

de varios canales (medida de cada electrodo). Posteriormente, se analiza esta información y se decide cuales son las mejores características para entrenar un clasificador que pueda decidir si la señal obtenida en que cada instante temporal corresponde a una comando motor u otro. Por último, dicho comando es enviado al periférico controlado por la BMI como puede ser un exoesqueleto o una silla de ruedas.

Aunque el esquema general de la BMI es el mismo en toda la bibliografía, en el caso concreto de los MRCP, encontramos gran diversidad tanto de filtros frecuenciales como de filtros espaciales y clasificadores. Con respecto a los filtros frecuenciales podemos encontrar filtros Butterworth paso banda entre (0.1-1 Hz) [10] [11], (0.1-2.5 Hz) [12], (0.05-3 Hz) [13], (0.05-10) [14] [15], o filtros paso bajo de 6 Hz [16]. Por su parte, los filtros espaciales más usados en la actualidad son el filtro de referencia de media común, CAR (common average reference) [10], el filtro espacial laplaciano, LLSF (large Laplacian spacial filter) [12] [14] [15] [17] o el filtro espacial óptimo, OSF (optimal spatial filter) [14] [10]. Y, por último, algunos de los clasificadores que se están usando actualmente en este campo son los clasificadores lineales (como el LDA, linear discriminant analysis) [10] [11] [15], clasificadores no lineales (SVM, support vector machine) u otras técnicas (matched filter) [14] [17].

1.2. Objetivos

El objetivo principal de este trabajo es estudiar, mediante una comparación sistemática, los distintos métodos utilizados para la implementación de un interfaz BMI que sea capaz de detectar la intención de movimiento utilizando MRPCs. Para la realización de este objetivo se han llevado a cabo los siguientes subobjetivos:

- Realización de un estudio del estado del arte.
- Selección de los distintos métodos a estudiar tanto a nivel de filtros frecuenciales como filtros espaciales y clasificadores.
- Selección de librerías y software disponible e implementación de métodos que requieran desarrollo.
- Evaluación de los distintos métodos tanto en sujetos sanos como en pacientes de ictus y pacientes de lesión medular.

1.3. Organización de la memoria

Este trabajo está dividido en cuatro capítulos, siendo el primero de ellos esta introducción. En el segundo se explicarán los datos empleados y los métodos utilizados para alcanzar los objetivos establecidos. En el tercero se detallarán los resultados obtenidos. Y en el cuarto se hablará sobre las conclusiones extraídas de estos resultados y del trabajo futuro que puede derivarse de este estudio.

2. Métodos

2.1. Introducción

En este capítulo se explicarán el conjunto de datos que se han utilizado y el esquema de decodificación de intención motora empleado en este estudio, así como las pruebas que se realizarán en sus distintas partes (filtrado frecuencial, filtrado espacial y clasificación).

Este estudio se va a realizar en dos fases: en primer lugar se va a realizar un análisis exhaustivo el proceso de decodificación sobre unos datos de sujetos sanos y en segundo lugar se probarán los métodos seleccionados en dos poblaciones de pacientes con deficits motores (pacientes de ictus y pacientes de lesión medular).

Debido a que el número de comprobaciones a realizar es muy alto, el análisis del proceso de decodificación se ha dividido en dos partes: en primer lugar se evaluarán distintos filtros frecuenciales con un filtro espacial y clasificador determinados y posteriormente, partiendo del filtro frecuencial elegido, se evaluarán los distintos filtros espaciales y clasificadores.

De esta forma, esta sección está dividida en cinco partes: una primera en la que se explicará la estructura del conjunto de datos a analizar, otra en la que se explicará detalladamente el esquema de decodificación de intención motora utilizado y otras tres en las que se explicarán los los filtros frecuenciales, espaciales y el clasificadores estudiados. Para terminar esta sección se detallarán las herramientas utilizadas y aquellas que ha sido necesario implementar durante la realización de este trabajo.

2.2. Conjunto de datos a analizar

Los datos que se van a analizar corresponden a ejecución de movimiento, de miembro inferior en sujetos sanos y pacientes de ictus y miembro superior en pacientes de lesión medular). Así pues este estudio se va a realizar en datos de disntintas poblaciones. Sin embargo el protocolo que siguieron es el mismo (ver Figura 2.1) en todos los casos, que consiste en un periodo de reposo tras el cual se le da al sujeto la orden de ejecutar el movimiento.

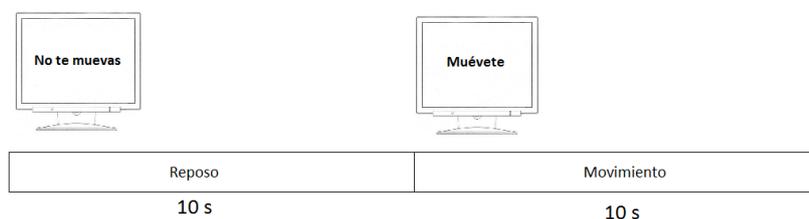


Figura 2.1: Protocolo de un ensayo. Nótese que en el utilizado en pacientes de lesión medular, el tiempo de reposo es 4 segundos.

Dado que el proceso de adquisición de datos no ha tenido lugar dentro de este trabajo, en este apartado se hará un breve resumen de la estructura de los datos a analizar y la forma en la que se obtuvieron. Para más información, ver Anexo A.

2.2.1. Datos de sujetos sanos

Este experimento lo llevaron a cabo diez sujetos. En él realizaron diez bloques de diez ensayos, durante los cuales se encontraban de pie, frente a una pantalla. Cada uno de estos ensayos se componía de dos partes: reposo y movimiento voluntario. La parte de reposo duraba 10 segundos en los cuales se pedía al sujeto que no realizase ningún movimiento, relajase sus músculos y fijase su mirada en un punto en la pantalla con el fin de evitar contaminar la señal medida con artefactos musculares y oculares (ver Anexo B). Tras estos 10 segundos aparecía en la pantalla una cruz, que indicaba que el sujeto podía comenzar a mover su pierna cuando quisiera, pero no antes de 1.5 segundos. Tras diez ensayos se realizaba un descanso de la duración deseada por el sujeto.

Dado que en este experimento el movimiento se ejecutaba cuando el sujeto lo decidía, para poder alinear los datos obtenidos al momento en el que se inicia el movimiento se colocó un interruptor en el pie del sujeto.

2.2.2. Datos de pacientes de ictus

El experimento fue el mismo que el realizado en sujetos sanos. Además, dado que estos pacientes no pueden ejecutar el movimiento de forma correcta, se grabó su señal electromiográfica, EMG, para detectar el momento en el que activan sus músculos. Este experimento fue realizado por diez sujetos, sin embargo, dado que estos datos están todavía siendo fruto de análisis, se han utilizado únicamente los datos correspondientes a los cuatro sujetos que presentaban una señal menos contaminada.

2.2.3. Datos de pacientes con lesión medular

Este experimento lo llevaron a cabo cuatro sujetos. En él realizaron cuatro bloques de 20 ensayos durante los cuales los pacientes se encontraban sentados frente a una pantalla. En cada uno de ellos en la pantalla se mostraba una orden de "Reposo" durante intervalos aleatorios de entre 4 y 7 segundos, seguido por la palabra "Movimiento" que permanecía durante 3 segundos. De esta forma los pacientes debían descansar o realizar intentos de mover su mano siguiendo las órdenes que se mostraban en la pantalla.

A diferencia de en los otros dos experimentos, en este el sujeto debía realizar el movimiento cuando recibía la orden y no cuando quisiera. Es por ello que estos datos han sido alineados a ese instante en el que se daba la orden, considerando que era en ese momento cuando comenzaba el movimiento.

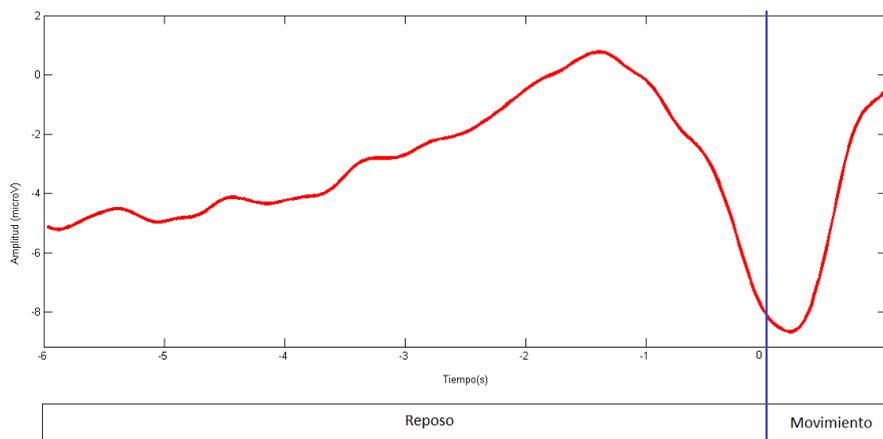


Figura 2.2: Estructura del MRCP de un ensayo de un sujeto sano

2.2.4. Estructura del ensayo a estudiar

Los datos que vamos a utilizar estarán compuestos por un número de ensayos (100 en sujetos sanos y pacientes de ictus y 80 en pacientes de lesión medular). En cada uno de estos ensayos el momento del movimiento vendrá precedido por, como mínimo, 4 segundos en los que el sujeto estuvo en reposo (ver Figura 2.2). Así pues, el instante 0 representará el momento en el que se ejecuta el movimiento (extraído mediante interruptor, EMG o momento de la presentación del estímulo visual).

2.3. Esquema de decodificación de intención motora

En una BMI, la señal pasa por una serie de etapas desde que es medida hasta que es traducida en comandos que son enviados a la aplicación que controla. Este trabajo no se centra en una aplicación concreta; el objetivo es mejorar este procesamiento de señal que utilizan este tipo de BMIs. Así pues, la señal, una vez adquirida es filtrada frecuentemente para separar la actividad cerebral de interés del resto de señal medida. Posteriormente se le aplica un filtrado espacial para maximizar el ratio señal ruido. Por último se extraen las características para entrenar un clasificador que posteriormente pueda determinar los comandos que serán enviados a la aplicación (ver Figura 2.3).

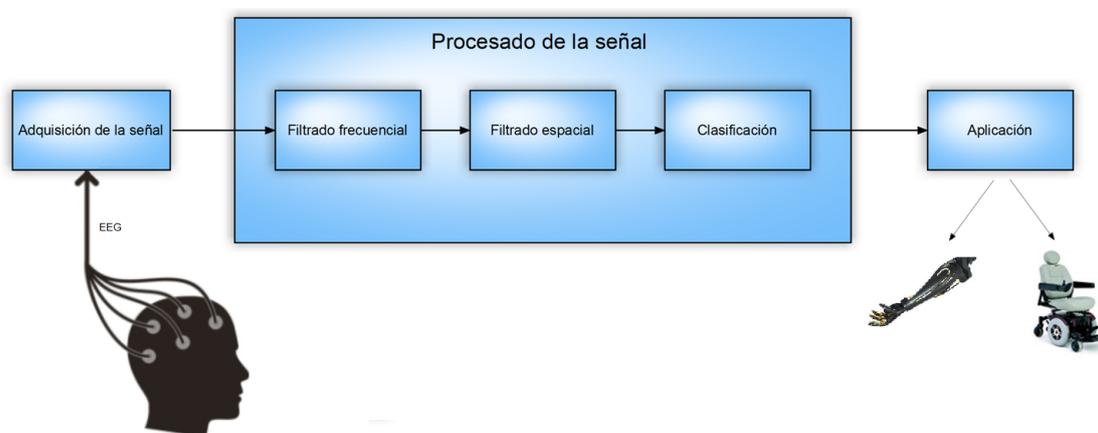


Figura 2.3: Diagrama de bloques de una BMI

En el esquema utilizado en este estudio, la actividad cerebral es obtenida mediante el EEG. Una vez obtenida, es filtrada mediante un filtro frecuencial para separar el MRCP del resto de actividad cerebral medida y, posteriormente, mediante el filtro espacial. Además, la señal, que fue tomada a 256 Hz, es subsampleada hasta los 32 Hz para reducir el volumen de datos con el que se trabajará en adelante. Una vez filtrada y subsampleada, esta señal es separada en ensayos, dentro de los cuales sabemos con certeza cuando el sujeto está en reposo y cuando ejecutando el movimiento. Estos ensayos van desde 6 segundos antes de la ejecución del movimiento (4 segundos en el caso de pacientes de lesión medular) hasta 1 segundo después. Para realizar esta decodificación, seleccionamos la señal de los canales pertenecientes al cortex motor que serán los que utilizaremos en adelante (FC1, FC2, C3, Cz, C4, CP1, CP2 en el caso de sujetos sanos y pacientes de ictus y FC3, FCz, FC4 C3, C1, Cz, C2, C4, CP3, CP1, CPz, CP2 y CP4 en el caso de pacientes de lesión medular, que fueron grabados con un montaje distinto, ver Anexo A).

Dado que queremos realizar una decodificación continua se utilizan ventanas deslizantes de 1 segundo de duración cada 0.125 segundos que serán las que el clasificador deba separar entre reposo o movimiento (ver Figura 2.4). De todas estas ventanas serán

consideradas de reposo aquellas que terminen antes de los 1.5 segundos previos a la ejecución del movimiento. Las ventanas que comiencen a partir de ese instante serán consideradas de movimiento evitando así el solapamiento entre ambas clases. Antes de ser clasificados, los valores de estos vectores son normalizados, con media cero y desviación típica uno, para evitar que las características con valores más elevados tengan un mayor peso en la clasificación. Además, como vamos a utilizar la señal de varios canales del EEG concatenamos las ventanas de cada canal de forma que obtenemos un vector de características con los valores de cada canal durante ese segundo. Así pues, el clasificador recibirá una matriz X con los valores del MRCP para cada instante, canal y ventana y un vector Y que indica a que clase (Movimiento o Reposo) pertenece cada ventana.

$$X \in \mathbb{R}^{(C \cdot T \cdot V)} \quad (2.1)$$

$$Y \in \mathbb{R}^V \quad (2.2)$$

donde C es el número de canales, T los instantes de tiempo (muestras) por ventana y V el número de ventanas.

Puesto que todos los clasificadores que vamos a estudiar son clasificadores de aprendizaje supervisado, necesitan un conjunto de datos de los que conozcan a que clase pertenecen para entrenar antes de poder clasificar nuevos datos (ver Figura 2.4). Como el número de ensayos de cada sujeto no es muy elevado para optimizar este volumen de datos de que disponemos se ha realizado una validación cruzada de los datos (cross-validation). Es decir, primero se ha entrenado el clasificador con los noventa primeros ensayos y se ha clasificado los otros diez, evaluando la actuación de el clasificador en estos últimos. Este proceso se ha realizado diez veces (ten-fold cross-validation) de forma que todos los ensayos han sido clasificados.

Como explicaremos más adelante (2.6.1), algunos clasificadores (como LDA o SVM) asignan a cada ventana una probabilidad de pertenecer a una clase u otra estableciendo el valor que separa las clases, threshold, en 0.5. Éstos minimizan el error en la clasificación de todas las ventanas pero, dado que en nuestro caso las clases no están balanceadas (hay más ventanas de la clase reposo que movimiento), el clasificador podría dar más peso a clasificar correctamente la clase reposo. Para evitar este funcionamiento no deseado del clasificador se ha realizado de nuevo una validación cruzada dentro de los datos de entrenamiento para ajustar el valor del threshold. En este caso se ha realizado un leave one out cross-validation (se entrena con $n-1$ ensayos y se clasifica el restante, este proceso se realiza n veces). Para evitar este comportamiento no deseado en la clasificación, dentro de esta validación cruzada se ha utilizado la misma métrica escogida para evaluar la actuación final del clasificador, el porcentaje de ensayos clasificados correctamente (ver 2.7.2).

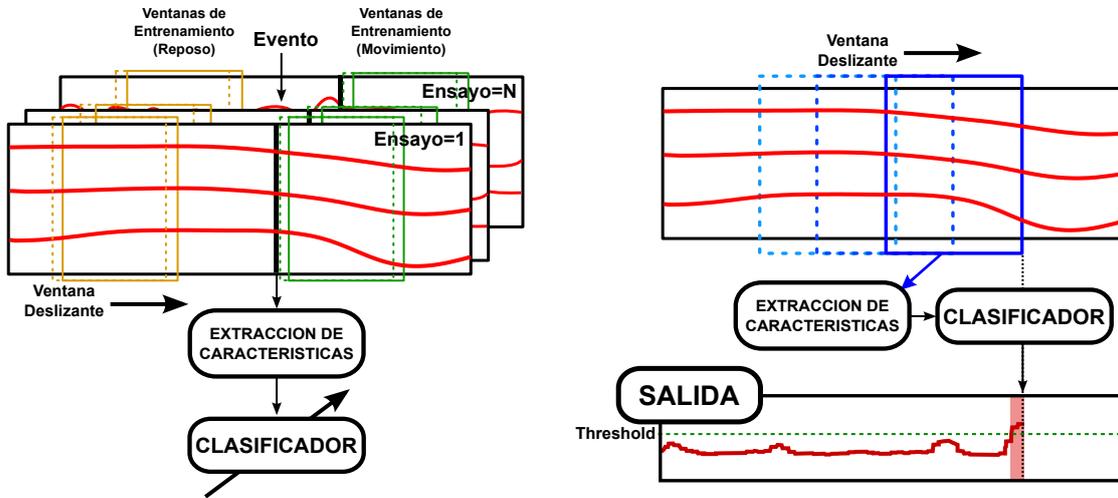


Figura 2.4: Proceso de extracción de características y clasificación.

2.4. Filtrado frecuencial

Un filtro frecuencial es un elemento que separa una determinada frecuencia o banda de frecuencias de una señal, pudiendo modificar tanto su amplitud como su fase. En este apartado se explicarán los distintos tipos de filtro y técnicas de filtrado que serán objeto de estudio en este trabajo.

Para estudiar la influencia del filtrado frecuencial en los resultados finales de clasificación se ha elegido un esquema de programa muy utilizado en la bibliografía actual [8] que aplica un filtrado espacial CAR (ver 2.5.1) y que, posteriormente, clasifica mediante el clasificador lineal LDA (ver 2.6.1).

2.4.1. Tipos de filtros frecuenciales

- **Filtro Butterworth**

El filtro Butterworth es uno de los filtros electrónicos más comunes. Su principal característica es que ofrece una respuesta lo más plana posible en su banda de paso, es decir no altera su amplitud. Además, se caracteriza porque en la frecuencia de corte su atenuación es siempre 3 dB, sin importar el orden del filtro. Fuera de la banda de paso la ganancia disminuye en $20n$ dB por década, donde n es el orden del filtro (ver Figura 2.5).

Para realizar este estudio hemos partido de uno de los filtros más usados, Butterworth (0.1-1) Hz de orden 2, y a partir de el hemos modificado tanto su banda de paso ([0.05-1], [0.1-1], [0.2-1], [0.3-1] y [0.1-1], [0.1-3], [0.1-5], [0.1-10]) como su

orden (1, 2, 4) con el fin de conseguir los mejores resultados de clasificación.

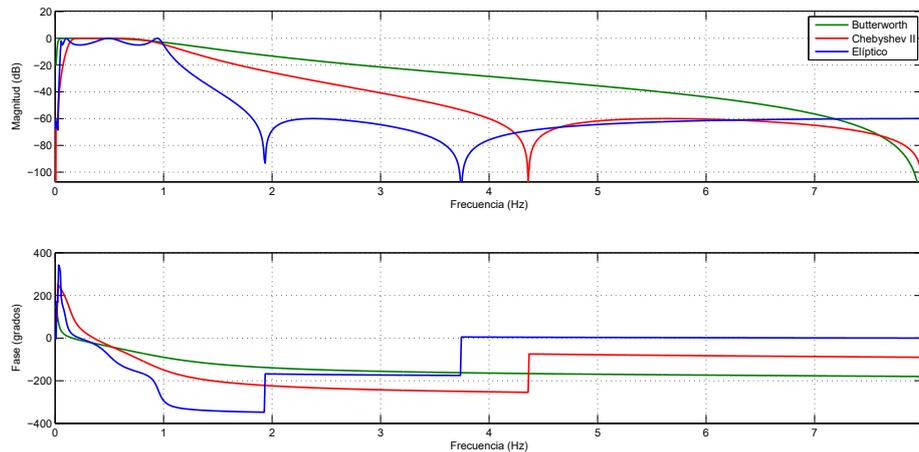


Figura 2.5: Diferencias entre los filtros estudiados.

• Filtro elíptico

El filtro elíptico es el que presenta una banda de transición más estrecha, pero por contra presenta un pequeño rizado tanto en la banda de paso como en la de rechazo. Además presentan una fase poco lineal en su banda de paso (ver Figura 2.5). Para optimizar el filtro elíptico hemos utilizado las mismas bandas de frecuencias y órdenes que en el caso del filtro Butterworth a excepción de la banda de paso (0.05-1) Hz que no ha sido estudiada por los motivos explicados en el Anexo E.

• Filtro Chebyshev II

El filtro Chebyshev II presenta una banda de rechazo más estrecha que el Butterworth, pero más ancha que el elíptico. Además, a diferencia del elíptico, presenta únicamente rizado dentro de la banda de rechazo. (ver Figura 2.5).

Este filtro, a diferencia de los anteriores, atenúa considerablemente los valores límite de la banda de paso (10 dB, para los parámetros elegidos en este estudio ver 3.2.1.3). Es por ello que, en el caso del filtro Chebyshev II, las bandas de paso y órdenes evaluados son distintas a las de los otros filtros. Así pues se probarán bandas de paso de [0.05-2], [0.1-2], [0.2-2], [0.2-2] y [0.1-1], [0.1-5], [0.1-10] y los órdenes 4, 6, 8 y 10.

2.4.2. Técnicas del filtrado frecuencial

Existen distintas técnicas de filtrado que se pueden dividir entre causales y no causales. Dado que las posibles aplicaciones del esquema de decodificación elegido dependen de la causalidad del mismo, en este trabajo se realizará un estudio independiente de cada una de estas dos técnicas.

Si nuestro objetivo es estudiar la morfología de la señal o realizar un análisis offline de distintos métodos de decodificación [8] [10], podremos utilizar un filtrado no causal ya que obtendremos una señal más limpia [7]. Sin embargo, si el objetivo de nuestro esquema de decodificación de intención motora es ir integrado en una aplicación que opere en tiempo real (como puede ser un sistema que controle un exoesqueleto) deberemos realizar el estudio aplicando una técnica de filtrado causal [13] ya que es la única realizable.

- **Filtrado causal**

Se considera que una técnica de filtrado es causal cuando utiliza sólo los valores pasados y presentes de entrada para calcular el valor actual de salida del filtro. Este tipo de filtrado es aplicable en tiempo real. Para ello la señal es filtrada en una única dirección, como lo haría en una aplicación en tiempo real.

- **Filtrado no causal**

Un filtrado no causal es aquel que utiliza valores futuros de entrada del filtro para calcular la salida actual. Un ejemplo de este tipo de filtrado, y el que se va a utilizar en este trabajo, es el filtrado fase cero (zero phase) que consiste en filtrar la señal en una dirección y posteriormente, filtrarla de nuevo en la dirección opuesta consiguiendo así una respuesta de fase cero.

2.5. Filtros espaciales

Los filtros espaciales tienen como objetivo maximizar el ratio señal ruido de cada canal modificando su valor mediante una combinación lineal de un conjunto de canales. Son, en otras palabras, un re-referenciado de la señal.

Para realizar este estudio sobre distintos filtros espaciales se ha utilizado un esquema como el explicado en el apartado 2.3 en el que se aplicarán distintos filtros espaciales (CAR, LLSF y OSF). Para este apartado se ha utilizado el filtro Butterworth orden 2 (0.05-1) Hz en el estudio causal y filtro Butterworth orden 2 (0.1-1) Hz en el no causal (ver 3.2).

Para terminar, se estudiará la forma en la que estos filtros afectan a morfología

de la señal obtenida mediante el Grand Average, media de todos los ensayos de un sujeto (ver 2.7.1) y se evaluarán los resultados de clasificación mediante la métrica de porcentaje de ensayos clasificados correctamente (ver 2.7.2).

2.5.1. CAR

El filtro CAR, referencia de media común (Common Average Reference), es un filtro espacial que consiste en restar al valor de un canal el valor del promedio de todos los canales en ese instante de tiempo de la siguiente forma:

$$X_{CAR}^C = X^{C \cdot t} - \bar{X}^t, \quad \forall c \in C, \quad \forall t \in T \quad (2.3)$$

Donde \bar{X} es la media de todos los canales en cada instante temporal:

$$\bar{X} = \frac{1}{C} \sum_{i=1}^C X^{i \cdot t} \quad \forall t \in T \quad (2.4)$$

X = datos sin re-referenciar, C = número de canales y T = Instantes de tiempo (muestras)

$$X \in \mathbb{R}^{C \cdot T} \quad (2.5)$$

En este análisis, el filtro CAR aplicado utiliza los canales (F3, Fz, F4, FC5, FC1, FC2, FC6, T7, C3, Cz, C4, T8, CP5, CP1, CP2, CP6, P3, Pz y P4) (ver Figura 2.6a) evitando utilizar los más exteriores ya que su señal puede estar contaminada por artefactos, lo que acabaría afectando a los canales de interés [?].

2.5.2. LLSF

Los filtros Laplacianos buscan re-referenciar el valor de un canal a la media de sus canales vecinos. En el caso concreto del LLSF, filtro espacial laplaciano grande (large Laplacian spatial filter), debemos restar a cada canal la media de cuatro canales vecinos que no sean contiguos. Por ejemplo, para filtrar el canal Cz los canales vecinos serían Fz, C3, C4 y Pz (ver Figura 2.6b) en cada instante temporal.

Así pues, para cada canal, la señal filtrada mediante un filtro espacial LLSF

de canales que maximice la varianza en el tiempo de la señal (pico de negatividad más pronunciado) y minimice la del ruido. Esto se ha conseguido minimizando el SNR, ratio señal ruido, que es:

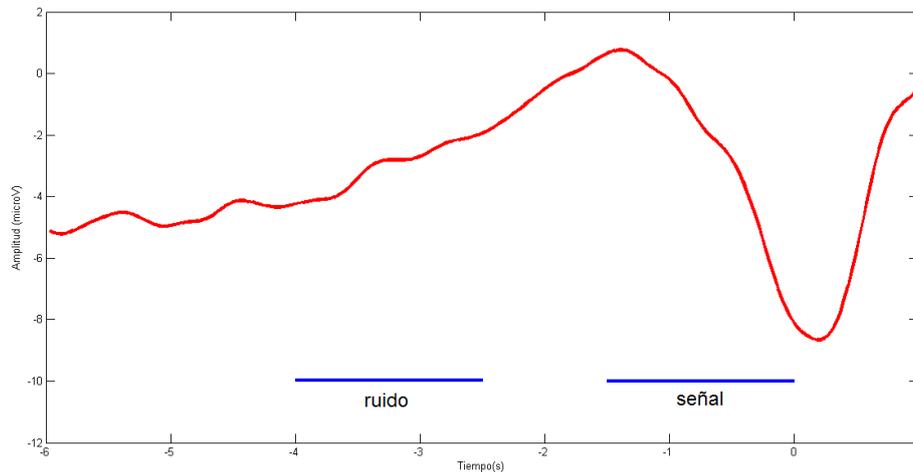


Figura 2.7: MRCP con las zonas consideradas de ruido y señal utilizadas en el OSF.

$$SNR = 10 * \log_{10}\left(\frac{P_S}{P_N}\right) \quad (2.8)$$

donde P_S y P_N son la varianza de la señal y del ruido respectivamente.

2.6. Clasificadores

El estudio de la influencia de los distintos clasificadores en los resultados finales de clasificación se ha realizado junto con el de los filtrado espaciales (ver 2.5). En él se ha evaluado el impacto de los distintos filtrados espaciales en cada uno de los clasificadores a estudiar. Los clasificadores que van a ser objeto de estudio van a ser: un clasificador lineal (Linear discriminant analysis, LDA), el clasificador no lineal (support vector machine, SVM) y otras técnicas de clasificación (matched filter). De esta forma obtendremos, en lugar de un resultado para cada clasificador, una matriz con los resultados de cada clasificador para cada filtro espacial.

2.6.1. LDA

El LDA o análisis de discriminación lineal es un clasificador que busca el hiperplano que mejor separa los datos de las distintas clases. Para ello el clasificador

supone que los datos tienen distribución gaussiana y una matriz de covarianza igual para ambas clases. Para más información sobre el funcionamiento interno del clasificador LDA, ver Anexo C.

2.6.2. SVM

Las SVM, máquinas de soporte vectorial (Support Vector Machines) son un método de aprendizaje supervisado que busca un hiperplano que separe ambas clases. Para ello busca el hiperplano que maximice la distancia entre puntos de entrenamiento más cercanos. Además, a diferencia del LDA, este clasificador permite crear fronteras de decisión no lineales utilizando funciones kernel. De esta forma el clasificador mapea los datos en un espacio de muchas dimensiones en el que las clases sean más separables. Más información sobre el funcionamiento del clasificador en Anexo D.

2.6.3. Matched filter

Este método de clasificación consiste extraer un patrón de la señal que queremos detectar de alguna señal conocida, en nuestro caso de los ensayos utilizados para entrenar el clasificador. Posteriormente, cada ventana de señal es correlada con este patrón de señal que queremos detectar.

En este estudio el patrón, de un segundo de longitud, será extraído desde un segundo antes del mínimo del MRCP en la zona de movimiento (ver Figura 2.8). Para este método consideramos la zona de movimiento, donde buscaremos el mínimo, entre $(-1.5, +1)$ siendo 0 el instante en el que se ejecuta el movimiento. Ampliamos esta zona hasta un segundo después ya que el mínimo del MRCP se suele encontrar ligeramente retrasado con respecto al comienzo de la ejecución del movimiento [12].

Una vez extraído el patrón y correladas todas las ventanas deslizantes del conjunto de datos de entrenamiento, ajustamos el valor del threshold con el fin de obtener los mejores resultados posibles en la métrica de clasificación del ensayo completo. Para ello, de la misma forma que hemos explicado en 2.3, hacemos un leave one out cross-validation con los ensayos de entrenamiento. Una vez extraído el patrón y ajustado el threshold el clasificador está listo para clasificar nuevas ventanas.

En resumen, se extrae el patrón de los datos de entrenamiento y se correla con todas las ventanas que debemos clasificar. Como podemos ver en la Figura 2.8, cuando el coeficiente de correlación supera el threshold (figura inferior) la ventana es clasificada como movimiento. Ésta va desde el momento en el que el threshold es superado hasta un segundo antes).

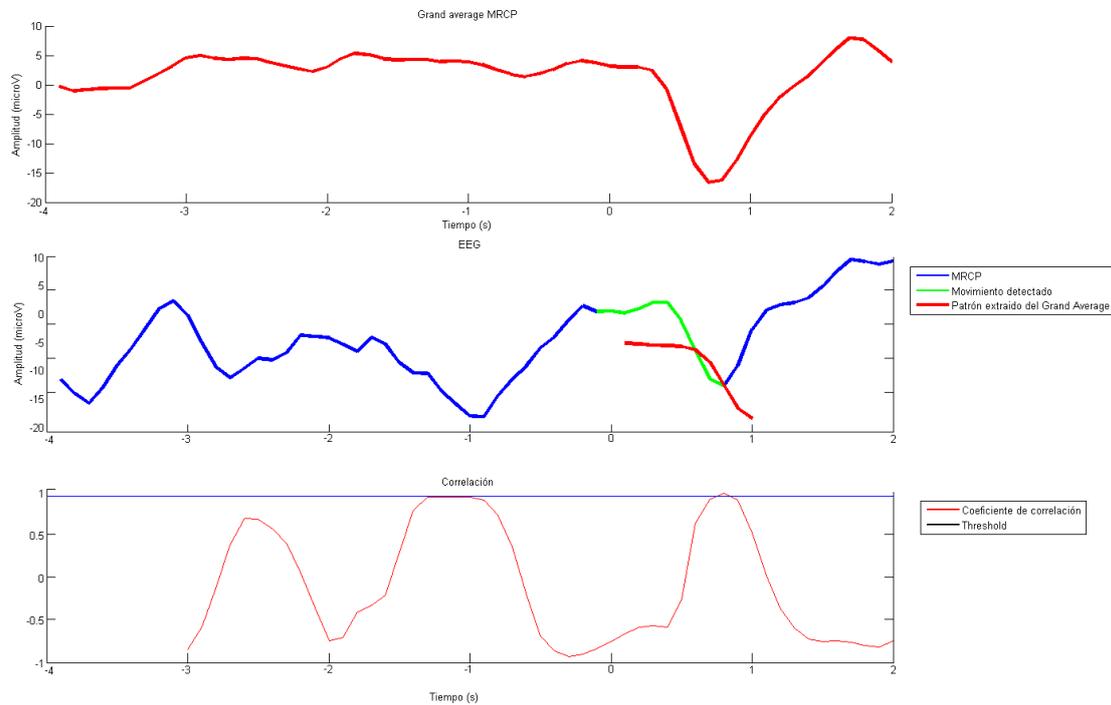


Figura 2.8: Ejemplo de funcionamiento del matched filter en un ensayo.

2.7. Métricas

2.7.1. Grand average

El Grand average es la media de todos los ensayos de un sujeto (ver 2.9). Es una métrica ampliamente usada en neurociencia para visualizar el patrón medio de activación [7]. Debido al bajo ratio señal ruido que tienen estas señales cerebrales, la forma de los MRCP es estudiada habitualmente utilizando su Grand average [8]. De esta forma, al mediar muchos ensayos, conseguimos eliminar el ruido y observar la forma de esta señal cerebral de una manera clara.

2.7.2. Porcentaje de ensayos clasificados correctamente

Esta métrica consiste en considerar un ensayo bien clasificado cuando la decodificación realizada permitiría a la BMI lanzar el movimiento del dispositivo correctamente. Es decir, que no generemos ninguna falsa activación durante el período de reposo y que generemos, al menos, una durante el periodo de movimiento.

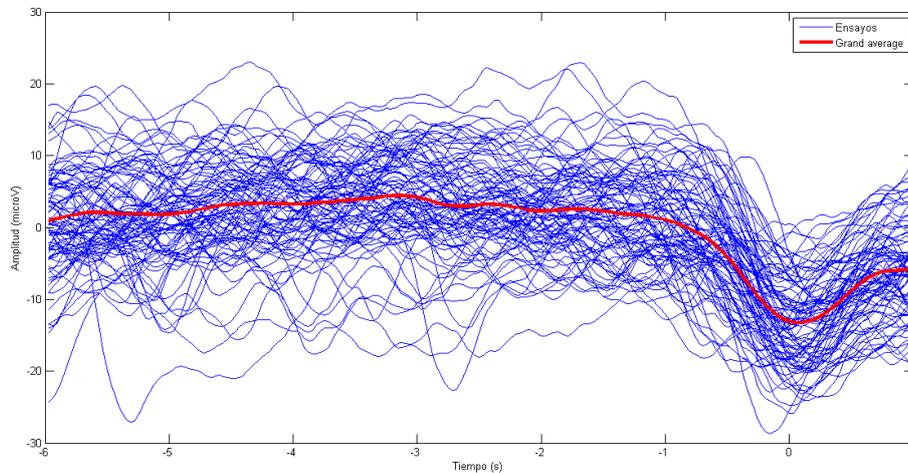


Figura 2.9: Grand average y ensayos del MRCP. Canal Cz, sujeto 1.

2.8. Herramientas utilizadas y trabajo implementado

Para la realización de este estudio, se ha utilizado la herramienta de software matemático Matlab (The MathWorks, Inc.) en la que se ha llevado a cabo el siguiente trabajo:

- Implementación de los scripts necesarios para realizar un filtrado frecuencial de las señales de acuerdo a los filtros ya disponibles de Matlab Butterworth, Elíptico y Chebyshev II.
- Implementación de los métodos de filtrado espacial CAR, LLSF y OSF.
- Implementación de los scripts utilizados para la extracción de características y entrenamiento de los clasificadores utilizados.
- Implementación los scripts necesarios para llevar a cabo los distintos métodos de cross-validation utilizados.
- Utilización del clasificador LDA implementado por Matlab y selección de la librería del clasificador SVM a utilizar.
- Implementación del clasificador Matched filter.
- Implementación las métricas utilizadas de Grand average y porcentaje de trials bien clasificados.

3. Resultados

3.1. Introducción

En este apartado se mostrarán los resultados obtenidos durante el estudio de las distintas partes del esquema de decodificación de intención motora basado en MRCP. Los resultados se mostrarán divididos en tres partes: filtrado frecuencial, filtrado espacial, clasificación y estudio de resultados en pacientes. Todas ellas mostrarán, por separado, los resultados para filtrados causales y no causales.

3.2. Estudio del filtrado frecuencial

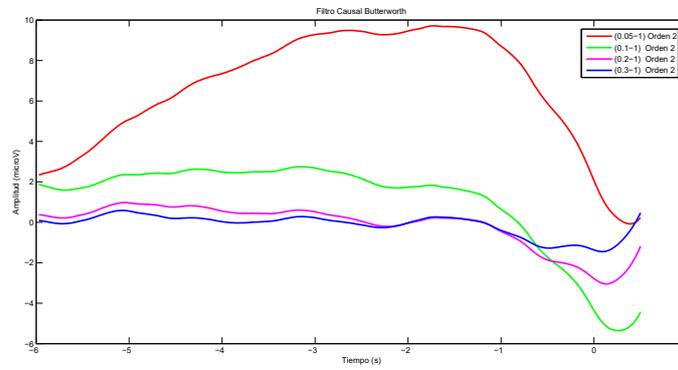
3.2.1. Filtrado causal

3.2.1.1. Filtro Butterworth

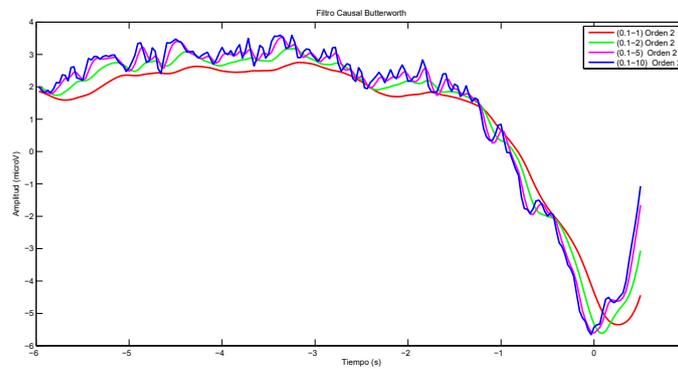
Para realizar este estudio hemos partido de uno de los filtros más usados, Butterworth (0.1-1) Hz de orden 2, y a partir de el hemos modificado tanto su banda de paso como su orden con el fin de conseguir los mejores resultados de clasificación.

En la Figura 3.1 podemos observar como afectan los distintos valores de banda de frecuencia y orden estudiados a la forma del Grand average. En ella podemos ver que para las bandas de paso (0.2-1) Hz y (0.3-1) Hz el MRCP tiene una negatividad mucho menos pronunciada (Figura 3.1a), lo que hará que sea mas difícilmente clasificable. Por su parte, el aumentar el valor limite superior de frecuencia no cambia sustancialmente la forma del MRCP, únicamente añaden ruido. Además podemos observar (Figura 3.1c) que órdenes superiores a 2 también atenúan la forma el MRCP.

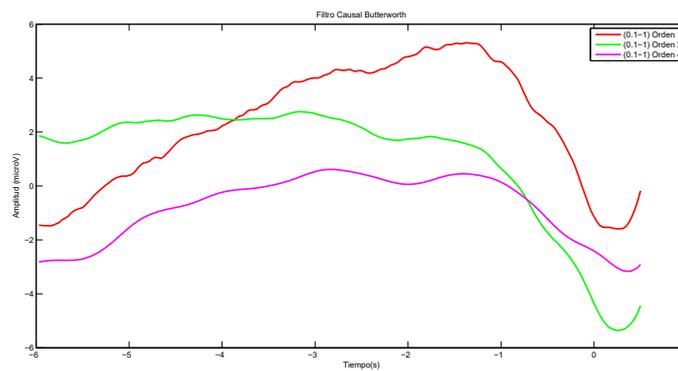
En la Figura 3.2a en la que se muestran los resultados de clasificación obtenidos para las distintas configuraciones del filtro Butterworth, podemos ver que para el filtro Butterworth (0.05-1) Hz de orden 2 obtenemos el mejor resultado de clasificación, un 0.55 ± 0.12 %. En lo referente al límite superior de la banda de paso vemos que no existe diferencia apreciable (apenas un 2%) para los valores probados.



(a) Variación del límite inferior de frecuencia de la banda de paso.

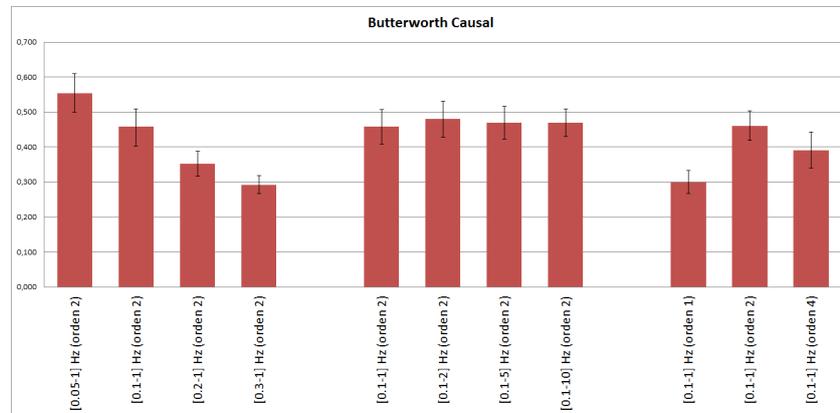


(b) Variación del límite superior de frecuencia de la banda de paso.

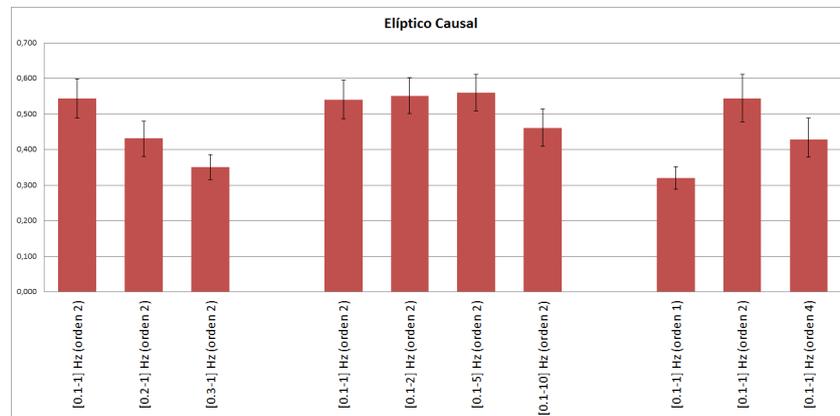


(c) Variación del orden del filtro.

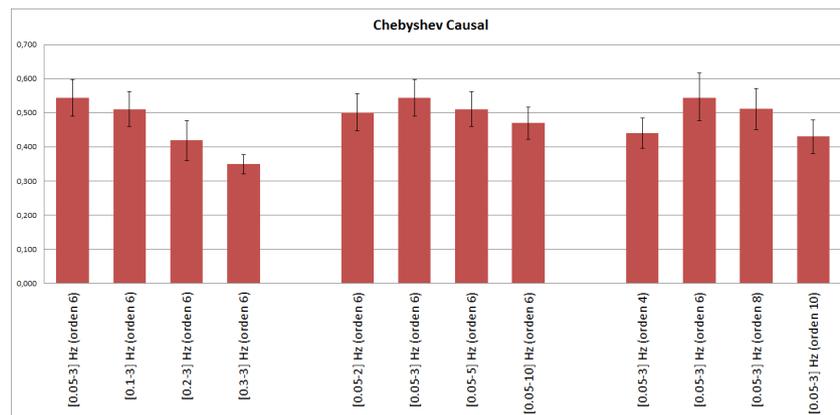
Figura 3.1: Grandes averages de las distintas configuraciones del filtro Butterworth causal.



(a) Butterworth.



(b) Elíptico.



(c) Chebyshev II.

Figura 3.2: Resultados de clasificación de los distintos filtros causales. Selección de parámetros.

3.2.1.2. Filtro Elíptico

El filtro elíptico presenta un rizado tanto en la banda de paso como en la de rechazo por lo que, para elegir el filtro elíptico deseado, debemos ajustar estos valores de rizado. Los valores de rizado obtenidos son 0.1 dB para la banda de paso y 90 para la banda de rechazo (Detalles en Anexo G.1). Los resultados mostrados en adelante para el filtro elíptico han sido obtenidos utilizando estos valores de rizado. Así pues, el filtro elíptico que mejores resultados de clasificación consigue es el filtro elíptico (0.1-1) Hz de orden 2 que obtiene un 0.54 ± 0.10 % (Figura 3.2b). Se ha estudiado la forma en que afectan las distintas configuraciones del filtro a la morfología del Grand average pero, dado que las conclusiones son similares a las extraídas del estudio del filtro Butterworth se ha decidido incluir en esta memoria únicamente los pertenecientes a este último.

3.2.1.3. Filtro Chebyshev II

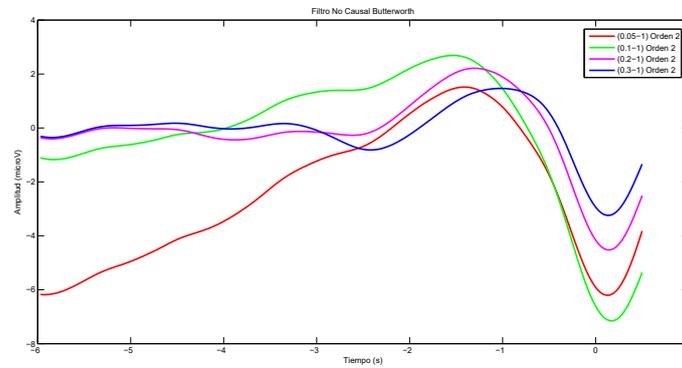
De la misma forma que en el estudio del filtro elíptico, los valores de rizado han sido optimizados por separado. El valor de rizado de la banda de rechazo obtenido en dicho estudio y el que se utilizará en adelante es 10 dB (detalles en Anexo H.1). Así pues, como podemos apreciar en la Figura 3.2c, los parámetros del filtro que mejores resultados otorgan son un filtro Chebyshev (0.05-3) de orden 6 que obtiene unos resultados de clasificación de 0.54 ± 0.09 %.

3.2.2. Filtrado no causal

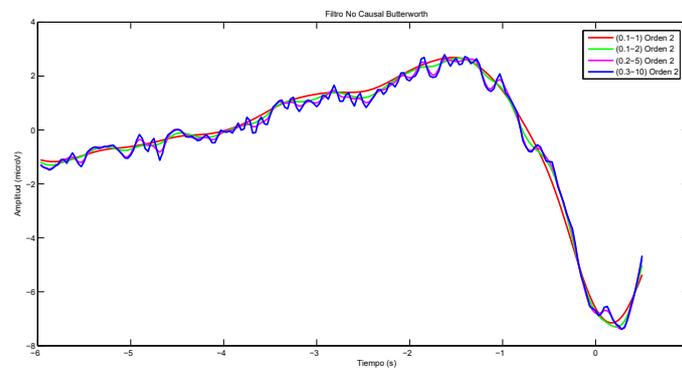
3.2.2.1. Filtro Butterworth

De igual forma que en el filtrado causal, hemos tomado como punto de partida el filtro más usado, Butterworth (0.1-1) Hz y orden 2. En la Figura 3.3 podemos ver como afecta cada una de las configuraciones del filtro Butterworth no causal a la forma final del MRCP. En ella podemos observar que, al tratarse de un filtrado fase cero, las diferencias entre las distintas configuraciones son mucho menores que en el caso del filtrado causal. Además podemos observar que los MRCPs tienen todos su mínimo en el mismo instante temporal, cosa que no ocurría cuando el filtrado sí afectaba a la fase.

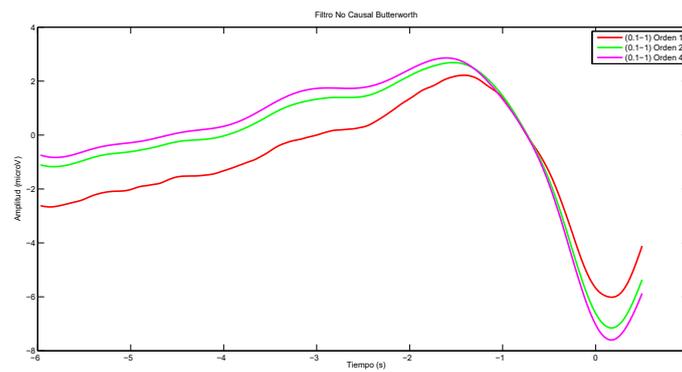
En la Figura 3.4a se muestran los resultados de clasificación obtenidos para cada configuración estudiada del filtro Butterworth no causal. En ella observamos que el mejor resultado lo encontramos con el filtro Butterworth (0.1-1) Hz de orden 2 que presenta un resultado de clasificación de 0.73 ± 0.14 %.



(a) Variación del límite inferior de frecuencia de la banda de paso.

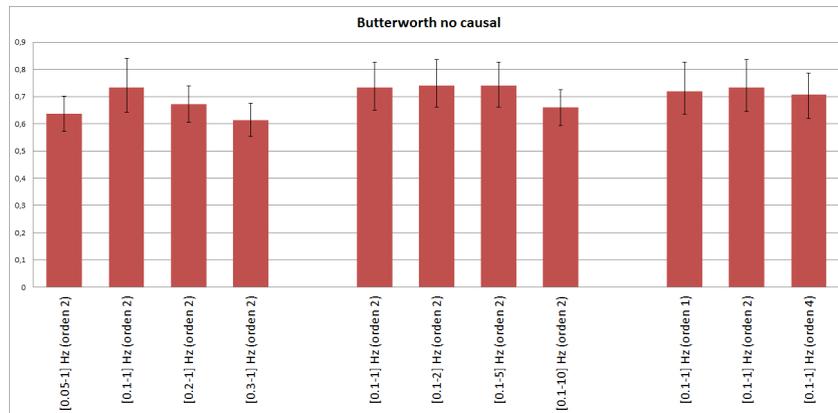


(b) Variación del límite superior de frecuencia de la banda de paso.

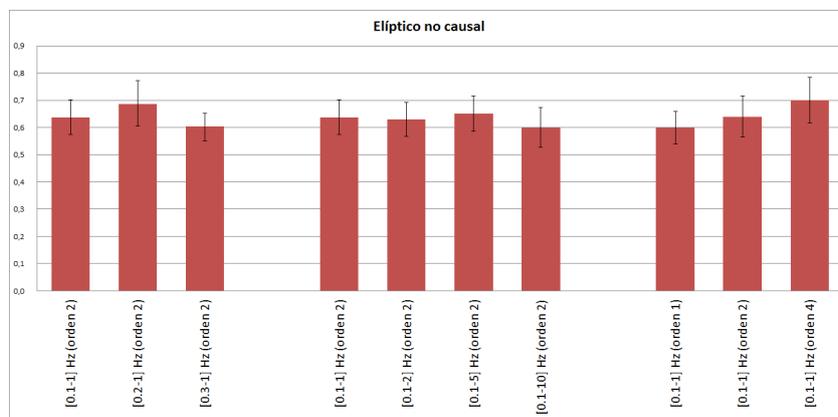


(c) Variación del orden del filtro.

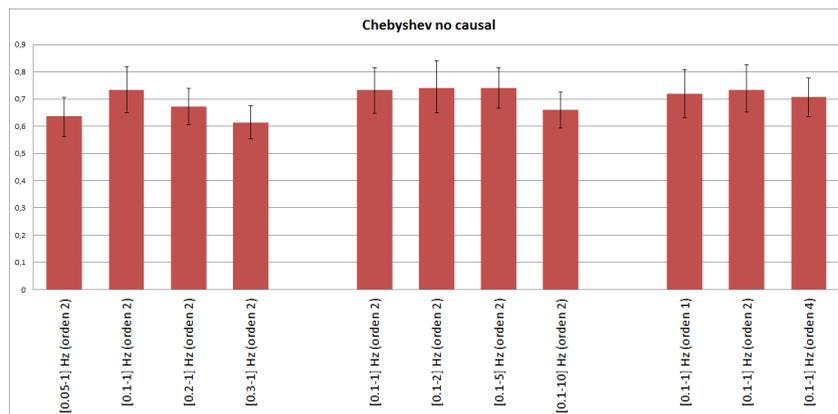
Figura 3.3: Grandes averages de las distintas configuraciones del filtro Butterworth causal.



(a) Butterworth.



(b) Elíptico.



(c) Chebyshev II.

Figura 3.4: Resultados de clasificación de los distintos filtros no causales. Selección de parámetros.

3.2.2.2. Filtro Elíptico

Para optimizar el filtro elíptico hemos partido de la misma banda de frecuencias y orden que en el caso anterior. Los valores obtenidos han sido un rizado paso banda de 0.2 y de 90 en la banda de rechazo (Detalles G.2). Así pues, el filtro elíptico que mejores prestaciones nos ofrece, Figura 3.4b, es el filtro elíptico (0.1-1) Hz de orden 4 que obtiene un resultado de 0.69 ± 0.13 % .

3.2.2.3. Filtro Chebyshev II

Para la evaluación del filtro Chebyshev II no causal, se han estudiado los mismos valores que los obtenidos en el estudio causal de dicho filtro. El valor de rizado de la banda de rechazo obtenida ha sido 10 dB (detalles Anexo H.2). En vista de los resultados mostrados en la Figura 3.4c, el filtro Chebyshev II que mejor resultados obtiene es el (0.1-3) Hz de orden 4 que presenta unos resultados de clasificación de 0.70 ± 0.16 %.

3.2.3. Comparación de los filtros

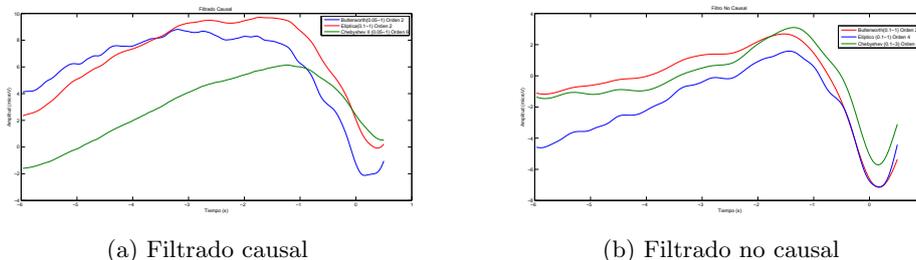


Figura 3.5: Grandes averages de los filtros elegidos.

Si observamos la Figura 3.6 en la que se muestran los resultados de clasificación de cada uno de los filtros estudiados podemos ver que no existen grandes diferencias entre ellos. De hecho, si observamos tanto los Grandes averages de estos filtros, Figura 3.5, como el diagrama de bode de los filtros elegidos, Figura 3.7, podemos apreciar que estos filtros, aunque con configuraciones algo distintas, tienen un comportamiento muy similar.

Por lo tanto seleccionamos para nuestro clasificador el filtro Butterworth (0.05-1) Hz de orden 2 para el estudio causal que presenta unos resultados de 0.55 ± 0.12 % y el Butterworth (0.1-1) Hz de orden 2 para el no causal que obtiene un resultado de 0.73 ± 0.14 % . Si analizamos la probabilidad de un esquema de decodificación

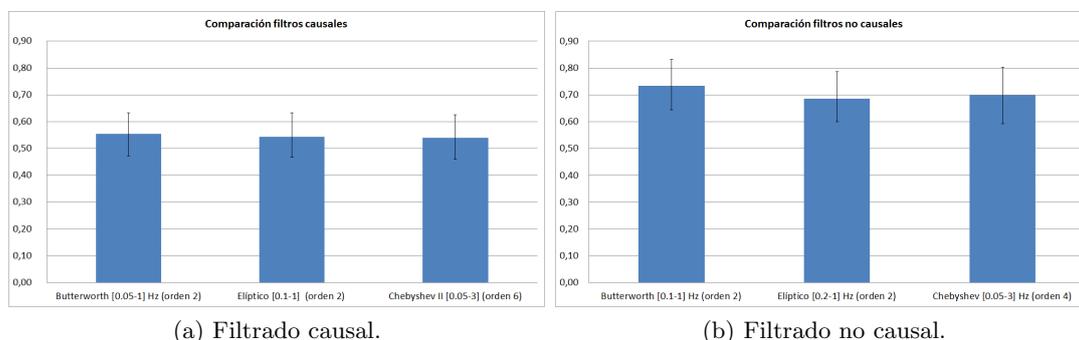


Figura 3.6: Resultados de clasificación de los distintos filtros no causales. Selección de parámetros.

aleatorio de realizar una decodificación correcta observamos que tiene una probabilidad del 4 % de clasificar correctamente un ensayo (con la métrica utilizada en este estudio). Así pues, podemos concluir que el esquema de decodificación propuesto añade una importante mejora a los resultados finales de clasificación.

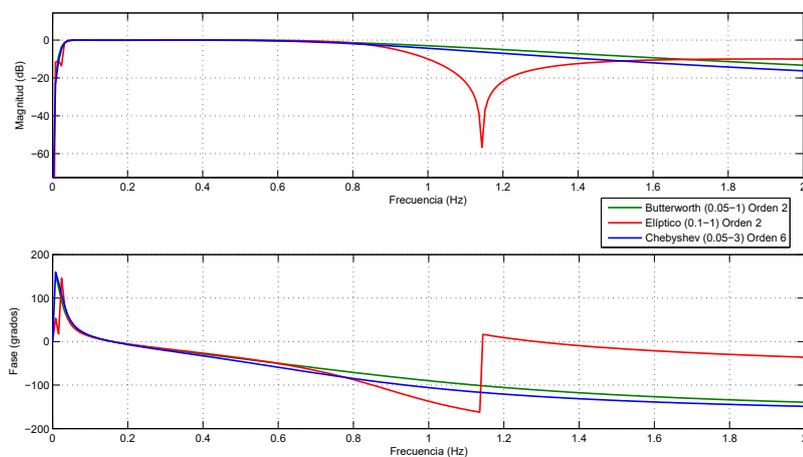
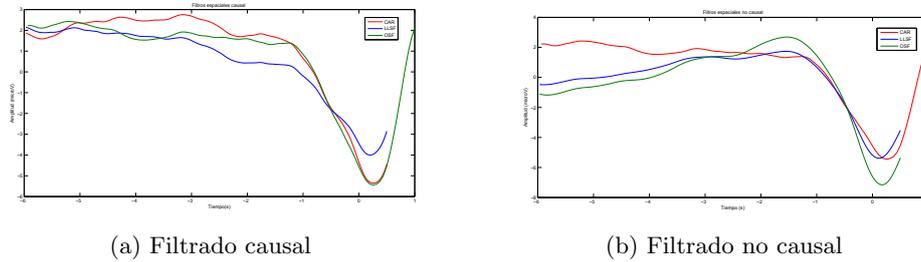


Figura 3.7: Respuesta en fase y frecuencia de los filtros elegidos.

3.3. Análisis del filtrado espacial y clasificación

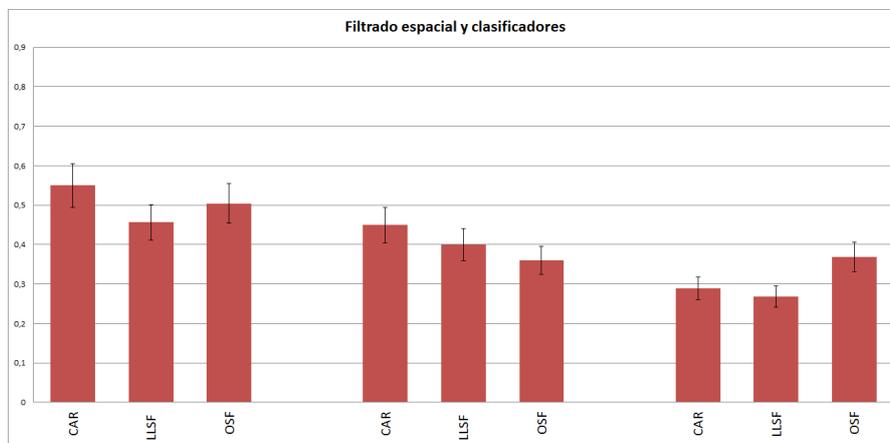
En la Figura 3.8, que muestra los grandes averages de la señal después de ser filtrada por el filtro frecuencial elegido y por cada uno de los filtros espaciales, podemos observar que no existen grandes diferencias entre las formas del MRCP obtenido tanto en el estudio causal como en el no causal.



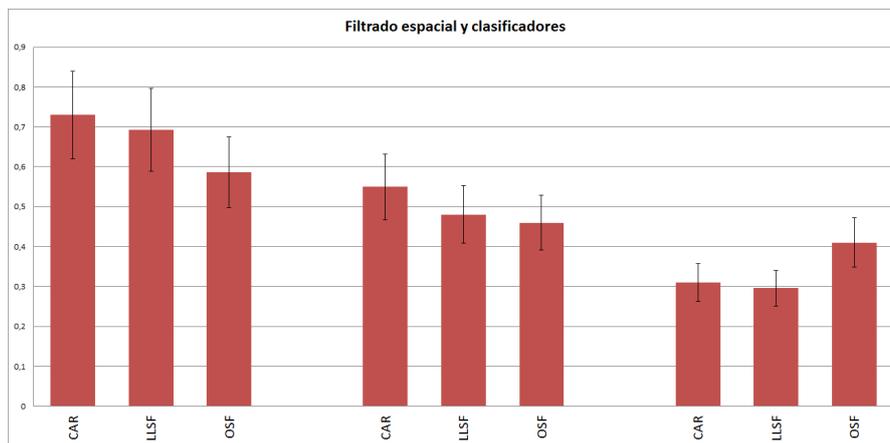
(a) Filtrado causal

(b) Filtrado no causal

Figura 3.8: Comparación entre los Grandes averages de los distintos filtros espaciales.



(a) Filtrado causal



(b) Filtrado no causal

Figura 3.9: Comparación entre los distintos filtros espaciales y clasificadores.

La Figura 3.9 muestra los resultados de clasificación para cada filtro espacial y clasificador estudiados. En ella podemos observar que, tanto utilizando un filtrado

causal como no causal, obtenemos los mejores resultados de clasificación para un esquema de decodificación de movimiento que utiliza un filtro CAR y que clasifica mediante el clasificador lineal LDA siendo estos resultados de 0.55 ± 0.12 % en el caso del filtrado causal y de 0.73 ± 0.14 % en el no causal. Así pues, esta será la configuración utilizada durante el resto de este estudio, junto con el filtro Butterworth elegido anteriormente (ver 3.2.3)

3.4. Evaluación en pacientes

En esta sección se van a mostrar los resultados de la configuración elegida tanto en los datos de sujetos sanos como en pacientes de ictus y pacientes de lesión medular.

Si observamos además los grandes averages de los tres conjuntos de datos estudiados, figura 3.10, podemos apreciar como en el momento del movimiento, los datos del MRCP de pacientes con lesión medular tienen una negatividad menos pronunciada que en el caso de los sujetos sanos lo que puede repercutir en un peor resultado de clasificación.

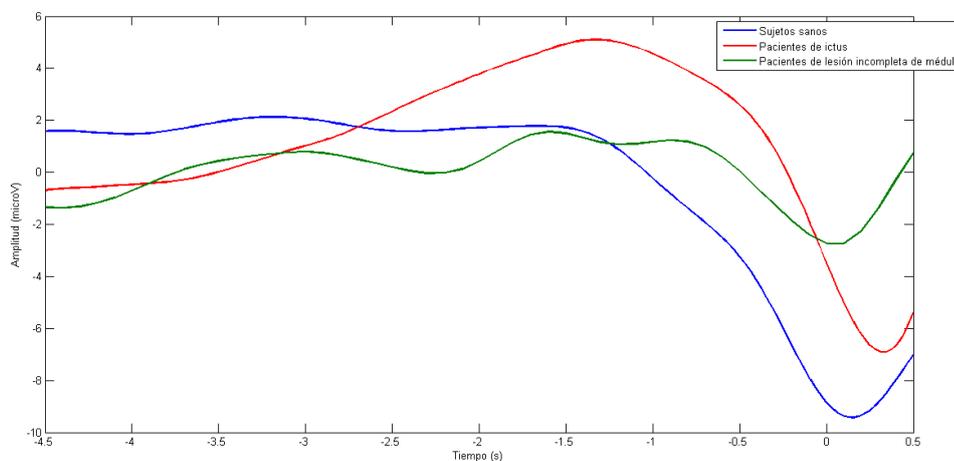


Figura 3.10: Grandes averages de sujetos sanos y pacientes. Filtrado no causal

La Figuras 3.11 muestra los resultados de clasificación obtenidos por el esquema de decodificación elegido en los tres conjuntos de datos (sujetos sanos, pacientes de ictus y pacientes de lesión medular) para los filtrados causal y no causal respectivamente. En ella podemos ver que los resultados obtenidos por los sujetos sanos son $0.55 \pm 0,12$ % en el caso del filtrado causal y de 0.73 ± 0.14 % en el no causal. Además, vemos que los pacientes de ictus son clasificados con un resultado de 0.60

± 0.08 % en el caso del filtrado causal y de 0.81 ± 0.14 % en en caso del filtrado no causal. Y por último, los pacientes de lesión medular obtienen unos resultados de clasificación de 0.34 ± 0.21 % en el caso causal y 0.44 ± 0.24 % en el no causal.

Así pues, si observamos los resultados de los pacientes de ictus vemos que obtienen unos resultados superiores a los de los sujetos sanos. Esto podría deberse a que los datos estudiados de estos pacientes se corresponden a los cuatro sujetos presentaban una señal más limpia, ver 2.2.1. Al evaluar el esquema elegido en datos de pacientes de lesión medular observamos que existe una caída de alrededor 20% en los resultados de pacientes con lesión medular en relación a los obtenidos para sujetos sanos. Esto podría deberse tipo de protocolo utilizado y al distinto miembro involucrado en el movimiento (miembro superior).

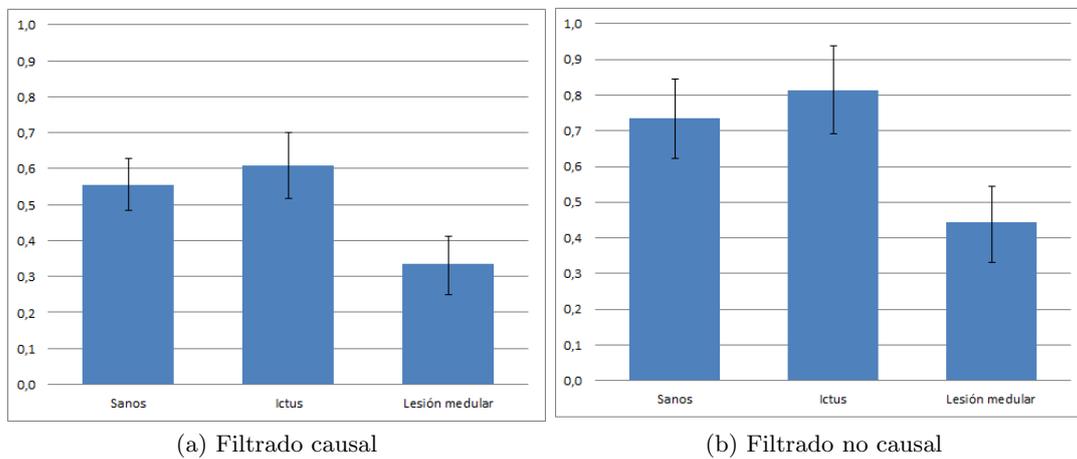


Figura 3.11: Evaluación del esquema en sujetos sanos y pacientes.

4. Conclusiones y trabajo futuro

4.1. Conclusiones

En el presente proyecto se ha realizado un estudio con el fin de optimizar las distintas fases un esquema de decodificación de intención de movimiento de una interfaz cerebro máquina (BMI) basado en potenciales cerebrales relacionados con el movimiento (MRCP). Este estudio ha sido realizado en dos fases, en primer lugar se ha realizado una comparativa detallada de filtros frecuenciales, espaciales y clasificadores en unos datos de sujetos sanos. En segundo lugar, se ha llevado a cabo una prueba en pacientes para observar el comportamiento de los distintos parámetros obtenidos dentro de un esquema de decodificación.

En lo referente al filtrado frecuencial, se ha observado que no existen diferencias sustanciales en los resultados de clasificación de los distintos tipos de filtros estudiados (Butterworth, Elíptico, Chebyshev). No obstante, estas diferencias se hacen notables al variar los valores de los distintos parámetros (rizado, banda de paso, orden) de cada filtro. Así pues, una de las conclusiones de este estudio es que utilizar una configuración adecuada del filtro tiene un importante impacto en los resultados finales de clasificación.

Con respecto al filtrado espacial, observamos que el filtro CAR (referencia de media común) es el que mejores resultados de clasificación consigue para los clasificadores LDA (análisis de discriminación lineal) y SVM (maquinas de soporte vectorial). No obstante, si utilizamos el clasificador Matched filter el filtro espacial que mejores resultados obtiene es el OSF (filtro espacial óptimo). Por otra parte, en el estudio de los distintos clasificadores hemos obtenido que el clasificador que mejores resultados obtiene es el clasificador lineal LDA.

Así pues, este estudio concluye que la mejor forma de realizar una decodificación de comandos motores a partir del MRCP, de entre las estudiadas, es un esquema que utilice un filtro espacial CAR y clasifique mediante el clasificador lineal LDA. Los resultados obtenidos utilizando este esquema han superado a un reciente estudio [11] cuando solo utilizó MRCP para realizar decodificación de

intención motora.

Al evaluar los resultados obtenidos en los pacientes de ictus, observamos que éstos han sido ligeramente superiores a los obtenidos en sujetos sanos. Esto se debe a que, dado que estos datos de pacientes grabados se encontraban altamente contaminados por ruido, se hizo una preselección de los cuatro sujetos que presentaban mejores MRPCs. Sin embargo, si estudiamos los resultados de los cuatro mejores sujetos sanos observamos que estos últimos tienen unos resultados un 6 % superiores.

Al evaluar este esquema en datos de pacientes con lesión incompleta de médula observamos una pérdida de en torno a un 20 % con respecto a los resultados obtenidos en los sujetos sanos. Esto puede ser debido a varios motivos: en primer lugar, el MRCP en pacientes de lesión medular es menos pronunciado que en sujetos sanos [18] lo que la hace más difícilmente clasificable. No obstante dado que los resultados obtenidos en pacientes de ictus se encuentran al nivel de los de sujetos sanos, puede que este factor no sea determinante. El segundo factor es que los datos no se corresponden al mismo movimiento, de hecho el tipo de movimiento podría afectar de forma significativa a la forma del MRCP [7]. Por último, el protocolo seguido por los pacientes de lesión medular es un protocolo cue-based (el movimiento se produce cuando se da la orden) mientras que en el caso de sujetos sanos este es un protocolo self-paced (el movimiento se realiza cuando el sujeto decide) lo que produce una negatividad más pronunciada en el MRCP[16]. Además, los datos de pacientes con lesión medular fueron adquiridos utilizando un sistema distinto lo que podría tener influencia en la forma de la señal.

4.2. Trabajo futuro

La tendencia actual en BMI basadas en decodificación de intención motora es combinar distintos tipos de características (como por ejemplo, ERD/ERS y MRCP). Puesto que en este trabajo hemos optimizado únicamente una de ellas, la comparación de nuestros resultados con otros clasificadores que combinan características no es directa. Es por ello que sería positivo evaluar como influye esta combinación de características en los resultados finales de clasificación.

En este trabajo se ha centrado en la métricas de porcentaje de ensayos bien clasificados, sin embargo a la hora de aplicar estas técnicas en una aplicación a tiempo real existe un compromiso entre la precisión en la clasificación y la anticipación con la que se detecta el movimiento. Por ello, resultaría interesante extender este estudio para ver la influencia que tienen las distintas partes de este esquema de decodificación estudiadas en el tiempo de detección.

Dado que hemos encontrado grandes diferencias en los resultados obtenidos en pacientes de lesión medular y pacientes de ictus, un posible trabajo futuro sería estudiar los factores que producen estas diferencias, utilizando distintos protocolos de experimentación en los dos tipos de pacientes.

Bibliografía

- [1] J d R Millán, Rüdiger Rupp, Gernot R Müller-Putz, Roderick Murray-Smith, Claudio Giugliemma, Michael Tangermann, Carmen Vidaurre, Febo Cincotti, Andrea Kübler, Robert Leeb, et al. Combining brain–computer interfaces and assistive technologies: state-of-the-art and challenges. *Frontiers in neuroscience*, 4, 2010.
- [2] Jonathan R Wolpaw, Niels Birbaumer, Dennis J McFarland, Gert Pfurtscheller, and Theresa M Vaughan. Brain–computer interfaces for communication and control. *Clinical neurophysiology*, 113(6):767–791, 2002.
- [3] Fernando Trincado-Alonso, Eduardo López-Larraz, Francisco Resquín, Aitor Ardanza, Soraya Pérez-Nombela, José L Pons, Luis Montesano, and Ángel Gil-Agudo. A feasibility study of hand rehabilitation for spinal cord injury patients using brain-triggered feedback based on electrical stimulation and virtual reality. *Medical engineering & physics (submitted)*, 2015.
- [4] Iñaki Iturrate, Javier M Antelis, Andrea Kübler, and Javier Minguez. A noninvasive brain-actuated wheelchair based on a p300 neurophysiological protocol and automated navigation. *Robotics, IEEE Transactions on*, 25(3):614–627, 2009.
- [5] Eduardo López-Larraz, Javier M Antelis, Luis Montesano, Angel Gil-Agudo, and Javier Minguez. Continuous decoding of motor attempt and motor imagery from eeg activity in spinal cord injury patients. In *Engineering in Medicine and Biology Society (EMBC), 2012 Annual International Conference of the IEEE*, pages 1798–1801. IEEE, 2012.
- [6] Gert Pfurtscheller and FH Lopes Da Silva. Event-related eeg/meg synchronization and desynchronization: basic principles. *Clinical neurophysiology*, 110(11):1842–1857, 1999.
- [7] Hiroshi Shibasaki and Mark Hallett. What is the Bereitschaftspotential? *Clinical Neurophysiology*, 117(11):2341–2356, 2006.

- [8] Gangadhar Garipelli, Ricardo Chavarriaga, and José del R Millán. Single trial analysis of slow cortical potentials: a study on anticipation related potentials. *Journal of neural engineering*, 10(3):036014, 2013.
- [9] Natalie Mrachacz-Kersting, Signe Rom Kristensen, Imran Khan Niazi, and Dario Farina. Precise temporal association between cortical potentials evoked by motor imagination and afference induces cortical plasticity. *The Journal of physiology*, 590(7):1669–1682, 2012.
- [10] Eduardo López-Larraz, Luis Montesano, Ángel Gil-Agudo, and Javier Minguéz. Continuous decoding of movement intention of upper limb self-initiated analytic movements from pre-movement eeg correlates. *Journal of neuroengineering and rehabilitation*, 11(1):153, 2014.
- [11] Andreea Ioana Sburlea, Luis Montesano, and Javier Minguéz. Continuous detection of the self-initiated walking pre-movement state from eeg correlates without session-to-session recalibration. *Journal of neural engineering*, 12(3):036007, 2015.
- [12] Ozge Yilmaz, Niels Birbaumer, and Ander Ramos-Murguialday. Movement related slow cortical potentials in severely paralyzed chronic stroke patients. *Frontiers in human neuroscience*, 8, 2014.
- [13] Ren Xu, Ning Jiang, Chuang Lin, Natalie Mrachacz-Kersting, Kim Dremstrup, and Dario Farina. Enhanced low-latency detection of motor intention from eeg for closed-loop brain-computer interface applications. *Biomedical Engineering, IEEE Transactions on*, 61(2):288–296, 2014.
- [14] Imran Khan Niazi, Ning Jiang, Olivier Tiberghien, Jørgen Feldbæk Nielsen, Kim Dremstrup, and Dario Farina. Detection of movement intention from single-trial movement-related cortical potentials. *Journal of neural engineering*, 8(6):066009, 2011.
- [15] Ernest Nlandu Kamavuako, Mads Jochumsen, Imran Khan Niazi, and Kim Dremstrup. Comparison of features for movement prediction from single-trial movement-related cortical potentials in healthy subjects and stroke patients. *Computational intelligence and neuroscience*, 2015.
- [16] Andrej Savić, Romulus Lontis, Ning Jiang, Mirjana Popović, Dario Farina, Kim Dremstrup, and Natalie Mrachacz-Kersting. Movement related cortical potentials and sensory motor rhythms during self initiated and cued movements. In *Replace, Repair, Restore, Relieve—Bridging Clinical and Engineering Solutions in Neurorehabilitation*, pages 701–707. Springer, 2014.
- [17] Ning Jiang, Leonardo Gizzi, Natalie Mrachacz-Kersting, Kim Dremstrup, and Dario Farina. A brain–computer interface for single-trial detection of gait

initiation from movement related cortical potentials. *Clinical Neurophysiology*, 126(1):154–159, 2015.

- [18] Antonio Castro, Fernando Díaz, and Alex Sumich. Long-term neuroplasticity in spinal cord injury patients: a study on movement-related brain potentials. *International Journal of Psychophysiology*, 87(2):205–214, 2013.