

## Estudio preliminar de la detección de cambios de velocidad de la marcha a partir de señales EEG

**Quiles Zamora, Vicente; Iáñez, Eduardo; Ortiz, Mario y Azorín, José M.**

Brain-Machine Interface Systems Lab, Universidad Miguel Hernández de Elche, Avda. de la Universidad S/N, 03202 Elche, España, [vquiles@umh.es](mailto:vquiles@umh.es), [eianez@umh.es](mailto:eianez@umh.es), [mortiz@umh.es](mailto:mortiz@umh.es), [jm.azorin@umh.es](mailto:jm.azorin@umh.es).

---

### **Abstract**

*The main objective of this work is analysing electroencephalographic (EEG) signals to get a mark to link brain information with characteristic indicators of the walk speed. This starts with developing a Brain-Machine Interface (BMI) and designing a validation protocol to allow to conclude an accuracy rate to assure reliable control of the BMI. It pretends to create a robust architecture that will be improvable in the future being able to provide a feedback with the patient in real time.*

**Keywords:** BMI, EEG, CWT, speed, walk.

---

### **Resumen**

*El objetivo de este estudio es analizar las señales electroencefalográficas (EEG) para obtener un indicador que relacione la información cerebral con marcadores de velocidad en la marcha. El planteamiento inicial pasa por desarrollar una interfaz cerebro-máquina (BMI) y el diseño de un protocolo de validación que permita concluir una tasa de acierto que asegure un correcto control de la BMI por parte de un paciente. Se pretende así crear una arquitectura robusta que asiente las bases para un modelo futuro en el que la interfaz controle en tiempo real la marcha del paciente mediante un exoesqueleto.*

**Palabras clave:** EEG, BMI, marcha, velocidad.

## **Introducción**

En la última década se ha producido un gran avance en los sistemas basados en la interacción hombre-máquina. Hasta, hace unos pocos años éstos estaban limitados a una actuación física por parte del usuario. Sin embargo el impulso de otro tipo de interfaces, como aquellas basadas en reconocimiento por voz, seguimiento ocular, señales EMG o señales cerebrales, ofrece nuevas posibilidades de interacción, especialmente para personas con limitaciones motoras en sus miembros inferiores y/o superiores. Estos avances junto al de mecanismos a la ayuda motora cada vez más sofisticados como los exoesqueletos, permiten crear nuevas terapias de rehabilitación que pueden ser beneficiosas en etapas iniciales de lesiones motoras (Murie et al., 2010). Algunos de los beneficios de la utilización de este tipo de sistemas en la rehabilitación resultan en un aumento de la vascularización, el equilibrio o la estabilidad, entre otros (Gorgey, 2018).

El análisis de las señales electroencefalográficas (EEG) es un campo de investigación novedoso, siendo su aplicación en interfaces cerebro-máquina (*Brain-Machine Interfaces*, BMIs, en inglés) una herramienta interesante para la ayuda a la marcha en terapias de rehabilitación (Dobkin, 2007). La posibilidad de detectar la intención del movimiento antes de que éste ocurra ofrece grandes posibilidades para mejorar el proceso de rehabilitación (Pfurtscheller, 1999). Algunos estudios plantean el uso de potenciales sensoriomotores para la detección de la intención de inicio, fin de marcha o cambios de dirección (Hortal et al., 2016). Estos potenciales vienen relacionados con fluctuaciones en las bandas de frecuencias alpha y beta momentos antes de la actividad motora (Toffanin et al., 2007).

Sin embargo, las terapias de rehabilitación parten de la premisa que debe existir una retroalimentación entre las actuaciones del usuario y el sistema, lo que deriva en un análisis de estos potenciales en tiempo real, con la finalidad de poder suministrar esta información a los sistemas de ayuda a la marcha. La interfaz que se propone en este trabajo pretende ser un primer acercamiento al desarrollo de un sistema online que permita detectar la intención de cambiar de velocidad de la marcha a partir del análisis de las señales EEG y regule el control de velocidad de un exoesqueleto.

En este trabajo planteamos un modelo que discierne entre dos clases, velocidad continuada e intención de incrementar velocidad. Para ello realizaremos un estudio que determine el cambio de aceleraciones, para que nuestro modelo sea capaz de entrenar con los datos generados por los equipos de adquisición no invasivos de EEG los dos estados descritos.

## **1. Materiales y métodos**

En este apartado se describe el material utilizado, así como el protocolo planteado en las pruebas. También detallamos los métodos de procesamiento, filtrado de ruido y extracción de características, para las señales cerebrales y de movimiento. Por último describimos el modelo de clasificación planteado y el método de validación.


### **1.1. Configuración experimental**

Para el registro de señales EEGs se ha utilizado el equipo amplificador de 24 bits actiCHamp de BrainProducts en combinación con un gorro de electrodos activos de 32 canales incluida la referencia. La configuración del equipo es parametrizable a través del programa PyCorder, el cual permite medir las impedancias de los electrodos, facilitando una correcta puesta a punto del mismo. Además el programa se encarga de desreferenciar las señales, implementar un paso banda de 0.1-100Hz y aplicar un filtro Notch a 50Hz para evitar interferencias de la red de alimentación.

La disposición de los electrodos empleada para registrar las señales EEG, siguiendo el sistema internacional 10/10, es la siguiente: Fz, FC5, FC3, FC1, FCz, FC2, FC4, FC6, C5, C3, C1, Cz, C2, C4, C6, CP5, CP3, CP1, CPz, CP2, CP4, CP6, P3, P1, Pz, P2, P4, FO7, FO3, Fpz, FO4, FO6. La señal esta doblemente referenciada al lóbulo izquierdo mediante un electrodo de oreja y a Fz (Jiang et al., 2015). La captación de la señal se realiza vía la comunicación entre el Pycorder y Matlab, donde realizamos el procesamiento y análisis de nuestros datos de forma offline.

Para el registro de la marcha el equipo utilizado es el tech-MCS V3 de Technaid, el cual permite el registro de las variables de movimiento del sujeto a partir de 7 unidades inerciales (IMUs) que nos proporcionan valores a una frecuencia de muestreo de 30 Hz para la aceleración en formato triaxial. Los sensores se colocan en las siguientes posiciones: lumbar, muslo derecho, espinilla derecha, pie derecho, muslo izquierdo, espinilla izquierda y pie derecho. El equipo procesa el ruido mediante un filtro Kalman según especifica TECHNAD. Por cada una de las IMU se extraen tres características: 'AccX', 'AccY' y 'AccZ', las cuales son procesadas posteriormente. Queda excluida la IMU de la lumbar por desvirtuar la forma de la señal promedio.

El equipo se coloca sobre un carrito móvil de dos niveles en el cual colocamos el portátil que procesa los datos y el amplificador (Fig1).



*Fig1. Montaje experimental para la realización de la prueba*

## **1.2. Procedimiento experimental**

Se han realizado dos experimentos distintos con protocolos diferentes, el primero más centrado en el análisis de la marcha y el segundo en el estudio de las señales EEG para la validación de la interfaz BMI, que debe predecir la intención del sujeto de cambiar de velocidad.

Gran parte del éxito en la detección de la intención del cambio de velocidad pasa por localizar correctamente el instante concreto en el cual se realiza el cambio de velocidad. Para la evaluación de la detección de dicho instante de cambio participaron cuatro primeros sujetos con edades comprendidas entre 18 y 24 años, todos diestros. El protocolo seguido en esta evaluación fue: el usuario comienza la marcha a una velocidad relativamente constante, con paso normal, y, aproximadamente cuatro segundos después se le pide que acelere lo más rápidamente posible y mantenga la velocidad otros tres segundos marcando el momento del cambio.

Para evaluar la BMI que proponemos se realizaron pruebas con tres sujetos con edades comprendidas entre 22 y 24 años, uno zurdo y dos diestros. Cada sujeto realizó 40 repeticiones del protocolo siguiente: el usuario permanece en reposo y tras 5s se le ordena que inicie la marcha a una velocidad constante y paso normal, y transcurridos aproximadamente 5-6s decide voluntariamente cambiar de velocidad manteniéndola de forma constante durante 3.4 s más aproximadamente (Fig2). Cada registro realizado consiste en un recorrido de 15 metros aproximadamente.

Como normas para la realización de las pruebas se les especifica que deben intentar minimizar parpadeos, movimientos mandibulares o posiciones gesticulares anómalas, así como realizar un paso firme y evitar zancadas bruscas, sobre todo en el tramo de marcha con mayor velocidad. En algunos casos se han descartado registros, por fallos en el protocolo, desprendimiento del equipo de captación de movimiento, distracciones por parte del sujeto o incumplimiento de alguna de las normas.




Fig2. El sujeto espera en reposo hasta que comienza la marcha a velocidad 1 desde la línea verde. Entre las dos líneas rojas aproximadamente decide incrementar el ritmo de la marcha a velocidad 2 hasta la última línea verde.

### 1.3. Análisis de la marcha

Para la identificación del instante de la aceleración, procesamos las señales que obtenemos de las IMUs. A continuación expondremos los filtros aplicados y el proceso que seguimos para detectar las continuidades y cambios bruscos.

#### 1.3.1. Filtrado de ruido

La etapa de eliminación de ruido es clave a la hora de una detección más certera. Aparte de los filtros integrados en el equipo de captación, se hará uso de un filtrado mediante una wavelet, anteponiéndolo a un filtrado más clásico como el suavizado de spline, debido a que este conserva mejor las características subyacentes de la señal original WAVELET DENOISING.

Este método de filtrado busca rechazar el ruido mediante el umbral de coeficientes wavelet de la señal ruidosa. Este procesamiento actúa en tres etapas diferentes. En primer lugar, una wavelet analiza la señal y extrae los coeficientes. Para ello utilizaremos la Db20 (Fournier, 2009). Luego los coeficientes extraídos son sometidos a un umbral de rechazo para eliminar el ruido. Finalmente una transformada wavelet inversa reconstruye la señal.

Para implementar dicho modelo utilizamos la función `wden` de Matlab y los parámetros de configuración son (Fournier, 2009):

1. La señal normalizada de la aceleración de la IMU.
2. Para el umbral hemos utilizado el principio de decisión Stein's Unbiased Risk Estimate (Donoho, 1995).
3. Se ha elegido un umbral suave por la capacidad de reducción del ruido, por oposición el umbral duro es mejor en la conservación.
4. Se ha reescalado estimando el nivel de ruido.
5. El número de nivel de descomposición se ha estimado de forma empírica, escogiendo un nivel de 4.

### *1.3.2. Extracción coeficientes CWT*

Para el cambio en la velocidad, hacemos un análisis en las variables de aceleración extraídas de las IMUs, y un análisis de tipo frecuencial nos permite detectar los cambios bruscos en la señal. Sin embargo con un análisis en el dominio frecuencial no seríamos capaces de detectar en que instante se producen esas señales características. Estudiar las componentes frecuenciales en el tiempo (CWT) (Capilla, 2006) nos posibilita no perder resolución temporal, y enfatizar sus discontinuidades.

Para el análisis CWT escogemos como wavelet madre la Haar, que nos enfatiza las discontinuidades del conjunto de datos a procesar. Otro aspecto importante para el análisis de dichos componentes es la selección de los coeficientes wavelet. Mediante un banco de filtros de paso banda se hará una división del rango de frecuencias (Tabla 1) y determinamos el número de secciones a coger (Valens, 1999) mediante

$$J = \log_2(N) \quad (1)$$


donde  $J$  es el número de escalas válidas y  $N$  es la frecuencia de muestreo de la señal.

Para una frecuencia de 30Hz se han escogido cinco escalas de la cinco a la ocho, correspondientes a un rango de frecuencias entre 0,12Hz y 3.75Hz.

**Tabla 1. Análisis para la selección de frecuencias en la CWT**

	Frecuencias		Muestras
	Desde (Hz)	Hasta (Hz)	
1	15,00	30,00	N/2
2	7,50	15,00	N/4
3	3,75	7,50	N/8
4	1,87	3,75	N/16
5	0,93	1,87	N/32
6	0,46	0,93	N/64
7	0,23	0,46	N/128
8	0,11	0,23	N/256
9	0,05	0,11	N/512
10	0,02	0,05	N/1024
11	0,01	0,02	N/2048

El protocolo seguido empieza por el filtrado del ruido según lo explicado en el apartado anterior. Una vez filtradas cada una de las tres aceleraciones se calcula el módulo de dicho vector, obteniendo una señal de aceleración por cada IMU. De la señal resultante se escogen las frecuencias de interés seleccionadas por el filtro de banco. Se calculan los coeficientes en cada rango obteniendo las componentes correspondientes a ese rango de frecuencias. Por último se suman las bandas para calcular la energía contenida en dicho rango, obteniendo el vector que representa las singularidades de la señal a esas escalas. De forma empírica se selecciona el mínimo de la señal como punto de transición obteniendo el punto de cambio de cada IMUs. Por último se promedian los valores (Fig3).



*Fig3. A la izquierda señal promediada de las aceleraciones, en el centro los coeficientes extraídos y a la derecha el contenido de la señal a las frecuencias elegidas.*

## **1.4. Procesamiento EEG**

Buscamos diferenciar la señal en dos estados, velocidad normal y cambio de velocidad. Para ello planteamos extraer las características más significativas que nos aporten menor correlación posible entre estados. Comentamos los filtros aplicados, así como la justificación de los potenciales seleccionados.

### *1.4.1. Preprocesamiento*

Se ha aplicado un filtro Butterworth de orden 8th en el rango de frecuencias 1-40 Hz, al desear evitar el límite de las bandas Alfa (8-14 Hz) y Beta (14-30 Hz). También aplicamos un filtro espacial Laplaciano (McFarland et al., 1997) para reducir la contribución del resto de electrodos a cada canal; usando la información de cada electrodo y la distancia al sensor de interés.

### *1.4.2. Extracción de características*

Este estudio trata de clasificar los patrones que codifican la intención de movimiento (Nam et al., 2011). Estos potenciales son endógenos: señales que se generan en el interior del cerebro sin necesidad de estimulación externa. Dependen de la habilidad del usuario para controlar su actividad electrofisiológica. Nuestro interés está en el estudio de los ritmos sensoriomotores, los cuales comprenden dos tipos de variaciones en amplitud, de tipo ERD (desincronización relacionada con el evento) y las ERS (sincronización relacionada con el evento). La primera representa una disminución de la actividad rítmica de duración breve y localizada 1.5s antes del evento, la segunda un aumento de la amplitud 0.5s después de éste. Estas variaciones son altamente específicas de la banda de frecuencia y no bloqueadas en fase al evento (Pfurtscheller, 1999).

Se selecciona la banda de frecuencia más idónea, separando el espacio a explorar en tres: 8-12Hz, 13-24Hz y 25-30Hz. Para la extracción de características se realiza una transformación de la señal al dominio de la frecuencia mediante el análisis de la potencia de la densidad espectral (PSD), utilizando ventanas Hanning, promediando el valor en todo el rango de frecuencias escogido. Los datos seleccionados se han segmentado en épocas de 1s cada 0.2s (0.8 s de solapamiento de la señal). En este estudio probamos los resultados de cada una de estas bandas en el modelo de clasificación seleccionado para cada uno de los usuarios (Gómez et al., 2012).



### 1.4.3. Análisis de componentes principales

Una señal EEG está compuesta por una mezcla de señales de muchas fuentes. Mediante el Análisis de Componentes Independientes (ICA) pretendemos separar la señal en sus componentes principales descartando aquellos que pertenezcan a fuentes de ruido. Para la aplicación del método ICA utilizaremos EEGLAB, importando sus funciones a Matlab SCCN. El proceso seguido para separar las señales es el siguiente:

- Se genera una estructura de datos a partir de las sesiones para que el programa itere sobre estos ficheros.
- Separación de componentes principales utilizando la función `rúnica` de EEGLAB. Esta función extrae los pesos de los componentes.
- Con los pesos se calcula el espectro en frecuencia de aquellos componentes que vayamos a analizar para una posible substracción.

**Por cada componente analizamos su espectro normalizándolo, según las condiciones expuestas más abajo. Solo se extraerán el 10% de los componentes para preservar la señal.**

Los componentes que buscamos eliminar son los pertenecientes a movimientos musculares y oculares, priorizando su eliminación según el orden anterior. El método seguido para discriminar los artefactos (Mayeli et al., 2016) es el que se indica a continuación:

- Las componentes debidas a movimientos se priorizan con un peso del 50% y en el rango de 0.5-4.5Hz se eliminan aquellas que superen un valor de 0.26.
- Las componentes musculares con un peso del 25%, en el rango de 30-60Hz eliminando aquellas que superen el valor de 0.68.
- Los componentes oculares con un peso del 25%, en el rango de 0.5-3Hz de aquellos que superen el valor de 0.22.

## 1.5. Clasificación

Los datos se procesan de forma offline según dos estados. Los pertenecientes a la clase C1 serán los datos que interpretamos como marcha normal y los pertenecientes a la clase C2 para la intención de cambio de velocidad.

Para la caracterización de las señales EEG, para nuestros dos estados, se ha utilizado un clasificador del tipo Máquinas de Vector Soporte (SVM). La parametrización del algoritmo, es la utilizada en la mayoría de sistemas BMI: núcleo de base radial, con la configuración de los parámetros  $C=512$  y  $\gamma=0.002$  (Flórez et al., 2011).

Una vez marcado el momento en el que la persona cambia, se etiquetan los datos según pertenezcan a la clase C1 o C2. El modelo predictivo se etiqueta, desde el cambio hasta 1.8s antes como C2 y desde 1.8s hasta 3.6s antes del cambio como C1.

Los resultados se extraen a partir de una validación cruzada, que valida nuestros resultados de forma estadística, garantizando la independencia de la partición entre datos de entrenamiento y prueba. Se divide en dos subconjuntos, uno de entrenamiento y otro de prueba con tamaño  $k=2$ , rotando el conjunto de prueba el proceso de validación cruzada es repetido hasta terminar todas las agrupaciones, sin repetir datos de conjuntos ya seleccionados. La medida utilizada para calcular la calidad de los resultados ha sido el F-score, mediante

$$F - score = 2 \frac{P \times TP}{TP + P} (2)$$

donde TP son los verdaderos positivos, el número de veces que se acierta la clase frente al total de instancias y P es la precisión, el número de veces que se clasifica incorrectamente la clase.

## **2. Resultados y discusión**

En esta sección exponemos las configuraciones que hemos planteado para el análisis de resultados, así como la justificación de dichas elecciones y por último analizamos la validez de dichos resultados.

### **2.1. Resultados en la detección del punto de cambio en la marcha**

Para validar la detección del punto de cambio en el primer experimento con los cuatro sujetos, se compara el momento en el que se le dice al sujeto que cambie de velocidad y el momento en el que detectamos que cambia.

La diferencia en segundos desde que se le dice al usuario que cambie de velocidad, hasta que cambia es inferior al segundo (Tabla 2). Podríamos deducir de los resultados que la determinación del punto no es todo lo precisa que cabría esperar. Sin embargo varias condiciones podrían matizar el resultado. Desde el momento que se indica la aceleración hasta que el sujeto realiza el cambio, existe un retardo; aparte de lo que tarda en acelerar y del tipo de zancada de cada individuo.

**Tabla 2. Diferencias entre el momento marcado y el detectado**

Sujetos	Sesiones				$\bar{x} \pm \sigma$
1	0.81 s	0.95 s	0.92 s	0.83 s	0.88 s $\pm$ 0.07 s
2	0.70 s	0.98 s	0.56 s	1.26 s	0.88 s $\pm$ 0.31 s
3	0.81 s	0.50 s	0.56 s	0.46 s	0.58 s $\pm$ 0.16 s
4	0.35 s	-0.07 s	0.49 s	0.83 s	0.40 s $\pm$ 0.37 s

## 2.2. Resultados en la clasificación de señales EEG

Seleccionamos las bandas más adecuadas con 11 electrodos FC1, FCz, FC2, C3, C1, Cz, C2, C4, CP1, CPz, CP2. Se estudian las bandas correspondientes a 8-12Hz, 13-24Hz y 25-30Hz, extrayendo una característica por electrodo.

Los espectros de las distintas bandas nos pueden estar indicando donde se produce la máxima distinción de los potenciales ERD/ERS (Ang y Guan, 2013) para cada sujeto (Tabla 3). El Sujeto 5 encuentra mayor acierto en las bajas, mientras que los otros dos maximizan el acierto en las altas. Debido a este análisis se ha decidido utilizar para los Sujetos 6 y 7 las frecuencias correspondientes a la zona Beta, mientras que para el Sujeto 1, las correspondientes a la zona Alfa.

**Tabla 3. Resultados para las diferentes bandas**

Sujetos	Banda: 8-13Hz		Banda: 13-24Hz		Banda: 25-30Hz	
	F-score C1 (%)	F-score C2 (%)	F-score C1 (%)	F-score C2 (%)	F-score C1 (%)	F-score C2 (%)
5	56.35	51.75	51.03	49.79	49.79	49.37
6	45.16	50.21	43.75	45.69	53.57	55.17
7	54.84	51.72	50.22	53.82	54.24	55.74
$\bar{x} \pm \sigma$	54.84 $\pm$ 6.07	51.72 $\pm$ 0.88	50.22 $\pm$ 3.98	49.79 $\pm$ 4.06	53.57 $\pm$ 2.39	55.17 $\pm$ 3.52

Se han probado (Rodríguez, 2017) distintas configuraciones correspondientes a la zona central y homúnculo motor para la configuración de electrodos 1, zona central y la zona motora para la configuración 2 y la configuración 3 zona central más lóbulo parietal.

**Tabla 4. Resultados para las configuraciones indicadas sin eliminación de artefactos**

Sujetos	Sin ICA					
	Configuración 1		Configuración 2		Configuración 3	
	F-score C1 (%)	F-score C2 (%)	F-score C1 (%)	F-score C2 (%)	F-score C1 (%)	F-score C2 (%)
5	56.35	51.75	57.26	59.35	52.72	53.11
6	53.57	55.17	57.64	57.27	57.63	54.55
7	54.24	55.74	46.67	46.67	60.99	66.15
$\bar{x} \pm \sigma$	54.24 $\pm$ 1.45	55.17 $\pm$ 2.16	57.26 $\pm$ 6.23	57.27 $\pm$ 6.80	57.63 $\pm$ 4.16	54.55 $\pm$ 7.15

Probamos dichas configuraciones sin (Tabla 4) y con filtro ICA. Los mejores resultados para los sujetos 5 y 6 se consiguen para la configuración 2, para el 7 se consiguen en la configuración 3. Como podemos observar (Tabla 5) los valores no mejoran, sino que incluso empeoran. Es posible que el algoritmo este quitando información esencial, no obstante eliminar las componentes debidas al movimiento es imprescindible puesto que sino podríamos estar clasificando artefactos, en vez de los potenciales que se buscan.

**Tabla 5. Resultados para las configuraciones indicadas con eliminación de artefactos**

Sujetos	Con ICA					
	Configuración 1		Configuración 2		Configuración 3	
	F-score C1 (%)	F-score C2 (%)	F-score C1 (%)	F-score C2 (%)	F-score C1 (%)	F-score C2 (%)
5	54.24	55.74	56.17	57.96	51.85	50.63
6	53.81	55.79	52.73	55.93	54.22	55.41
7	57.03	50.89	54.98	50.66	54.69	52.7
$\bar{x} \pm \sigma$	54.24±1.75	55.74±2.81	54.98±1.75	55.93±3.77	54.22±1.52	52.7±2.40

### 3. Conclusión

En este trabajo se ha creado una interfaz BMI para la detección de la intención del cambio de velocidad a partir de la adquisición de señales EEG y el estudio de la marcha. Abordamos los protocolos a seguir y las especificaciones para la creación de un modelo de predicción combinando el análisis de la marcha, con el procesamiento de los potenciales sensoriomotores. Para el análisis de la marcha se ha utilizado el análisis CWT, con filtrado de ruido y selección de la banda de frecuencias más óptima (Fournier, 2009). Los resultados obtenidos (Tabla 3) nos aportan un error menor a 1 s, que achacamos al tiempo de reacción y al tiempo de aceleración. La señal EEG, es filtrada y suavizada extrayendo el poder espectral para ciertas bandas de frecuencia. Una vez separada según la clase se entrena un modelo de clasificación SVM para cada una de las configuraciones. El mayor acierto para ambas clases conseguido en la configuración 2 para sujetos 5, 6 y la configuración 3 para el sujeto 7 según la (Tabla 4) es del 58.31%±0.61. El resultado no es lo suficientemente aceptable, debido a que la arquitectura BMI no permitiría el control óptimo para que un modelo de rehabilitación sea consistente. El algoritmo de filtrado no ha aportado resultados satisfactorios. El eliminar ciertas componentes (Mayeli et al., 2016) ha empeorado los resultados (Tabla 5) para cada configuración (Tabla 3) un 1.6% de media, empeorando también los mejores resultados globales expuestos anteriormente. Al no ser resultados positivos (Tabla 5), no podemos descartar que los artefactos de movimiento infieran acierto en la clasificación cuando no aplicamos el filtro ICA (Tabla 4).

En resumen, nuestros resultados no son concluyentes pero asientan las bases para el futuro de una interfaz más eficaz. Existiendo un gran abanico de posibilidades para la mejora: aspectos como la selección de las frecuencias óptimas por cada canal, la selección de las ventanas que mayor acierto proporcionan para cada usuario... Con una tasa de acierto mayor el paso siguiente sería un modelo online de predicción.

#### 4. Agradecimientos

Esta investigación ha sido realizada en el marco del proyecto *Walk - Control de exoesqueletos de miembro inferior mediante interfaces cerebro-máquina para asistir a personas con problemas de marcha* (RTI2018-096677-B-I00), financiado por el Ministerio de Ciencia, Innovación y Universidades (MCIU), la Agencia Estatal de Investigación (AEI) y la Unión Europea a través del Fondo Europeo de Desarrollo Regional (FEDER).

#### 5. Referencias

ANG, K. K., and Guan, C. (2013). "Brain-computer interface in stroke rehabilitation". *J. Comput. Sci. Eng.* 7, 139–146.

BRAIN PRODUCTS. *Products & Application*  
<[https://www.brainproducts.com/products\\_by\\_type.php?tid=1](https://www.brainproducts.com/products_by_type.php?tid=1)> [ Consulta : 11 de agosto de 2017]

CAPILLA, C. (2006). "Application of the Haar wavelet transform to detect microseismic signal arrivals". *Journal of applied geophysics*, 59(1), 36-46.

DOBKIN, B. H. (2007). "Brain-computer interface technology as a tool to augment plasticity and outcomes for neurological rehabilitation". *J. Physiol.* 579, 637–642.

DONOHU, D. L., & Johnstone, I. M. (1995). "Adapting to unknown smoothness via wavelet shrinkage." *Journal of the american statistical association*, 90(432), 1200-1224.

EEGLAB. *Descomposing Data Using ICA*.  
<[https://sccn.ucsd.edu/wiki/Chapter\\_09:\\_Decomposing\\_Data\\_Using\\_ICA](https://sccn.ucsd.edu/wiki/Chapter_09:_Decomposing_Data_Using_ICA)> [ Consulta : 13 de agosto de 2017]

FLOREZ, F., Azorín, J. M., Iáñez, E., Úbeda, A., & Fernández, E. (2011, October). Development of a Low-cost SVM-based Spontaneous Brain-computer Interface. In *IJCCI (NCTA)* (pp. 415-421).

FOURNIER, H. (2009). "Automated Processing of GPS/MEMS-IMU Data for Position", *Velocity and Attitude Determination* (No. STUDENT).

GOMEZ, J., Aguilar, M., Horna, E., & Minguez, J. (2012). "Quantification of event-related desynchronization/synchronization at low frequencies in a semantic memory task". *Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (pp. 2522-2526). IEEE.

- GORGEY, A. S. (2018). Robotic exoskeletons: The current pros and cons. *World journal of orthopedics*, 9(9), 112.
- HORTAL, E., Úbeda, A., Iáñez, E., Azorín, J. M., & Fernández, E. (2016). "EEG-based detection of starting and stopping during gait cycle". *International journal of neural systems*, 26(07), 1650029.
- JIANG, N., Gizzi, L., Mrachacz-Kersting, N., Dremstrup, K., & Farina, D. (2015). "A brain-computer interface for single-trial detection of gait initiation from movement related cortical potentials". *Clinical Neurophysiology*, 126(1), 154-159.
- MATHWORKS. *Wavelet Denoising*. <<https://es.mathworks.com/help/wavelet/ug/wavelet-denoising.html>>[Consulta : 14 de agosto de 2017]
- MAYELI, A., Zotev, V., Refai, H., & Bodurka, J. (2016). "Real-time EEG artifact correction during fMRI using ICA". *Journal of neuroscience methods*, 274, 27-37.
- MCFARLAND, D. J., McCane, L. M., David, S. V., & Wolpaw, J. R. (1997). "Spatial filter selection for EEG-based communication". *Electroencephalography and clinical Neurophysiology*, 103(3), 386-394.
- MURIE-FERNANDEZ, M., IRIMIA, P., MARTINEZ-VILA, E., MEYER, M. J., & TEASELL, R. (2010). "Neuro-rehabilitation after stroke" *Neurología*, vol. 25, 3, 189-196.
- NAM, C. S., Jeon, Y., Kim, Y.-J., Lee, I., and Park, K. (2011). "Movement imagery-related lateralization of event-related (de) synchronization (ERD/ERS): motor-imagery duration effects". *Clin. Neurophysiol.* 122, 567-577.
- PFURTSCHELLER, G., & Da Silva, F. L. (1999). Event-related EEG/MEG synchronization and desynchronization: basic principles. *Clinical neurophysiology*, 110(11), 1842-1857.
- RODRIGUEZ-Ugarte, M., Iáñez, E., Ortíz, M., & Azorín, J. M. (2017). "Personalized offline and pseudo-online BCI models to detect pedaling intent". *Frontiers in neuroinformatics*, 11, 45.
- TECHNAID, *Manual de usuario Sistema de Captura de Movimiento Tech-MCS V.3.0*. Revisión : 25 de Junio de 2014
- TOFFANIN, Paolo, et al. "Rethinking neural efficiency: Effects of controlling for strategy use." *Behavioral neuroscience* 121.5 (2007): 854.
- VALENS, C. (1999). "A really friendly guide to wavelets". ed. *Clemens Valens*.