

Análisis de Algoritmos para Detección de Pedaleo en Interfaces Cerebro-Máquina

M. Ortiz*, M. Rodríguez-Ugarte, E. Iáñez, J. M. Azorín

Brain Machine Interfaces Systems Lab. Miguel Hernández University of Elche, Spain

Resumen

El uso de interfaces cerebro-máquina en personas que han sufrido un accidente cerebro-vascular puede ayudar en su proceso de rehabilitación mediante la implicación cognitiva del paciente. Dichas interfaces traducen las ondas cerebrales en comandos con el fin de controlar un dispositivo mecánico de movimiento asistido. No obstante, el control de estos dispositivos debería ser más robusto y tener una alta precisión. Este trabajo estudia si algoritmos basados en transformadas como las de Stockwell o Hilbert-Huang pueden mejorar el control de estos dispositivos aumentando su precisión, y si es recomendable llevar a cabo una personalización por sujeto y configuración de electrodos. Mediante el análisis de cinco voluntarios se comprueba además, que no es posible detectar con suficiente robustez la intención motora a partir de la desincronización/sincronización relacionada a eventos motores con únicamente los datos previos al movimiento. Por ello, es preciso extender el tiempo de análisis a los dos segundos posteriores al inicio del movimiento.

Palabras Clave:

Análisis y tratamiento de señales, (De)sincronización relacionada a eventos, Intención motora, Interfaces Cerebro-Máquina, Máquinas de soporte vectorial, Offline, Rehabilitación, Transformada de Fourier, Transformada de Hilbert-Huang, Transformada de Stockwell

Analysis of Algorithms for Detection of Pedaling Intention in Brain-Machine Interfaces

Abstract

The use of brain-machine interfaces in people who has suffered a cerebrovascular accident could help the rehabilitation process through the cognitive involvement of the patient. These interfaces translate the brain waves into commands to control the movement of an assistant mechanical device. However, the control of these devices should be more stable and achieve a higher accuracy. This work studies if algorithms, such as Stockwell or Hilbert-Huang transform, can improve the control of these devices, and if a personalization by subject or electrode configuration is desirable. Besides, through the analysis of five volunteers is determined that the motor intention can not be detected only by data acquired previously to the movement using desynchronized/synchronized related events. Therefore, it is needed to extend the time processing to the two seconds after the movement starting.

Keywords:

Signal analysis and processing, Event related (De)synchronization, Motor intention, Brain-Machine Interfaces, Offline, Rehabilitation, Fourier Transform, Hilbert-Huang transform, Stockwell transform

1. Introducción

El accidente cerebro-vascular (ACV) es una de las principales causas de discapacidad neurológica entre adultos provocando con frecuencia disfunciones motoras (Go et al., 2014). Por ello, la mejora del proceso de rehabilitación de personas afectadas por un ACV es objeto de investigación (Ramos-Murguialday et al.,

2013; Ang and Guan, 2013). Para conseguir dicho objetivo, es recomendable el uso de herramientas no invasivas como las interfaces cerebro-máquina (Brain-Machine Interfaces, en inglés, BMI). Mediante éstas, las señales cerebrales pueden procesarse con el fin de generar un comando que permita activar el dispositivo externo que se desee controlar, involucrando cognitivamente

*Autor para correspondencia: nortiz@umh.es

al paciente en el proceso de rehabilitación en comparación con un control más mecánico por joystick o pulsación (He et al., 2018). Un ejemplo de este tipo de dispositivos son los exoesqueletos. Estos dispositivos se colocan alrededor de la extremidad a rehabilitar, dando soporte al usuario a la hora de realizar el movimiento. La combinación de un sistema BMI con un exoesqueleto puede mejorar el tiempo y la calidad del proceso de rehabilitación como indican algunas investigaciones (Veneman et al., 2007).

Son varios los bloques que conforman el diseño de una BMI: adquisición de las señales, procesamiento y finalmente clasificación y emisión del comando de control. Hoy en día, la técnica menos invasiva, barata y portable para registrar la actividad cerebral es la electroencefalografía (EEG). Esta técnica registra los campos eléctricos de las neuronas en la superficie del cuero cabelludo (Rao, 2013). Dicha actividad se puede estudiar en base a los ritmos cerebrales conocidos correspondiendo a las siguientes bandas de frecuencia: delta (0,1 - 4 Hz), relacionada con el sueño profundo (Amzica and Steriade, 1998); theta (4-7 Hz); alfa (8-15 Hz); mu (8-12 Hz) que pertenece a la banda alfa y es más notoria al realizar una tarea de imaginación motora (Steriade, 2005); beta (16-32 Hz), detectada en el área parietal y en el lóbulo frontal cuando una persona está concentrada (Rao, 2013); y gamma (33-100 Hz). Debido a que la técnica de adquisición de señales EEG tiene una resolución espacial baja, la presencia de ruido puede ser alta. Por ello, es necesario realizar una primera fase de preprocesamiento para mitigar este problema y extraer posteriormente, mediante el algoritmo o transformada matemática considerada, las características que contienen la información más representativa de la actividad a detectar, i.e. reposo o intención motora. Por último lugar, se lleva a cabo una clasificación de las características extraídas, agrupando la información en base a las etiquetas asociadas a los grupos de datos (reposo vs. intención motora). Una vez se tiene el modelo entrenado, éste es capaz de catalogar cualquier vector de datos adicional que se le ofrezca, indicando la agrupación de datos a la que pertenece y asignándole la etiqueta del mismo.

Los algoritmos de control de las BMIs presentes en la literatura, independientemente de que se busque el control de la BMI mediante intención de movimiento o imaginación motora, basan su estudio de la actividad cerebral analizando las siguientes características:

- Potenciales corticales relacionados con el movimiento (Movement Related Cortical Potential MRCP): En las señales EEG aparecen características en el dominio del tiempo asociadas al movimiento o la toma de decisiones (Shibasaki and Hallett, 2006). Muchas de las BMIs de la bibliografía usan este método (López-Larraz et al., 2016; Zhang et al., 2017).
- Fenómeno de desincronización/sincronización relacionada con eventos (en Inglés, Event Related Desynchronization/Synchronization ERD/ERS): Consiste en fluctuaciones de potencia que se producen principalmente en las bandas de frecuencias mu y beta (Pfurtscheller et al., 2006). Este fenómeno comienza con una bajada de potencia (ERD), 2 segundos antes del inicio del movimiento y termina con un aumento de potencia (ERS), 2 segundos después de haberlo iniciado (Nam et al., 2011). Dicho

fenómeno ha sido tratado en estudios previos como (Kilicarslan et al., 2013, 2016; López-Larraz et al., 2016).

- Potenciales evocados en régimen permanente (en Inglés, Steady-State Evoked Potentials SSEP): No van directamente asociados al movimiento y representan una respuesta cerebral a un estímulo externo, pero pueden ser usados como parte del algoritmo de control de la BMI. Este estímulo puede ser visual (Kwak et al., 2015), auditivo (Lopez-Gordo et al., 2012), o incluso incluir un potencial táctil (Yin et al., 2016).

En los dos primeros casos, la operación y entrenamiento de la BMI requiere habitualmente realizar tareas para generar los patrones cerebrales asociados. Normalmente consisten en tareas discretas como imaginar la acción de caminar, giro, movimientos de extensión o contracción. En nuestro caso evaluaremos la intención del movimiento de pedaleo basada en el cambio ERD/ERS que se produce entre los 2 segundos previos y posteriores al movimiento.

Adicionalmente, aunque el objetivo final es la implementación en línea de una BMI, su estudio “offline” es el primer paso necesario para desarrollar un modelo robusto. Por ello, muchos estudios se basan en el análisis offline de las BMIs y es la opción estudiada en este trabajo.

Otro problema reside en que las diferentes investigaciones suelen tener formas diferentes a la hora de establecer la tasa de éxito de las BMIs. Aunque la mayoría de estudios suelen dar la medida de precisión (Accuracy en inglés, Acc), ésta a veces no se calcula del mismo modo, o no se da acompañada de los falsos positivos por minuto (False positive per minute en inglés, FP/min). Por ello, en (Rodríguez-Ugarte et al., 2017) se desarrolló un índice denominado discriminador de peso (weighted discriminator (WD)) con el fin de evaluar de un modo más preciso el funcionamiento de la BMI. Esta medida se basa en la ponderación de la tasa de los aciertos positivos por minuto (True positive rate en inglés, TPR), la Acc y los FP/min. Estos tres parámetros son fundamentales ya que si uno no se diera, no se podría determinar con precisión el funcionamiento de la BMI. Por ejemplo, si se da una Acc del 100 %, 0 FP/min y no se da el TPR, podría ser debido a que el clasificador ha detectado 1, y sólo 1, de las 5 imaginaciones de movimiento. Varios estudios de detección de intención de movimiento olvidan al menos una de estas tres variables, lo que implica una gran dificultad a la hora de comparar los resultados (He et al., 2018).

La actual investigación continúa el estudio realizado en (Rodríguez-Ugarte et al., 2017). En él, se estudiaron 8 configuraciones de electrodos y 5 algoritmos diferentes para la detección de la intención del pedaleo mediante el análisis de dos tipos de ventanas: 2 segundos (previos al movimiento del pedaleo), y 4 segundos (2 segundos previos y 2 segundos posteriores al movimiento del pedaleo). Para ello, se parte de las mejores configuraciones de electrodos que obtuvo cada usuario, reduciendo de 8 a 3 las configuraciones a evaluar para los 5 algoritmos nuevos de procesamiento desarrollados. Los objetivos principales del artículo son 3:

- Determinar si la ventana temporal que ofrece sólo información antes del inicio del pedaleo es suficiente, o es necesario también ampliar a la de 4 segundos como se

hacía en dicho artículo, al mejorar la resolución temporal de los nuevos algoritmos desarrollados. Dichos algoritmos están basados en las transformadas de Stockwell (ST) (Stockwell et al., 1996) y Hilbert Huang (HHT) (Huang et al., 1998), incluyendo esta última la descomposición empírica modal (EMD) y la transformada de Hilbert (HT).

- Evaluar si los nuevos algoritmos basados en estas transformadas mejoran la anterior aproximación basada en la transformada de Fourier (FT) para controlar una BMI mediante la intención de pedaleo.
- Analizar si dentro del protocolo de pruebas resulta pertinente llevar a cabo una personalización de configuración de electrodos (C.E.) y/o algoritmos por sujeto para mejorar los resultados o puede utilizarse una configuración generalizada.

Todo ello con el fin de una futura implementación en línea de la BMI desarrollada para su uso con un dispositivo asistido de pedaleo para rehabilitación.

2. Materiales y métodos

Para el análisis de la intención de pedaleo, se ha registrado la actividad cerebral de 5 usuarios. Estos datos han sido separados en dos clases (reposo e intención de pedaleo) para posteriormente procesarlos y realizar una validación cruzada en el clasificador.

Se analizan tanto soluciones estandarizadas entre todos los usuarios como soluciones personalizadas para cada uno de ellos.

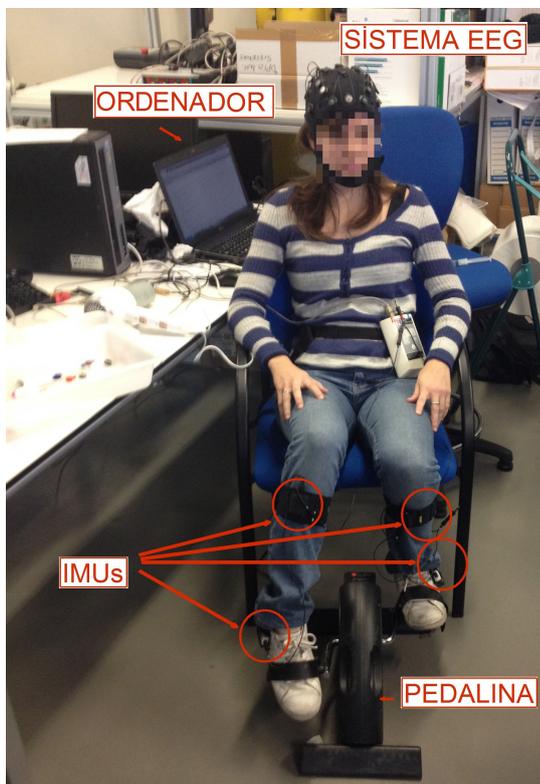


Figura 1: Arquitectura del sistema. El usuario permanece sentado frente a la pedalina mientras se miden sus señales EEG y sensores de movimiento, permitiendo determinar el instante en el que voluntariamente inicia el pedaleo. El usuario ha dado el consentimiento informado para que se publique la fotografía.

2.1. Descripción del experimento

El experimento consistió en el registro de las señales EEG de 5 sujetos mientras realizaban periodos de reposo y pedaleo. Para ello, los sujetos se sentaron en una silla fija frente a una pedalina, como se muestra en la Figura 1. Cada sesión de pruebas estaba formada por 16 registros, en las cuales se realizaban 5 ciclos de reposo/pedaleo. La Figura 2 muestra el protocolo de un ciclo de reposo/pedaleo. Cada ciclo está compuesto por 10 segundos de reposo seguidos de un estímulo auditivo para avisar al sujeto que puede comenzar a pedalear por al menos 5 segundos. Para evitar que las señales EEG tuvieran un artefacto debido al estímulo auditivo, se avisó a los sujetos que esperaran un tiempo prudencial de varios segundos antes de iniciar el movimiento, siendo necesario que este tiempo fuera al menos de 3 segundos. En el caso de no respetarse estos tiempos mínimos de espera o pedaleo, el ciclo era descartado. Entre cada uno de los 5 ciclos se dejaba un tiempo variable siempre superior a 5 segundos.

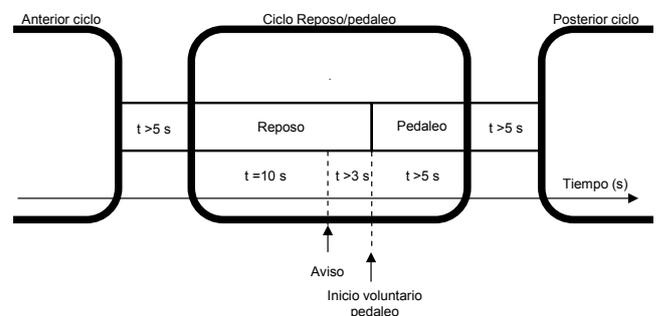


Figura 2: Protocolo utilizado durante las pruebas experimentales. Cada uno de los 16 registros por sujeto está constituido por 5 ciclos de reposo/pedaleo separados un tiempo variable siempre superior a 5 segundos. Un ciclo consta de 10 segundos en reposo, seguidos de un estímulo auditivo para avisar que se puede comenzar a pedalear. Es necesario esperar tras el estímulo al menos 3 segundos antes de iniciar el movimiento y mantener el pedaleo al menos durante 5 segundos tras los que el usuario era avisado de que podía dejar de pedalear.

2.2. Sujetos

Cinco sujetos sanos de entre 24 y 35 años (3 hombres y 2 mujeres, 28.6 ± 4.2 años), todos diestros, participaron voluntariamente en este experimento. Ninguno de los participantes tenía ninguna enfermedad neurológica conocida y todos dieron su consentimiento tras ser informados sobre el experimento. La Oficina Evaluadora de Proyectos (OEP) de la Universidad Miguel Hernández de Elche aprobó este estudio a través de su Comité de ética.

2.3. Interfaz cerebro-máquina

El interfaz cerebro-máquina desarrollado se explica en los siguientes subpuntos.

2.3.1. Adquisición de datos

El equipo utilizado para la captura de señales EEG fue el Enobio32 de Neuroelectrics ©. Este sistema transmite los datos registrados de forma inalámbrica por conexión bluetooth a una frecuencia de muestreo de 500 Hz. La distribución de los electrodos tuvo como base el Sistema Internacional 10/10 (P7, P4, CZ, PZ, P3, P8, O1, O2, C2, F8, C4, F4, FP2, FZ, C3, F3, FP1, C1, F7, OZ, PO4, FC6, FC2, AF4, CP6, CP2, CP1, CP5, FC1, FC5, AF3, PO3). El equipo cuenta con dos electrodos de

referencia ubicados en el lóbulo derecho de la oreja del usuario: Common Mode Sense (CMS) y DRL (Driven Right Leg). CMS actúa como canal de comparación con todas las señales EEG medidas, mientras que DRL se utiliza para llevar el potencial del sujeto lo más cerca posible del cero del sistema eléctrico. Ambos son importantes para asegurar una medición de alta calidad, reduciendo el ruido, especialmente de 50Hz, y la deriva de las señales EEG.

Por otro lado, con el fin de determinar con exactitud el instante inicial del pedaleo voluntario, se utilizó el sistema Tech MCS ©(Technaid S.L., España). Dicho sistema está compuesto por Unidades de Medida Inercial (Inertial Measurement Units, en inglés, IMUs). Cada IMU tiene tres tipos de sensores: un giróscopo 3D, un magnetómetro y un acelerómetro. De los 19 parámetros que proporciona cada IMU, únicamente se utilizó el giro en el eje perpendicular al plano sagital para calcular el inicio del pedaleo. Los datos de las IMUs fueron registrados a una frecuencia de muestreo de 20 Hz y enviados por cable al computador para el procesamiento. La arquitectura de software es la encargada de configurar ambos equipos, iniciando y deteniendo simultáneamente el registro de ambos. Esta arquitectura ha sido utilizada en anteriores trabajos sin problemas de sincronización o retardos significativos.

La ubicación de las dos IMUs utilizadas en cada pierna fue la parte exterior del tobillo y el tibialis anterior como puede verse en la Figura 1.

Todo el registro, así como el análisis explicado a continuación, fue desarrollado en Matlab ©.

2.3.2. Etiquetado de los datos

Puesto que el inicio de pedaleo de los sujetos de prueba es totalmente voluntario, es preciso determinar mediante las IMUs dicho instante, con el fin de etiquetar correctamente las señales EEG registradas para la creación del modelo clasificador. El inicio se establece cuando la información registrada por las IMUs excede para ambas piernas una velocidad angular de 0.1 rad/s y una aceleración angular de 0.001 rad/s². El valor de estos umbrales se obtuvo realizando varias pruebas previas y observando cuándo se producía el movimiento.

En base a lo indicado por (Toffanin et al., 2007; Nam et al., 2011), los potenciales ERD/ERS se producen desde los 2 segundos previos al movimiento hasta los 2 segundos posteriores. Es por ello que para los eventos de intención de pedaleo se consideran ventanas de que se inician 2 segundos previos al movimiento e incluyen los 2 segundos posteriores. Con el fin de evaluar si es posible detectar la intención de movimiento antes de que se produzca mediante potenciales ERD/ERS, también se realiza el análisis en ventanas de datos basadas únicamente en los dos segundos previos al movimiento. De este modo, hay dos tipos de ventanas de evento (reposo e intención de pedaleo) analizadas en el trabajo para duraciones de 2 y 4 segundos. A los datos de cada una de esas ventanas se le asigna una etiqueta 0 para reposo y 1 para intención de pedaleo. La Figura 3 muestra cómo se selecciona la información en ambos casos. Indicar también, que para la actualización temporal de los datos, el procesamiento se hace en subventanas de 1 segundo que son actualizadas cada 0.2 segundos. Por tanto, el número de subventanas a analizar por cada evento es de 16 para las ventanas de 4 segundos, y de 6 para las ventanas de 2 segundos.

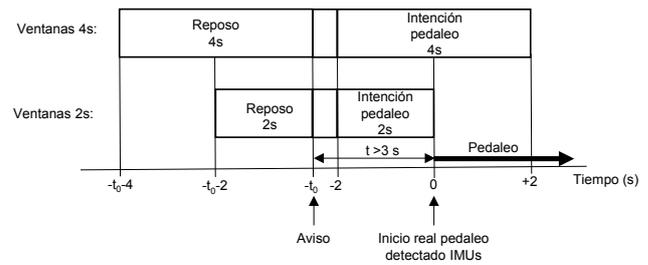


Figura 3: Selección de los datos para los dos tipos de ventanas analizadas en función del inicio real de pedaleo detectado mediante las IMUs. Considerando el inicio de la escala de tiempo en la detección de las IMUs cada evento de intención de pedaleo incluirá: los 2 segundos previos al movimiento $[-2, 0]$ para ventanas de 2 s, o los 2 segundos previos y posteriores al mismo $[-2, +2]$ para ventanas de 4 s. En el caso del evento de reposo, éste estará formado por: los 2 segundos previos al aviso acústico $[-t_0 - 2, -t_0]$ para ventanas de 2 s, o los 4 segundos previos $[-t_0 - 4, -t_0]$ para ventanas de 4 s.

2.3.3. Preprocesamiento

Para mitigar el ruido presente en la señal EEG obtenida, es preciso realizar un preprocesamiento. Éste depende del equipo de adquisición utilizado, ya que algunos equipos incorporan filtros por hardware. En este caso, se aplican tres filtros. En primer lugar, se utiliza un filtro Notch a 50 Hz para eliminar la influencia de la red eléctrica. Posteriormente, se usa un filtro Butterworth paso alto de orden 4 con una frecuencia de corte en 0.2 Hz. Finalmente, se aplica un filtro espacial de Referencia Media Común (Common Average Reference, en inglés, CAR), que elimina para cada electrodo la potencia media del resto de los electrodos ((Ludwig et al., 2009)).

A cada una de estas subventanas se le aplica el preprocesamiento indicado, se seleccionan los canales de estudio y se genera un vector de características etiquetado con su clase correspondiente para su posterior clasificación. La selección de canales y los algoritmos de procesamientos se explican a continuación.

2.3.4. Selección de Canales

Una vez preprocesados los datos, es necesario escoger la C.E. más pertinente. En este trabajo se ha optado por analizar 3 C.E. con ubicación en la corteza motora y premotora. Éstas configuraciones pueden ser vistas en la Figura 4 y han sido adoptadas en base a los mejores resultados obtenidos por el mejor de los métodos de la anterior investigación realizada en (Rodríguez-Ugarte et al., 2017) (Método D* con C.E. 1*, 2* y 4* respectivamente, ver Tabla 1 para -2 a 2 segundos del mismo). No se tuvo en cuenta también la C.E. 5* ya que para el sujeto 2 obtuvo un resultado similar a la C.E. 1*.

2.3.5. Extracción de Características

Se evalúan 5 algoritmos diferentes para extraer las características más importantes de las señales EEG y comprobar cuál de ellos ofrece mejores resultados.

Estos algoritmos están basados en transformadas menos habituales en el estudio en frecuencia de señales EEG que la Transformada Rápida de Fourier (Fast Fourier Transform en inglés, FFT), concretamente: la transformada de Stockwell (ST) y la transformada de Hilbert Huang (HHT). ST combina la transformada de Fourier y la transformada de Wavelet para mejorar la representación de la señal en frecuencia-tiempo ((Stockwell

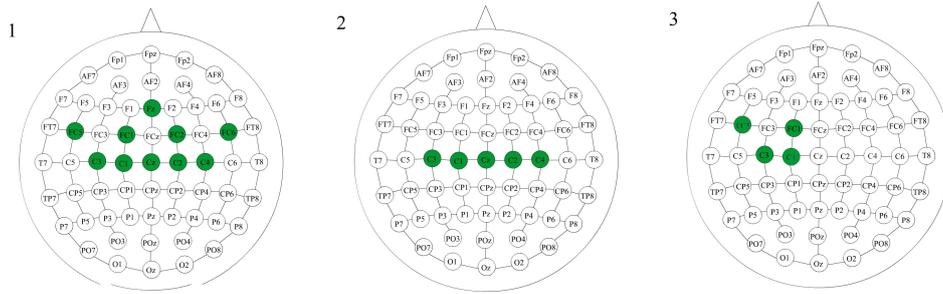


Figura 4: Configuración de electrodos basada en el Sistema internacional 10/10. Los electrodos en verde corresponden a los utilizados en cada configuración. Configuración 1: ubicados en la zona motora y premotora; Configuración 2: ubicados en la zona motora; Configuración 3: versión reducida de la primera configuración con electrodos ubicados en la zona motora y premotora del hemisferio izquierdo.

et al., 1996)). Por otro lado, HHT ((Huang et al., 1998)) combina un proceso iterativo de descomposición, la descomposición empírica modal (EMD), con la transformada de Hilbert (HT) ((Hahn, 1996)), para definir igualmente el contenido en frecuencia-tiempo de la señal. La Figura 5 muestra un ejemplo del espectro de una señal EEG para la banda de frecuencia 13-28 Hz. La figura fue obtenida mediante ST para una subventana de intención de movimiento en el electrodo C2.

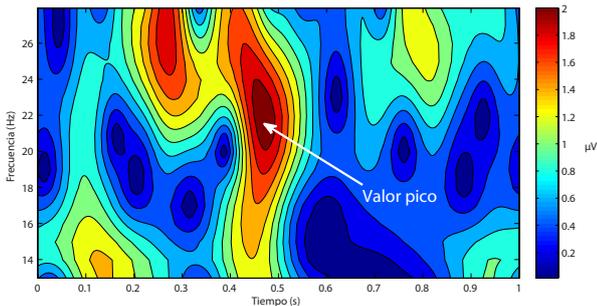


Figura 5: Espectro de frecuencia para el electrodo C2 en una subventana de intención de movimiento para la banda de frecuencia 13-28 Hz obtenida mediante ST. La figura muestra la composición de la señal en amplitud en un mapa de contorno con un pico entorno a los 22 Hz y una amplitud de unos 2 micro voltios.

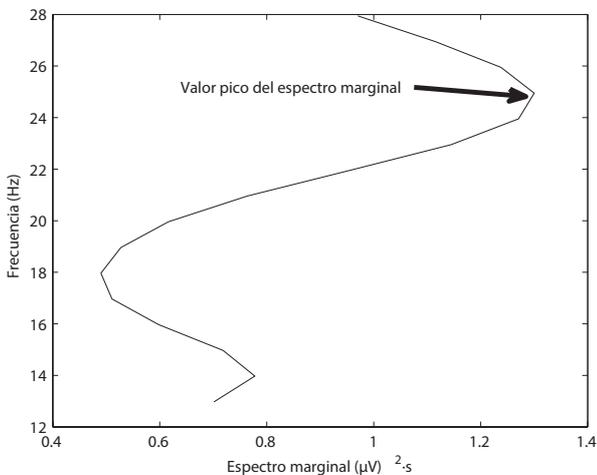


Figura 6: Espectro marginal para el electrodo C2 en una subventana de intención de movimiento para la banda de frecuencia 13-28 Hz. El valor a considerar en comparación con la Figura 5 se muestra para unos 25 Hz al tenerse en cuenta no el valor instantáneo máximo, sino la subventana de análisis completa.

Alguno de los algoritmos varían la extracción de características teniendo en cuenta el espectro marginal ((Huang et al., 1998)) en vez del valor de pico instantáneo. Éste integra la energía del espectro a lo largo de la ventana de tiempo analizada, como puede verse en la Figura 6. Otro modo de extraer las características que se tuvo en cuenta, utiliza la EMD ((Huang et al., 1998)) para extraer la energía de algunas de las funciones intrínsecas de modo (IMFs) obtenidas.

En la Figura 7, puede observarse las IMFs 3, 4 y 5 y su energía, tanto de modo instantáneo, como una vez integrada en la ventana de cálculo.

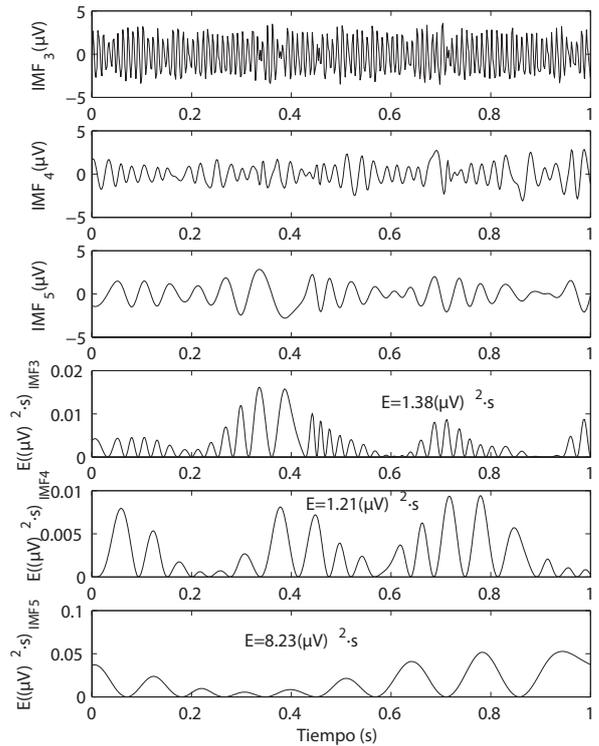


Figura 7: EMD para las IMFs 3, 4 y 5 del electrodo Cz en una subventana de intención de movimiento. Abajo se puede observar el valor instantáneo y el valor, una vez integrado, de energía de las componentes, que es el usado como característica.

Los algoritmos utilizados son:

- Algoritmo A: Valor de frecuencia en el que el espectro marginal es máximo para la banda 8-28 Hz. Análisis me-

dante ST. Este algoritmo genera 1 característica por electrodo.

- Algoritmo B: Valor pico puntual para las bandas: 1-4 Hz, 8-12 Hz y 13-28 Hz. Análisis mediante ST. Este algoritmo genera 3 características por electrodo.
- Algoritmo C: Valor pico puntual de amplitud y su valor de frecuencia, y valor máximo del espectro marginal y su frecuencia para las bandas: 1-4 Hz, 8-12 Hz y 13-28 Hz. Análisis mediante ST. Este algoritmo genera 6 características por electrodo.
- Algoritmo D: Valor máximo del espectro marginal para las bandas de frecuencia: 8-12 Hz, 13-24 Hz y 25-30 Hz. Análisis mediante HHT. Este algoritmo genera 3 características por electrodo.
- Algoritmo E: Energía de las IMFs obtenidas mediante EMD con valor de frecuencia instantánea media en las bandas beta (16-32 Hz), alfa (8-15 Hz) y theta (4-7 Hz). Estas IMFs para los electrodos estudiados suelen coincidir con las número 3, 4 y 5. Este algoritmo genera 3 características por electrodo.

2.3.6. Clasificación

El clasificador utilizado para crear el modelo y testarlo es conocido como Máquinas de Soporte Vectorial (Support Vector Machine, en inglés, SVM) ((Steinwart and Christmann, 2008)). Este clasificador fue escogido, porque en estudios previos, como el de (Planelles et al., 2014), se comprobó su buen funcionamiento y robustez en el análisis de señales EEG. SVM se basa en maximizar la separación de distintas clases mediante hiperplanos.

Los datos son analizados offline mediante una validación cruzada de 16 iteraciones. En cada iteración, una vez creado el modelo con 15 de las repeticiones, se obtienen las predicciones de cada subventana con la repetición restante. Además, a cada clase, que contiene 16 ó 6 subventanas de predicción (según el tamaño de la ventana de análisis), se le aplica una votación por mayoría, obteniendo como salida definitiva si el usuario se encontraba en reposo o pedaleando. En caso de empate, la salida seleccionada es reposo. Los resultados se obtienen comparando el ciclo en el que nos encontremos (reposo o pedaleo) con la salida obtenida del clasificador aplicándole la votación.

2.4. Parámetros de estudio

Como se indica en la introducción, a la hora de evaluar una BMI es preciso calcular al menos los siguientes parámetros:

La tasa de verdaderos positivos (True positive rate, en inglés, TPR): indica el porcentaje de eventos de intención de pedaleo correctamente detectados. Incluye por tanto el porcentaje de detecciones correctas para las ventanas de intención de movimiento.

$$TPR = \frac{\text{Número de eventos de pedaleo correctos}}{\text{Número total de eventos de pedaleo}} \quad (1)$$

Falsos positivos por minuto False positive per minute, en inglés, (FP/min): indica cuántas veces se ha detectado la intención de pedaleo durante los periodos de reposo.

$$FP/min = \frac{\text{Número de falsos eventos de pedaleo}}{\text{Tiempo eventos reposo}(min)} \quad (2)$$

Precisión (Accuracy en, inglés, Acc): indica cómo de preciso es el clasificador a la hora de clasificar los eventos. Evalúa por tanto el número de eventos detectados de forma correcta, independientemente sean de reposo o intención de movimiento, respecto del número total de eventos.

$$Acc = \frac{\text{Número de eventos correctos}}{\text{Número total de eventos}} \quad (3)$$

No obstante, a la hora de comparar los resultados de diferentes aproximaciones, resulta difícil evaluar tres parámetros a la vez. Por ello, (Rodríguez-Ugarte et al., 2017) introdujo el índice WD que se define por:

$$WD = 0,4 \cdot TPR + 0,6 \cdot Acc - FPR \quad (4)$$

Estando TPR y Acc en p.u. y siendo FPR:

$$FPR = FP/min \cdot \text{Duración de un FP en minutos} \quad (5)$$

Siendo la duración de un FP de 4/60 min y 2/60 min para las ventanas de 4 y 2 segundos respectivamente. WD da por tanto un índice que oscila entre -1 y +1 para evaluar de peor a mejor la actuación de las diferentes aproximaciones.

3. Resultados

El análisis de los resultados viene separado en varios puntos. En primer lugar se analiza si las ventanas de 2 segundos son suficientes para determinar la intención de de pedaleo. En segundo lugar se analiza cuál es la configuración de electrodos óptima. Y por último, se exponen los resultados globales comparando entre una solución general para todos los usuarios o una solución personalizada para cada uno.

Al analizar los resultados de las distintas configuraciones se ha utilizado el índice WD, ya que permite obtener de forma agregada los tres parámetros: TPR, Fp/min y Acc. Si existen varias opciones con WD similar, se le da más peso a aquella que obtenga menor FP/min ya que este índice resultaría bastante molesto en un aplicación en línea de la BMI.

3.1. Análisis de las ventanas de 2 y 4 segundos

La Tabla 1 muestra los resultados utilizando ventanas de evento de 4 segundos mientras que la Tabla 2 los muestra para ventanas de evento de 2 segundos.

De la observación de los resultados se puede concluir que el \bar{WD} por usuario para todas las C.E. tiene un valor más elevado para las ventanas de evento de 4 segundos que para las de 2 segundos, oscilando entre $[0.46 \pm 0.16, 0.67 \pm 0.15]$ en el primero de los casos y entre $[0.12 \pm 0.15, 0.29 \pm 0.11]$ en el segundo de ellos. Si observamos los resultados de \bar{WD} teniendo en cuenta las 3 posibles C.E. la diferencia es más acusada, variando los valores entre $[0.40 \pm 0.11, 0.73 \pm 0.08]$ y $[0.02 \pm 0.12, 0.35 \pm 0.15]$ respectivamente, para tamaño de evento de 4 y 2 segundos. Nótese, que para abreviar el contenido de las tablas, no se ha incluido la desviación típica para los valores de \bar{WD} por C.E. Adicionalmente, los valores de los FP/min resultan más altos para ventanas de 2

Tabla 1: Resultados ventanas 4 segundos: Valores de los parámetros obtenidos para el procesamiento de los 5 algoritmos para las 3 C.E. y 5 sujetos de pruebas. en los laterales y parte baja de la tabla se pueden observar los valores medios del índice agregado WD. En negrita se indican los mejores valores por usuario y valores promedio de WD.

		Sujeto			1			2			3			4			5			Promedio
		C.E.			1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	
Algoritmo	A	TPR(%)	66.3	67.5	51.3	77.5	72.5	82.5	84.0	77.3	78.7	65.0	50.0	50.0	56.3	47.5	37.5	64.3 ± 14.7		
		FP/min	3.9	2.4	1.1	3.9	3.0	2.3	2.6	3.4	4.0	1.9	2.4	5.3	2.3	3.9	2.3	3.0 ± 1.1		
		Acc(%)	75.3	83.2	90.4	77.5	80.8	87.1	86.2	82.9	72.5	86.6	80.1	58.8	89.6	62.6	70.8	79.0 ± 9.5		
		WD	0.45	0.61	0.67	0.51	0.58	0.70	0.68	0.58	0.48	0.65	0.52	0.20	0.61	0.30	0.43	0.53 ± 0.14		
	B	TPR(%)	63.8	66.3	60.0	80.0	70.0	81.3	77.3	78.7	74.7	71.3	55.0	57.5	73.8	63.8	52.5	68.4 ± 9.4		
		FP/min	3.2	3.4	2.3	4.9	3.2	2.8	3.4	4.0	3.0	1.9	2.3	3.6	1.1	0.8	0.8	2.7 ± 1.2		
		Acc(%)	75.2	78.5	83.4	74.8	73.2	78.3	81.0	80.6	76.4	86.4	74.6	69.0	95.3	97.2	91.0	81.0 ± 8.3		
		WD	0.49	0.51	0.59	0.44	0.51	0.61	0.57	0.53	0.56	0.68	0.52	0.41	0.79	0.79	0.71	0.58 ± 0.14		
	C	TPR(%)	62.5	72.5	72.5	75.0	66.3	82.5	70.7	70.7	80.0	63.8	70.0	61.3	82.5	83.8	77.5	72.8 ± 7.4		
		FP/min	3.8	3.6	3.0	4.3	4.3	3.9	3.2	3.4	3.0	3.4	2.6	5.8	2.4	2.1	0.8	2.7 ± 1.2		
		Acc(%)	73.8	73.2	79.8	77.1	67.2	79.6	75.4	81.3	77.9	76.6	83.9	63.8	86.7	89.2	97.2	78.8 ± 8.4		
		WD	0.44	0.49	0.57	0.48	0.38	0.54	0.52	0.54	0.59	0.49	0.61	0.24	0.69	0.73	0.84	0.54 ± 0.14		
	D	TPR(%)	63.8	70.0	63.8	62.5	57.5	80.0	76.0	77.3	85.3	72.5	60.0	60.0	70.0	56.3	26.3	65.4 ± 13.9		
		FP/min	4.3	3.6	3.6	1.5	3.8	3.4	4.8	5.0	4.4	2.4	2.4	4.5	1.5	1.5	0.9	3.2 ± 1.4		
		Acc(%)	73.2	77.7	73.7	81.3	59.0	82.5	70.5	73.8	72.8	84.4	83.1	70.7	93.0	90.3	76.0	77.5 ± 8.6		
		WD	0.41	0.51	0.46	0.64	0.33	0.59	0.41	0.42	0.48	0.63	0.58	0.36	0.74	0.67	0.50	0.52 ± 0.12		
	E	TPR(%)	22.5	71.3	52.5	48.8	47.5	82.5	74.7	66.7	74.7	62.5	53.8	45.0	87.5	77.5	71.3	62.6 ± 17.3		
		FP/min	2.4	8.6	3.8	0.9	2.3	3.8	2.0	5.0	3.4	4.5	3.8	4.3	1.5	1.3	1.9	3.3 ± 1.9		
		Acc(%)	48.0	57.9	64.8	67.0	69.3	80.1	81.8	70.7	80.2	71.5	70.3	62.3	93.3	93.1	89.6	73.3 ± 13.0		
		WD	0.22	0.06	0.35	0.53	0.46	0.56	0.66	0.36	0.55	0.38	0.39	0.27	0.81	0.78	0.70	0.47 ± 0.21		
		WD	0.40	0.43	0.53	0.52	0.45	0.60	0.57	0.49	0.53	0.57	0.52	0.30	0.73	0.65	0.63			
		WD Sujeto	0.46 ± 0.16			0.52 ± 0.10			0.53 ± 0.09			0.46 ± 0.15			0.67 ± 0.15					

Tabla 2: Resultados ventanas 2 segundos: Valores de los parámetros obtenidos para el procesamiento de los 5 algoritmos para las 3 C.E. y 5 sujetos de pruebas. en los laterales y parte baja de la tabla se pueden observar los valores medios del índice agregado WD. En negrita se indican los mejores valores por usuario y valores promedio de WD.

		Sujeto			1			2			3			4			5			Promedio
		C.E.			1	2	3	1	2	3	1	2	3	1	2	3				
Algoritmo	A	TPR(%)	48.8	35.0	46.3	62.5	61.3	68.8	36.0	78.7	64.0	56.3	42.5	57.5	35.0	50.0	52.5	53.0 ± 12.9		
		FP/min	10.9	7.1	4.5	10.5	11.3	12.0	10.0	14.8	8.4	10.9	10.5	9.4	13.5	12.0	15.8	10.8 ± 2.8		
		Acc(%)	61.3	55.0	77.8	59.3	60.1	67.3	49.8	64.1	64.5	58.3	52.1	61.7	38.1	52.9	46.1	57.9 ± 9.5		
		WD	0.20	0.23	0.50	0.26	0.23	0.28	0.11	0.21	0.36	0.21	0.13	0.29	-0.08	0.12	-0.04	0.20 ± 0.14		
	B	TPR(%)	50.0	56.3	56.3	62.5	56.3	75.0	60.0	61.3	64.0	57.5	40.0	53.8	40.0	58.8	42.5	55.6 ± 9.5		
		FP/min	9.8	9.8	7.1	7.9	10.5	9.4	7.2	10.0	8.8	8.6	13.5	10.9	11.3	6.8	10.9	9.5 ± 1.8		
		Acc(%)	57.0	59.9	69.6	66.7	60.7	71.8	67.4	67.1	64.4	70.8	41.7	57.2	44.2	77.4	54.8	62.0 ± 10.0		
		WD	0.22	0.26	0.41	0.39	0.24	0.42	0.40	0.31	0.35	0.37	-0.04	0.20	0.05	0.47	0.14	0.28 ± 0.15		
	C	TPR(%)	50.0	52.5	48.8	50.0	36.3	71.3	50.7	53.3	62.7	32.5	41.3	61.3	38.8	52.5	36.3	49.2 ± 10.8		
		FP/min	7.5	7.9	5.6	9.8	11.6	9.4	11.6	8.4	9.2	10.9	13.5	15.0	15.0	8.3	8.3	10.1 ± 2.8		
		Acc(%)	68.8	62.1	71.1	62.9	44.1	65.9	52.9	71.7	62.7	45.6	46.1	65.2	40.7	63.3	51.4	57.6 ± 10.3		
		WD	0.36	0.32	0.43	0.25	0.02	0.37	0.13	0.36	0.32	0.04	-0.01	0.08	-0.10	0.32	0.18	0.21 ± 0.12		
	D	TPR(%)	51.3	51.3	52.5	50.0	36.3	47.5	50.7	65.3	66.7	46.30	42.5	55.0	46.3	45.0	48.8	50.3 ± 7.8		
		FP/min	10.9	7.9	10.1	9.8	11.6	11.6	8.0	10.8	8.0	9.4	12.8	13.1	9.4	7.9	12.0	10.2 ± 1.8		
		Acc(%)	56.9	68.8	63.0	62.9	44.1	53.4	70.6	64.1	69.1	61.8	43.3	57.3	54.3	58.3	54.7	58.8 ± 8.2		
		WD	0.18	0.36	0.25	0.25	0.02	0.12	0.36	0.29	0.41	0.24	0.00	0.13	0.20	0.27	0.12	0.21 ± 0.12		
	E	TPR(%)	21.3	53.8	51.3	35.0	32.5	46.3	57.0	33.3	53.3	50.0	40.0	32.5	33.8	38.8	35.0	40.8 ± 10.3		
		FP/min	3.4	12.0	12.8	4.1	9.4	11.3	5.6	8.8	10.4	11.6	10.5	13.9	10.5	9.0	12.4	9.7 ± 3.1		
		Acc(%)	60.4	62.7	59.7	66.7	51.5	52.9	71.5	51.8	62.7	57.7	49.0	39.4	42.1	48.9	49.5	55.1 ± 9.0		
		WD	0.34	0.19	0.14	0.40	0.13	0.13	0.47	0.15	0.24	0.16	0.10	-0.10	0.04	0.15	0.02	0.17 ± 0.15		
		WD	0.26	0.27	0.35	0.31	0.13	0.26	0.29	0.26	0.34	0.20	0.04	0.12	0.02	0.26	0.08			
		WD Sujeto	0.29 ± 0.11			0.23 ± 0.13			0.30 ± 0.11			0.12 ± 0.13			0.12 ± 0.15					

segundos, siendo el valor de FP/min promedio para ventanas de 4 segundos de $FP/min=3.09 \pm 1.36$ mientras que para ventanas de 2 segundos alcanza $FP/min=10.06 \pm 2.50$. Aunque el WD permite comparar el comportamiento global de las diferentes aproximaciones, no se debe desestimar la importancia del valor de FP/min ya que en el uso en línea de la BMI, una mala detección durante reposo provocaría una activación no deseada del dispositivo de movimiento asistido asociado.

Por lo tanto, el análisis de los siguientes puntos se ha centrado en las ventanas de 4 segundos, al determinarse que úni-

camente con los 2 segundos previos al movimiento no se tiene suficiente información para detectar la intención de inicio de pedaleo a partir de las señales EEG mediante la aproximación escogida basada en ERD/ERS.

3.2. Resultados de las diferentes configuraciones de electrodos

Si se observan los datos de la Tabla 1, en los cuales se indican las C.E. personalizadas para cada sujeto, se obtiene que para los sujetos 1 y 2 la mejor configuración de electrodos es la 3, mientras que para los sujetos 3-5 la que obtiene mejores resul-

tados es la 1. En la Tabla 3 se puede observar el valor medio para las C.E., independientemente del sujeto de pruebas y algoritmo.

En principio puede parecer que la diferencia entre los valores medios es pequeña, pero si se observa el resultado en función del método y sujeto, la influencia de la C.E. puede ser mucho mayor. Por ejemplo en el caso del mejor resultado del sujeto 4, el algoritmo B obtiene un valor de WD de 0.68 para la C.E. 1 y de 0.41 para la C.E. 3. Sin embargo, en el caso del sujeto 1 la situación es la inversa, obteniéndose valores WD con el algoritmo A para la C.E. 1 de tan sólo 0.45 mientras que la C.E. 3 aumenta a 0.67. Por tanto, no es posible definir una C.E. de electrodos óptima sin personalizar por sujeto.

Tabla 3: Valor promedio de WD en función de la configuración de electrodos para ventanas de 4 segundos.

	C.E.		
	1	2	3
$\bar{W}D$	0.56±0.12	0.51±0.09	0.52±0.13

3.3. Resultados generalizados frente a personalizados

Unido al punto anterior se ve necesario definir una combinación de C.E. y algoritmo personalizada por sujeto. Observando, los mejores resultados por sujeto, estos se dan en 3 ocasiones para el algoritmo A y en 1 ocasión para el algoritmo B y C. Por tanto, los algoritmos D y E pueden ser descartados. En el caso del algoritmo D, aunque los resultados tengan un valor en media similar al A (WD de 0.52 vs. 0.53), sus bajos valores para los sujetos 1 y 3 nos han llevado a descartarlo y quedarnos únicamente con los 3 primeros algoritmos. En cuanto a los resultados por sujeto en base a la C.E., como se vio en el punto anterior, es recomendable personalizar la elección de los electrodos por sujeto, optando por la C.E. 1 para los sujetos 3-5 y la C.E. 3 para los sujetos 1 y 2.

Si se lleva a cabo una comparación de los algoritmos A, B y C personalizando la C.E. por sujeto se obtiene:

Tabla 4: Comparación de los WD para los algoritmos A, B y C personalizando por C.E. cada sujeto.

	Sujeto C.E.	WD					$\bar{W}D$
		1	2	3	4	5	
Algoritmo	A	0.67	0.70	0.68	0.65	0.61	0.66±0.03
	B	0.59	0.61	0.57	0.68	0.79	0.65±0.09
	C	0.57	0.54	0.52	0.49	0.69	0.56±0.08
Mayor diferencia WD respecto a algoritmo A		-	-	-	0.03	0.18	

Por dicha razón, aunque el algoritmo B obtenga un mejor valor medio en la Tabla 1, una personalización por sujeto de la C.E. revela que el algoritmo A obtiene en media un mejor resultado y con menor dispersión, siendo el algoritmo C el más penalizado por la personalización de la C.E.

4. Discusión

De los resultados expuestos se puede concluir que es necesario utilizar ventanas de evento de 4 segundos que incluyan desde los 2 segundos previos al inicio de pedaleo hasta los 2 segundos después. Se comprueba por tanto, que utilizando únicamente los dos segundos previos a la intención de pedaleo no se generan

resultados aceptables para su futuro uso en pruebas en línea. Hay que tener en cuenta, que para poder detectar un evento como intención de pedaleo, es necesario que el número de subventanas clasificadas sea mayoría. Eso, en ventanas de 2 segundos, significa un mínimo de 4 subventanas respecto de 6, mientras que para un evento de 4 segundos significa 9 subventanas de 16. Si el cambio en ERD/ERS por tanto no se aprecia en las primeras subventanas de los 2 segundos previos no es posible la correcta clasificación del evento.

En cuanto a los diferentes algoritmos, los resultados muestran que los algoritmos basados en HHT (D) y EMD (E), aunque pueden proporcionar resultados puntuales muy buenos, e.g. $\bar{W}D = 0.81$ para la C.E. 1 del sujeto 5, tienen unos valores muy variables. La razón de este comportamiento errático viene dada por la dificultad que presenta la EMD para separar tonos de frecuencia y obtener IMFs que permitan obtener un espectro de frecuencia sin tonos mezclados (Rilling and Flandrin, 2008). Ésto no sólo afecta al algoritmo D, sino también al E ya que una mala descomposición, además puede tener una influencia en los tonos asociados a las IMFs 3, 4 y 5; correspondiendo los tonos y características de energía extraídas de las distintas subventanas a bandas de frecuencia diferentes. Una supervisión de la extracción de las IMFs puede mitigar este problema. Sin embargo, esto resulta inviable para una BMI que debe actuar en línea de forma no supervisada. Por el contrario, los algoritmos basados en ST presentan un comportamiento más robusto, especialmente en los casos de los algoritmos A y B, que utilizan únicamente los valores de amplitud del espectro tanto marginal como puntual. La causa de que el algoritmo C obtenga un menor resultado puede estar relacionada con el hecho de introducir como parámetro adicional el valor de frecuencia. Un adecuado estudio de los pesos atribuidos a las características de frecuencia respecto a amplitud podría mejorar el resultado de este algoritmo. No obstante, al tener que ser este estudio de carácter heurístico, y probablemente personalizado por sujeto, lo limita como método a tener en cuenta en su aplicación en línea.

Una personalización de algoritmo por sujeto, aunque recomendable no es necesaria, ya que la mejora en WD salvo para el sujeto 5 o no se produce o es pequeña, ver Tabla 4. Pudiéndose considerar el algoritmo A como el que mejor resultado obtiene globalmente. No obstante, una personalización por C.E. sí que sería deseable. Globalmente, la C.E. 1, que incluye 10 electrodos en la zona motora, es la que mejores resultados obtiene para 3 de los 5 sujetos. La C.E. 3 obtiene en cambio los mejores resultados para los 2 sujetos restantes. Hay que tener en cuenta que la C.E. 3 corresponde a la C.E. 4* del artículo de (Rodríguez-Ugarte et al., 2017) que era una de las que ofrecía mejores resultados de forma global en la investigación previa. El hecho de que sea necesario personalizar la C.E. por sujeto, conlleva que en el protocolo de pruebas para el uso de la BMI en línea deba tenerse en cuenta. Sería por tanto necesario, a la hora de crear el modelo de clasificación de la BMI, realizar una comparación de resultados para ambos métodos y, en base al WD obtenido, optar por una u otra C.E. por sujeto de pruebas para las pruebas en línea. Esto no resulta muy problemático, puesto que la creación del modelo para unos 5 registros y el análisis por validación cruzada no ocupa en media más de 1 o 2 minutos.

Otro punto importante a discutir es determinar si los nuevos desarrollos de este artículo mejoran los trabajos previos. Para

poder hacer una comparación rigurosa de resultados es importante tener en cuenta varias cosas. En primer lugar, los resultados tienen dependencia del sujeto de pruebas y su grado de experiencia en el manejo de BMIs. Por lo tanto, es difícil realizar una comparación de resultados si el tamaño de muestra de sujetos no es suficientemente grande para que estadísticamente la media sea significativa. Una muestra significativa debería constar al menos de 30 sujetos, siendo raro que el volumen de sujetos en estudios de BMIs supere este valor (He et al., 2018). En segundo lugar, resulta complicado comparar resultados si el modo de calcular Acc es diferente o no se aportan datos de TPR o FP/min. Por último, es necesario aportar un índice que integre estos 3 parámetros. En este artículo se comparan los resultados de los nuevos algoritmos desarrollados con los obtenidos en el análisis offline de (Rodríguez-Ugarte et al., 2017) basados en FFT. Además, debido a que la base de datos de sujetos es compartida, la comparación de resultados resulta más rigurosa. Para ello, se comparan los resultados con los de la Tabla 1* y 2* de la investigación previa para ventanas de 4 s (el símbolo * indica que los datos se refieren a la investigación previa de (Rodríguez-Ugarte et al., 2017)). El método D* de dicha investigación, al igual que el método A de la actual, es el que tiene un comportamiento más estable para los 5 sujetos. Las Tablas 5 y 6 muestran una comparación entre ambos métodos personalizando por C.E. o por C.E. y algoritmo respectivamente, indicando de forma adicional los valores de TPR, Acc y FP/min con su desviación típica.

Tabla 5: Comparación algoritmos desarrollados respecto a los de (Rodríguez-Ugarte et al., 2017), personalizando la C.E. para ventanas de evento de 4 segundos. En * aparecen los resultados correspondientes a la anterior investigación. Se indica la dispersión mediante la desviación típica.

Sujeto	Algoritmo	C.E.	TPR (%)	FP/min	Acc (%)	WD
1	A	3	51.3±20.6	1.13±1.86	90.4±15.0	0.67
	D*	4*	63.8±24.5	1.69±2.18	89.1±13.7	0.68
2	A	3	82.5±20.5	2.25±2.32	87.1±12.9	0.70
	D*	5*	71.25±23.06	1.31±3.94	94.38±15.48	0.76
3	A	1	84.0±22.9	2.60±2.97	86.2±14.7	0.68
	D*	1*	71.3±29.2	2.25±2.57	78.6±26.9	0.61
4	A	1	65.0±23.7	1.88±2.16	86.6±14.7	0.65
	D*	1*	82.67±24.92	3.2±3.49	82.82±18.26	0.61
5	A	1	56.3±27.5	2.25±5.20	89.6±22.7	0.61
	D*	2*	57.5±26.2	2.44±2.73	81.65±21.76	0.56

Tabla 6: Comparación mejores algoritmos personalizando la C.E. y el algoritmo para ventanas de evento de 4 segundos. En * aparecen los resultados correspondientes a la investigación de (Rodríguez-Ugarte et al., 2017). Se indica la dispersión mediante la desviación típica.

Sujeto	Algoritmo	C.E.	TPR (%)	FP/min	Acc (%)	WD
1	A	3	51.3±20.6	1.13±1.86	90.4±15.0	0.67
	D*	4*	63.8±24.5	1.69±2.18	89.1±13.7	0.68
2	A	3	82.5±20.5	2.25±2.32	87.1±12.9	0.70
	E*	6*	50.0±27.3	0.19±0.75	93.8±25.0	0.75
3	A	1	84.0±22.9	2.60±2.97	86.2±14.7	0.68
	D*	1*	71.3±19.3	2.25±2.57	78.6±26.9	0.61
4	B	1	71.3±19.3	1.88±2.16	86.4±17.1	0.68
	C*	3*	67.5±20.5	2.44±2.50	83.7±16.8	0.61
5	C	3	77.5±24.1	0.75±3.00	97.2±11.1	0.84
	A*	1*	82.5±21.8	3.56±4.55	82.8±20.8	0.59

Tanto en un caso como en el otro, los nuevos algoritmos desarrollados presentan un mejor comportamiento que los basados en FFT para los sujetos 3-5. Tan sólo el sujeto 2 tiene unos resultados superiores para FFT, ya que en el caso del sujeto 1

los resultados son muy similares (0.67 vs 0.68) y el algoritmo A obtiene un valor inferior en FP/min.

Otro punto no comentado, pero importante para la implementación futura de la BMI en línea, es el tiempo de computación por subventana. En el caso de FFT, el procesamiento y clasificación de cada subventana de 1 segundo está en el rango de 10^{-4} segundos para el equipo utilizado en las pruebas, mientras que para ST ronda los 0.15 segundos. Los métodos basados en HHT y EMD superan en alguno de los casos los 0.2 segundos, lo que unido a su peor desempeño los hace desaconsejables como algoritmo. Si no se quiere obtener un retraso en el uso en tiempo real, el valor medio de computación no debería superar los 0.2 segundos. Este tiempo corresponde al movimiento de las subventanas de procesamiento, por lo que si se opta por otro intervalo habría que tenerlo en cuenta. En el caso de ST, esto podría limitar su uso si se emplean preprocesamientos adicionales o clasificadores diferentes a SVM que requieran un mayor tiempo de computación. En el caso de FFT, esto sería menos problemático ya que su procesamiento es mucho más rápido.

5. Conclusiones

Se puede concluir que los nuevos métodos desarrollados basados en la ST tienen un comportamiento más robusto que los basados en FFT. Adicionalmente, para mejorar el funcionamiento de la BMI en línea sería conveniente llevar a cabo una personalización por C.E. El coste de ello en tiempo en el protocolo de pruebas no es reseñable y podría ayudar a mejorar los resultados. Una personalización por sujeto del algoritmo también podría ser interesante, pero el número de combinaciones de electrodos y algoritmos debería ser limitado para no alargar en demasía los tiempos de cómputo y el protocolo de pruebas (no más de 2 C.E. y 2 algoritmos para unos 10 minutos).

Otra importante consecuencia extraída de los resultados estriba en la dificultad de detectar la intención de pedaleo utilizando subventanas compuestas únicamente por datos previos al movimiento real. Una detección de la intención motora a partir de datos previos al movimiento necesitaría de un enfoque basado en una aproximación diferente a la mostrada, que analiza el fenómeno ERD/ERS mediante la evaluación de subventanas. Esta aproximación alternativa debería intentar buscar cambios puntuales en las señales EEG previos al movimiento, evitando la utilización de clasificadores por mayoría, ya que se ven penalizados por las subventanas de procesamiento. Otra opción sería basar el control en periodos de imaginación motora en vez de intención de movimiento.

Para la primera de las opciones, las transformadas tratadas en este artículo, podrían resultar interesantes para detectar variaciones en el tiempo de las señales EEG basadas únicamente en los datos previos. Futuras investigaciones intentarán explotar esta idea, para mejorar la detección de intención de movimiento, como método alternativo de control respecto a la imaginación motora en BMI.

Agradecimientos

Este trabajo ha sido realizado en el marco del proyecto Asocciate - Decodificación y estimulación de actividad cerebral sensorial y motora para permitir potenciación a largo plazo mediante estimulación Hebbiana y estimulación asociativa pareada

durante la rehabilitación de la marcha (con referencia DPI2014-58431-C4-2-R), financiado por el Ministerio de Economía y Competitividad (Plan Estatal de I+D+I) y por la Unión Europea a través del Fondo Europeo de Desarrollo Regional - FEDER «Una manera de hacer Europa». También queremos agradecer a Neuroelectrics por prestar el equipo Enobio 32 para este estudio.

Referencias

- Amzica, F., Steriade, M., 1998. Electrophysiological correlates of sleep delta waves. *Electroencephalography and clinical neurophysiology* 107 (2), 69–83.
- Ang, K. K., Guan, C., 2013. Brain-computer interface in stroke rehabilitation. *Journal of Computing Science and Engineering* 7 (2), 139–146.
- Go, A. S., Mozaffarian, D., Roger, V. L., Benjamin, E. J., Berry, J. D., Blaha, M. J., Dai, S., Ford, E. S., Fox, C. S., Franco, S., et al., 2014. Executive summary: heart disease and stroke statistics—2014 update: a report from the American Heart Association. *Circulation* 129 (3), 399.
- Hahn, S. L., 1996. Hilbert transforms in signal processing. Vol. 2. Artech House Boston.
- He, Y., Eguren, D., Azorín, J. M., Grossman, R. G., Phat Luu, T., apr 2018. Brain-machine interfaces for controlling lower-limb powered robotic systems. *Journal of Neural Engineering* 15 (2), 021004.
URL <https://doi.org/10.1088/1741-2552/aaa8c0>
- Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., Yen, N.-C., Tung, C. C., Liu, H. H., 1998. The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London A: Mathematical, Physical and Engineering Sciences* 454 (1971), 903–995.
- Kilicarslan, A., Grossman, R. G., Contreras-Vidal, J. L., apr 2016. A robust adaptive denoising framework for real-time artifact removal in scalp EEG measurements. *Journal of Neural Engineering* 13 (2), 026013.
URL <https://doi.org/10.1088/1741-2560/13/2/026013>
- Kilicarslan, A., Prasad, S., Grossman, R. G., Contreras-Vidal, J. L., jul 2013. High accuracy decoding of user intentions using EEG to control a lower-body exoskeleton. In: Conference proceedings : Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual Conference. Vol. 2013. IEEE, pp. 5606–5609.
URL <http://ieeexplore.ieee.org/document/6610821/>
- Kwak, N.-S., Müller, K.-R., Lee, S.-W., oct 2015. A lower limb exoskeleton control system based on steady state visual evoked potentials. *Journal of Neural Engineering* 12 (5), 056009.
URL <http://stacks.iop.org/1741-2552/12/i=5/a=056009?key=crossref.d574e38494295e53b491abb83540a57c>
- Lopez-Gordo, M. A., Pelayo, F., Prieto, A., Fernandez, E., jun 2012. An Auditory Brain-Computer Interface with Accuracy Prediction. *International Journal of Neural Systems* 22 (03), 1250009.
URL <http://www.worldscientific.com/doi/abs/10.1142/S0129065712500098>
- López-Larraz, E., Trincado-Alonso, F., Rajasekaran, V., Pérez-Nombela, S., Del-Ama, A. J., Aranda, J., Minguez, J., Gil-Agudo, A., Montesano, L., aug 2016. Control of an ambulatory exoskeleton with a brain-machine interface for spinal cord injury gait rehabilitation. *Frontiers in Neuroscience* 10 (AUG), 359.
URL <http://journal.frontiersin.org/Article/10.3389/fnins.2016.00359/abstract>
- Ludwig, K. A., Miriani, R. M., Langhals, N. B., Joseph, M. D., Anderson, D. J., Kipke, D. R., 2009. Using a common average reference to improve cortical neuron recordings from microelectrode arrays. *Journal of neurophysiology* 101 (3), 1679–1689.
- Nam, C. S., Jeon, Y., Kim, Y.-J., Lee, I., Park, K., 2011. Movement imagery-related lateralization of event-related (de)synchronization (ERD/ERS): motor-imagery duration effects. *Clinical Neurophysiology* 122 (3), 567–577.
- Pfurtscheller, G., Brunner, C., Schlögl, A., Da Silva, F. L., 2006. Mu rhythm (de)synchronization and EEG single-trial classification of different motor imagery tasks. *Neuroimage* 31 (1), 153–159.
- Planelles, D., Hortal, E., Costa, Á., Úbeda, A., Iáñez, E., Azorín, J. M., 2014. Evaluating classifiers to detect arm movement intention from EEG signals. *Sensors* 14 (10), 18172–18186.
- Ramos-Murguialday, A., Broetz, D., Rea, M., Lärer, L., Yilmaz, Ö., Brasil, F. L., Liberati, G., Curado, M. R., Garcia-Cossio, E., Vyziotis, A., et al., 2013. Brain-machine interface in chronic stroke rehabilitation: a controlled study. *Annals of Neurology* 74 (1), 100–108.
- Rao, R. P., 2013. Brain-computer interfacing: an introduction. Cambridge University Press.
- Rilling, G., Flandrin, P., 2008. One or two frequencies? The empirical mode decomposition answers. *IEEE transactions on signal processing* 56 (1), 85–95.
- Rodríguez-Ugarte, M., Iáñez, E., Ortíz, M., Azorín, J. M., jul 2017. Personalized Offline and Pseudo-Online BCI Models to Detect Pedaling Intent. *Frontiers in Neuroinformatics* 11, 45.
URL <http://journal.frontiersin.org/article/10.3389/fninf.2017.00045/full>
- Shibasaki, H., Hallett, M., nov 2006. What is the Bereitschaftspotential? *Clinical Neurophysiology* 117 (11), 2341–2356.
URL <https://doi.org/10.1016/j.clinph.2006.04.025>
- Steinwart, I., Christmann, A., 2008. Support vector machines. Springer Science & Business Media.
- Steriade, M., 2005. Cellular substrates of brain rhythms. Vol. 5. Lippincott Williams and Wilkins, Philadelphia, PA.
- Stockwell, R. G., Mansinha, L., Lowe, R. P., Apr 1996. Localization of the complex spectrum: the s transform. *IEEE Transactions on Signal Processing* 44 (4), 998–1001.
- Toffanin, P., Johnson, A., De Jong, R., Martens, S., 2007. Rethinking neural efficiency: effects of controlling for strategy use. *Behavioral neuroscience* 121 (5), 854.
- Veneman, J. F., Kruidhof, R., Hekman, E. E., Ekkelenkamp, R., Van Asseldonk, E. H., Van Der Kooij, H., 2007. Design and evaluation of the Lopes exoskeleton robot for interactive gait rehabilitation. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 15 (3), 379–386.
- Yin, E., Zeyl, T., Saab, R., Hu, D., Zhou, Z., Chau, T., feb 2016. An Auditory-Tactile Visual Saccade-Independent P300 Brain-Computer Interface. *International Journal of Neural Systems* 26 (01), 1650001.
URL <http://www.worldscientific.com/doi/abs/10.1142/S0129065716500015>
- Zhang, Y., Prasad, S., Kilicarslan, A., Contreras-Vidal, J. L., apr 2017. Multiple kernel based region importance learning for neural classification of gait states from EEG signals. *Frontiers in Neuroscience* 11 (APR), 170.
URL <http://journal.frontiersin.org/article/10.3389/fnins.2017.00170/full>