

# Metodología para la Creación de una Interfaz Cerebro-Computador Aplicada a la Identificación de la Intención de Movimiento

del Castillo, M<sup>a</sup> D., Serrano, J.I., Ibáñez, J., Barrios, L.J

Grupo de Bioingeniería, CAR, CSIC,  
Ctra. Campo Real, km. 0,800, 28500 Arganda del Rey, Madrid, España  
(e-mail: [lola.castillo@car.upm-csic.es](mailto:lola.castillo@car.upm-csic.es), [ignacio.serrano@car.upm-csic.es](mailto:ignacio.serrano@car.upm-csic.es),  
[luis.barrios@car.upm-csic.es](mailto:luis.barrios@car.upm-csic.es), [jaimie.ibanez@car.upm-csic.es](mailto:jaimie.ibanez@car.upm-csic.es))

Resumen: Las Interfaces Cerebro-Computador proporcionan un canal para enviar órdenes al mundo exterior haciendo uso de medidas electrofisiológicas de la actividad cerebral. En este artículo se presenta la combinación de un método de selección de características y un algoritmo de clasificación probabilístico para construir el modelo predictivo de la intención anticipada de movimiento voluntario de pacientes con temblor a partir de un solo ensayo. Los resultados obtenidos muestran una potencial de discriminación del 70%, una tasa de error aceptable (6.6%) y una rápida respuesta (cada 250ms), lo que indica que esta combinación es una buena base para la construcción de ICCs que no requieran entrenamiento del usuario de forma personalizada, asíncrona y adaptativa. Copyright © 2011 CEA.

Palabras Clave: Interfaz Cerebro-Computador (ICC) asíncrona, señal electroencefalográfica, personalización, ritmos sensorimotora, minería de datos, adaptación, clasificación.

## 1. INTERFACES CEREBRO-COMPUTADOR (ICCs)

Las Interfaces Cerebro-Computador (ICCs) proporcionan una vía de comunicación entre un sujeto y su entorno para facilitar la interacción y el control del mismo sin utilizar su sistema nervioso periférico y sus músculos (Wolpaw *et al.*, 2002; Daly and Wolpaw, 2008). Las ICCs recogen la actividad cerebral, bien de manera invasiva, mediante electrodos implantados en la superficie o dentro de la corteza cerebral (Donoghue, 2002), bien de manera no invasiva, mediante electrodos ubicados en el cuero cabelludo. En cualquiera de los dos casos, el núcleo de la ICC es un algoritmo que transforma la señal encefalográfica que recibe del sujeto en comandos para controlar dispositivos externos como un cursor, una neuroprótesis o un neurorobot (Isa *et al.*, 2009). De este modo, la ICC se convierte en un nuevo canal de salida del cerebro que, como otros canales, puede regular su respuesta para adaptarla al objetivo propuesto.

La mayoría de las aplicaciones ICC registran señales electroencefalográficas (EEG) que presentan una resolución temporal alta, un coste aceptable y un riesgo bajo para el usuario. Una ICC basada en EEG utiliza determinadas características presentes en la señal bioeléctrica de entrada, las procesa y las emplea como señal de salida. Estas características pueden pertenecer al dominio del tiempo (Kutas and Hillyard, 1984) o al de la frecuencia (Farina *et al.*, 2007). En cualquiera de los casos, para la extracción de las características de la señal, es fundamental el procedimiento usado para medirlas. Este procedimiento debe considerar el tipo de electrodos y su posición, la referencia tomada, los filtros espaciales y temporales aplicados, entre otros métodos de procesamiento de la señal (Bashashati *et al.* 2007), y las condiciones de uso de la ICC por parte del sujeto. El objetivo es registrar con la mayor fiabilidad posible las características de la señal que codifican los mensajes del usuario.

Los métodos de procesamiento de la señal deben contribuir a minimizar el impacto del ruido, sea de origen neural o externo, en los rangos de frecuencia, tiempo o amplitud en los que se encuentran las características de la señal en las que la ICC basa su funcionamiento.

El algoritmo de la ICC procesa las características, que contienen las cualidades específicas del estado actual de la señal EEG de un sujeto en diversos dominios, y las transforma en órdenes que pueden ser utilizadas como entrada a un dispositivo que ejecuta una tarea práctica concreta dentro de la aplicación elegida de la ICC. Este algoritmo debe ser capaz de encontrar patrones de actividad cortical que reflejen la intención del usuario y que se adecúen a las restricciones de la aplicación.

Aunque una ICC es una herramienta que recoge y analiza la actividad cortical, su diseño y desarrollo están inevitablemente guiados por la aplicación a la que va a servir. La elección del algoritmo, aunque condicionada por la aplicación, puede articularse en torno a tres parámetros: el método para construir el modelo a partir de las características presentes, su capacidad de adaptación y el tipo de salida que proporciona (Wolpaw *et al.*, 2000). Todo ello debe analizarse detalladamente con el fin de elegir una solución que se ajuste a los requerimientos demandados por la aplicación en cuanto a eficacia, obteniendo una precisión óptima al acometer la tarea encomendada, y a eficiencia, en lo que respecta a la velocidad de respuesta y al tiempo necesario de entrenamiento del usuario. Este último aspecto está vinculado al tipo de señal que utiliza la ICC como entrada. Una ICC que emplee una señal endógena controlada por el usuario, como los ritmos sensorimotora (Pfurtscheller *et al.*, 2000), puede necesitar que éste ejercite exhaustivamente la tarea para conseguir que la señal tome valores dentro de unos rangos especificados. Una ICC basada en señales exógenas, como los potenciales evocados (Farwell and Donchin, 1988), no requiere

entrenamiento del usuario pero le ofrece un entorno a controlar más limitado y rígido.

El objetivo del trabajo, que aquí se describe, se centra en el diseño y desarrollo de una metodología para aprender gradualmente el modelo predictivo de la información contenida en la señal EEG de un sujeto con el fin de detectar anticipadamente la intención de sus movimientos voluntarios y notificarla a un sistema de control. Ese modelo predictivo analizará la actividad mental espontánea contenida en la señal EEG de un determinado sujeto de forma continua, esto es, sin restricciones temporales predefinidas, y asignará dicha actividad a la clase objetivo, de intención de movimiento, o a su complementaria, de inactividad o basal en tiempo real. El tipo de señal de entrada unido al modelo predictivo o clasificador de la misma y al tipo de señal de salida conforman una ICC asíncrona, adaptativa y personalizada.

Este artículo está organizado del siguiente modo: el apartado 2 presenta de forma detallada la aplicación objetivo. El apartado 3 describe la metodología empleada para el diseño y desarrollo de la ICC concebida para tal aplicación, el proceso de minería de datos llevado a cabo para establecer las características relevantes del fenómeno fisiológico que subyace a la clase bajo estudio y el método paramétrico elegido para obtener el modelo predictivo o clasificador. El apartado 4 muestra las pruebas realizadas y los resultados obtenidos. En el apartado 5 se discuten los aspectos críticos de la propuesta descrita. Por último, en el apartado 6 se exponen las conclusiones del trabajo presentado así como su proyección futura.

## 2. IDENTIFICACIÓN DEL MOVIMIENTO VOLUNTARIO

En las últimas décadas se han creado prototipos de ICCs para ayudar a personas con pérdida severa de su capacidad motriz, que pueden clasificarse atendiendo a diferentes dimensiones. Básicamente, las diferencias entre unas y otras radican en el paradigma que pretenden resolver y en el tipo de características de la señal EEG que emplean para generar acciones de control. Unas descansan en potenciales evocados como el P300 (Donchin *et al.*, 2000). Otro tipo de ICCs utilizan potenciales corticales lentos, que el usuario puede controlar con entrenamiento y observando la salida (Kubler *et al.*, 2000). Existen ICCs que emplean potenciales relacionados con el movimiento voluntario (MRP, Movement Related Potentials) (Mason and Birch, 2000), señales evocadas que se generan cuando los sujetos realizan algún tipo de tarea mental (Millán *et al.*, 2000; Serrano and del Castillo, 2005) o la variación de los ritmos sensorimotrices al realizar o imaginar un movimiento, que se manifiesta con una desincronización (ERD, Event Related Desynchronization) o caída de potencia anterior al inicio del movimiento en la banda alfa y una sincronización (ERS, Event Related Synchronization) o incremento de la potencia al final del movimiento (Pfurtscheller *et al.*, 2000) en la misma banda.

La mayoría de ellas trabajan en modo síncrono ya que indican de algún modo al sujeto que las usa el período de tiempo en el que éste puede realizar la tarea (Wang *et al.*, 2004). Son escasas las contribuciones en ICCs asíncronas que vayan más allá del ámbito teórico y que hayan sido probadas en aplicaciones reales. Yom-Tov e Inbar (2003) presentan una ICC asíncrona basada en MRPs para detectar y discriminar el movimiento de diferentes miembros en sujetos neurológica y muscularmente sanos, que

requiere para su entrenamiento un conjunto pequeño de datos pero que obtiene una alta tasa de detecciones erróneas.

Otro punto a considerar como la capacidad de una ICC para identificar la presencia de un movimiento en la señal EEG a partir de un ensayo único tiene poca repercusión en la literatura (Fazli *et al.*, 2009; Pfurtscheller *et al.*, 2006). El trabajo de (Gu *et al.*, 2009) para discriminar tipos y velocidad de movimiento de la muñeca está en esa línea. Utilizan como espacio de características los valores de ERD/ERS y MRP recogidos en cada uno de los ensayos realizados por diversos sujetos en lugar del promediado de ambas características para todos los ensayos. Es por tanto destacable que, en aquellos estudios en los que trabaja con datos experimentales, para mejorar la relación señal-ruido (Sannelli *et al.*, 2009), se realiza un promediado de las características de la señal EEG sobre varios ensayos de diferentes sujetos. De este modo, obvian la variabilidad propia de cada sujeto en cuanto a los valores subjetivos de esas características y a las ventanas temporales en las que se producen, dando lugar a ICCs con baja precisión.

Por último, señalar que son escasos los estudios sobre ICCs (Müller *et al.*, 2005; Wolpaw *et al.*, 2004) que incluyan pruebas experimentales con grupos de sujetos con las patologías para los que inicialmente fue concebida la ICC, obteniendo sus conclusiones a partir de sujetos sanos. En (Wolpaw *et al.*, 2004) se presenta una comparativa del control bidimensional de un cursor, mediante un método de regresión lineal que utiliza la amplitud de la señal EEG recogida en el área motora, entre pacientes con lesión medular, en los que la señal se captura en el cuero cabelludo, y primates no humanos, en los que se utiliza una implantación invasiva de electrodos. En (Müller *et al.*, 2005), el estudio se centra en un solo paciente para evaluar el incremento de su capacidad de controlar una ICC, mediante los ritmos sensorimotrices, con un entrenamiento de pocos días.

### 2.1 ICC para la Identificación del Movimiento Voluntario en Actividades de la Vida Diaria

El paradigma de la ICC que aquí se presenta, dentro del marco de un proyecto europeo, es el de controlar una neuroprótesis de miembro superior, utilizando dispositivos de estimulación eléctrica funcional (FES, Functional Electrical Stimulation), con el objeto de eliminar o cancelar el movimiento tembloroso de pacientes, diagnosticados con Parkinson y con temblor esencial, cuando realizan un movimiento voluntario en actividades de la vida diaria.

En una primera fase experimental, el sistema de control de la neuroprótesis recibe, además de la respuesta anticipada del clasificador para EEG aquí presentado, información de otras fuentes como la señal electromiográfica EMG y la señal procedente de unidades de medida inerciales (IMU, Inertial Measurement Unit), registradas ambas en el miembro superior objeto de control.

Los requisitos del paradigma que influyen directamente en la metodología de diseño y desarrollo del algoritmo clasificador de la ICC son los de una rápida respuesta en el tiempo y una alta resolución temporal, además de un alto porcentaje de movimientos voluntarios anticipados correctamente clasificados. La ICC propuesta descansa en el algoritmo clasificador de la señal EEG de un sujeto, registrada mediante electrodos dispuestos en el cuero cabelludo que cubre la corteza

sensorimotora, que analiza y clasifica la intención de movimiento del miembro superior dominante del sujeto. Uno de los objetivos es que esta ICC funcione en modo asíncrono, es decir, sin conocer de antemano el tiempo en el que se inicia la actividad mental asociada a la intención de movimiento (Townsend *et al.*, 2004). La intención de movimiento ha de ser detectada y discriminada del ruido y de otros eventos mentales tan rápida y precisamente como sea posible.

En la literatura relativa al estudio de las señales EEG se ha estudiado extensa y rigurosamente la actividad de determinadas poblaciones neuronales y su dinámica de cambio en relación con la realización de determinadas tareas (Pfurtscheller, 1977; (Pfurtscheller and Neuper, 1994; Pfurtscheller and Lopes da Silva, 1999). En concreto, los movimientos voluntarios producen una desincronización o disminución de la potencia localizada en el área sensorimotora en la franja superior de la banda de frecuencia alfa y en la banda de frecuencia beta (Pfurtscheller and Aranibar, 1979). Esta desincronización, promediada para varios ensayos, comienza alrededor de 2 segundos antes a la realización del movimiento en la región contralateral de Rolando y pasa a ser bilateralmente simétrica inmediatamente antes de la ejecución del movimiento. La desincronización es independiente de la duración del movimiento y su amplitud puede verse incrementada durante el aprendizaje de tareas motoras complejas o con la imaginación del movimiento previa a su realización. Este fenómeno electrofisiológico se puede interpretar como el reflejo de la actividad conjunta de determinadas áreas corticales involucradas en el procesamiento de información sensorial o cognitiva o en la generación de un movimiento voluntario (Pfurtscheller, 1992).

En pacientes de Parkinson se ha observado que, en promedio, este fenómeno se presenta menos lateralizado en el área sensorimotora contralateral y se retrasa con respecto al inicio del movimiento frente a los sujetos de control (Pfurtscheller *et al.*, 1981).

### 3. CLASIFICACIÓN DE LA INTENCIÓN DE MOVIMIENTO

El objetivo central de este trabajo es el de diseñar y desarrollar un método para construir sistemas que transformen una señal EEG en valores de características que representen el fenómeno neurológico subyacente previo al movimiento voluntario. Estos valores se emplearán para que el usuario pueda controlar el entorno.

Como se ha señalado anteriormente, en las señales EEG recogidas en el cuero cabelludo, las características que presenta la actividad mental previa al movimiento, como por ejemplo el fenómeno ERD, sólo son evidentes tras promediar un gran número de ensayos sobre un sujeto (Grainmann *et al.*, 2002). Con un solo ensayo, la relevancia de tales características es muy pobre comparada con la actividad mental subyacente en la señal. Para mejorar esa relevancia, y con ello la relación señal-ruido, se han realizado múltiples trabajos en los que se analizan de forma independiente técnicas de procesamiento de señal y de reconocimiento de patrones (Townsend *et al.*, 2006) con el fin de construir clasificadores precisos. En el trabajo que aquí se presenta se ha combinado un filtrado temporal, mediante la estimación de la potencia espectral media (PSD, Power Spectral Density), con un método de clasificación y se ha empleado una técnica de minería de datos para seleccionar las características

más relevantes del estado de desincronización previo al movimiento en cada sujeto para cada uno de los ensayos que realiza.

A partir de los datos recogidos de la corteza sensorimotora de un sujeto cuando ejecuta una tarea concreta de movimiento durante un número determinado de ensayos, un procedimiento de minería de datos extrae el conjunto óptimo de características que recoge el fenómeno bajo estudio, esto es, la presencia en la señal de la actividad mental relativa a la intención de movimiento. Con los datos representados de acuerdo a este conjunto óptimo, se construye, en primer lugar, el modelo informativo de la señal y, posteriormente, mediante un método de aprendizaje inductivo se construye el modelo predictivo de la misma. Haciendo uso del modelo predictivo, la ICC podrá clasificar la nueva señal EEG entrante de un sujeto en señales de control de dos categorías: 1) intención de movimiento o premovimiento y 2) no intención de movimiento o basal.

El objetivo del proceso de aprendizaje del modelo predictivo o clasificador de la señal es encontrar la descripción discriminante de la categoría de ejemplos "premovimiento", o ejemplos positivos, frente a la categoría "basal", o ejemplos negativos, a partir de la señal continua EEG recogida para un sujeto dado. Un ejemplo de la clase positiva, cuya descripción se pretende aprender, se representa mediante: 1) la potencia espectral media PSD, obtenida mediante el cálculo de la transformada rápida de Fourier (FFT, Fast Fourier Transform) (Drongelen, 2007) en una ventana de tiempo previa al inicio del movimiento voluntario para un intervalo de frecuencia, dentro de un rango de frecuencia concreta y para cada uno de los electrodos ubicados en el área sensorimotora. De acuerdo al fenómeno de desincronización, los rangos de frecuencia seleccionados pertenecen a las bandas alfa y beta; y 2) la desviación típica de las potencias espectrales instantáneas dentro del mismo intervalo de frecuencia y en la misma ventana de tiempo. Ambos atributos simbolizan el fenómeno ERD previo al inicio del movimiento, es decir, la caída de la potencia espectral con respecto a la de un período de reposo y el estancamiento de esa caída durante un intervalo de tiempo.

Puesto que se pretende detectar la intención de movimiento antes de que éste tenga lugar, el extremo superior de la ventana de tiempo previa a la ejecución del mismo se ubica 0.5s antes del inicio del movimiento. Del mismo modo se representan los ejemplos negativos de la clase "basal" pero situando la ventana temporal, del mismo tamaño que la de los ejemplos positivos, entre movimientos consecutivos donde el sujeto no realiza tarea motora alguna.

Se ha comprobado experimentalmente la inter-variabilidad entre sujetos y la intra-variabilidad en un mismo sujeto presente en la señal EEG a lo largo del tiempo por lo que la ICC se ha concebido para adaptarse a cada sujeto particular. Esto conlleva que el procedimiento para la selección de características conducente a obtener el modelo informativo se realice de forma personalizada para cada sujeto en una o varias sesiones y, por tanto, el modelo predictivo podrá ser único para cada sujeto. De este modo, el control del sistema final que utilice el usuario dependerá de la información presente en su propia señal.

#### 3.1 Selección de Características

La señal EEG recogida para esta ICC es multidimensional,

puesto que procede de un vector de electrodos, además de continua y variable en el tiempo. Constituye, por tanto, un conjunto exhaustivo de datos, con ruido y susceptible de ser un campo adecuado para la aplicación de técnicas de minería de datos (Flexer and Bauer, 2000). La minería de datos (DM, Data Mining) es la parte central de un proceso de descubrimiento de conocimiento útil y oculto en grandes base de datos (Fayyad *et al.*, 1996). Para llevarlo a cabo, se pueden emplear métodos procedentes de la estadística, del reconocimiento de patrones y del aprendizaje automático, entre otros.

Los canales a considerar para el paradigma objetivo que se localizan en el área sensorimotora del sistema internacional 10-20 son: FC3, FCz, FC4, C5, C3, C1, Cz, C2, C4, C6, CP3, CPz y CP4. La frecuencia de muestreo de la señal EEG de cada sujeto es de 256 Hz y se analizan ventanas de tiempo de 1.5s, 2s y 3s (384, 512, 768 muestras, respectivamente) situadas para los ejemplos positivos 0.5s antes del inicio del movimiento y para los negativos en el punto medio del intervalo entre dos movimientos consecutivos. Para cada canal, se toman en cuenta los intervalos solapados de frecuencia 7-9 Hz, 8-10 Hz, 9-11 Hz, 10-12 Hz, 11-13 Hz para la banda alfa (7-13 Hz) y el intervalo único 20-30 Hz, dentro de la banda beta (13-30Hz). En (Grainmann *et al.*, 2002) se establece que para considerar los patrones más importantes presentes en los ritmos sensorimotores es suficiente analizar el rango de frecuencias de 7 Hz a 34 Hz con una resolución en frecuencia de 1 Hz.

Además de este análisis para cada canal, también se tienen en cuenta los datos que resultan de realizar diferencias entre canales. Por tanto, para cada ventana de tiempo, se construye una base de datos formada por ejemplos positivos y negativos expresados como:  $e_{ijk} = \{wt_i, ch_j, fb_k, PSD, \Delta PSD\}$ , donde  $wt_i$  es la ventana de tiempo que puede tomar los valores 1.5, 2 o 3,  $ch_j$  es un canal o una diferencia de canales y  $fb_k$  es un intervalo de frecuencia. PSD y  $\Delta PSD$  representan la potencia espectral media y la variación de la potencia instantánea una vez establecidos los parámetros previos. La resolución de PSD, dependiendo del tamaño de la ventana de tiempo de 1.5s, 2s o 3s es de 0.66, 0.5 o 0.33 Hz, de modo que el número de muestras considerado para su cálculo en intervalos de frecuencia de 2 Hz es de 3, 4 y 6, respectivamente (Drongelen, 2007).

Con el fin de reducir la alta dimensión de los datos (13 canales, 6 intervalos de frecuencia y 3 ventanas de tiempo), sin que ello suponga pérdida de efectividad del clasificador final, el proceso de DM busca que este espacio de características alcance su tamaño óptimo. Este aspecto ha sido estudiado por diversos autores, concluyendo que este tamaño está en torno al 25% del tamaño inicial (Yang and Honavar, 1998). El procedimiento empleado para optimizar el espacio de características o vocabulario y, con ello, el tiempo que emplearía un clasificador basado en este vocabulario en clasificar un ejemplo, se lleva a cabo mediante un algoritmo genético (Goldberg, 1989) combinado con un método de aprendizaje bayesiano. El algoritmo genético parte de una población inicial compuesta por un conjunto de vocabularios con distinto número de características. Mediante la aplicación de operadores genéticos, el algoritmo persigue la evolución y convergencia hacia un vocabulario final óptimo. La bondad de cada vocabulario se calcula en función de la precisión en la clasificación que obtiene un clasificador bayesiano sobre ejemplos representados de acuerdo a las características de ese vocabulario.

Este es el procedimiento seguido de manera esquemática:

- i) Se construye la población de vocabularios formados por un número variable de características.
- ii) Los ejemplos positivos y negativos se representan de acuerdo a cada vocabulario.
- iii) Para cada vocabulario, se realiza una validación cruzada de 10 subconjuntos sobre los ejemplos de las dos clases, premovimiento y basal.
- iv) Se construyen las distribuciones de probabilidad de cada característica para ambas clases utilizando 9 subconjuntos de ejemplos de entrenamiento.
- v) Se clasifica el subconjunto de test. Un ejemplo se clasifica en la clase para la que obtenga la mayor probabilidad de acuerdo a:  $P(\text{ejemplo}|\text{Clase}_k) = \prod p(\text{Clase}_k|\text{característica-valor})$ . El término  $p(\text{Clase}_k|\text{característica-valor})$  se obtiene de la distribución de probabilidad obtenida con los valores PSD y  $\Delta PSD$  de todos los ejemplos de entrenamiento.
- vi) Se calcula la precisión media de la validación cruzada de 10 subconjuntos y se asigna como valor de bondad al vocabulario correspondiente.
- vii) Se aplican operadores de selección, cruce y mutación y con la nueva población se repite el procedimiento desde el paso ii) hasta que la bondad de todos los vocabularios de esa población converge al mejor valor. Se observa que el tamaño de la población final se sitúa en torno al 25% del tamaño de partida.

Este procedimiento de minería de datos se lleva a cabo para cada sujeto en diferentes sesiones, de modo que el resultado del mismo conduce a establecer el conjunto óptimo de canales, la ventana de tiempo y los intervalos de frecuencia en los que el sujeto analizado presenta el fenómeno de desincronización de forma más discriminante.

### 3.2 Algoritmo Clasificador Adaptativo

Una vez determinado el vocabulario óptimo de características para el sujeto estudiado, se representan los ejemplos positivos y negativos de su señal con respecto a ellas. El método elegido para extraer su modelo predictivo es un algoritmo probabilístico bayesiano. Este algoritmo calcula la probabilidad explícita que tiene cada ejemplo de pertenecer a una clase partiendo de la hipótesis de que las características o atributos del vector ejemplo son estadísticamente independientes (Mitchell, 1997), de manera que:  $P(\text{ejemplo}|\text{Clase}_k) = \prod p(\text{Clase}_k|\text{atributo-valor})$ , donde  $p(\text{Clase}_k|\text{atributo-valor})$  se extrae de la distribución de probabilidad presente en los ejemplos de entrenamiento del clasificador. El término  $\text{Clase}_k$  puede tomar el valor “premovimiento” y “basal”.

A pesar de que la aplicación de este método asume la independencia estadística de los atributos de los ejemplos de un dominio dada la clase de los mismos, en la práctica ha demostrado una efectividad óptima, e incluso superior a la de otros métodos, en la clasificación en muchos dominios donde existe una clara dependencia entre atributos (Domingos y Pazzani, 1996). El dominio de las señales electrofisiológicas es un ejemplo más de dicha dependencia entre características. La razón que subyace a este comportamiento óptimo se encuentra en que, aunque el método pueda producir estimaciones poco realistas de la probabilidad de que un ejemplo pertenezca a una clase, la clase correcta a la que el ejemplo realmente pertenece

obtiene la mayor estimación y, de este modo, el método produce la clasificación correcta.

Por otra parte, la elección de este algoritmo también radica en su eficiencia de cálculo, que se reduce a un producto de valores. Además, puesto que su potencial predictivo descansa en la distribución a priori de los valores de los atributos de los ejemplos de entrenamiento o modelo informativo de los mismos, este modelo puede actualizarse de forma rápida y sencilla a medida que se dispone de más ejemplos de entrenamiento o de los aciertos o fallos que pudieran realimentar al clasificador. El paradigma presentado puede beneficiarse de esta última característica ya que en tiempo real de clasificación de la señal de un sujeto, el clasificador puede disponer de los errores y aciertos en la identificación de la intención del movimiento voluntario gracias a la información que suministra el sensor inercial sobre la realización o no del movimiento real. Todo ello otorga a la ICC su capacidad adaptativa al sujeto y a sus circunstancias bioeléctricas durante el uso de la misma. De esta manera, la ICC podrá ajustar su respuesta gradualmente en el tiempo al estado mental del usuario.

En (Bai *et al.*, 2007) se presenta un estudio detallado de diferentes métodos computacionales para la predicción sincrónica de la intención de movimiento. En este estudio, se observa el buen comportamiento de los clasificadores bayesianos y de las máquinas de vectores de soporte en la clasificación para diferentes caracterizaciones de la señal con datos procedentes de sujetos sanos. Sin embargo, a diferencia de la propuesta que se presenta aquí, la característica basada en el fenómeno ERD se obtiene promediando todos los ensayos llevados a cabo por todos los sujetos y el tamaño y la posición de la ventana temporal previa al movimiento se establece de manera determinista.




Figura 1. Esquema del flujo de la información EEG hasta su clasificación.

#### 4. PARADIGMA EXPERIMENTAL

##### 4.1 Adquisición de Datos

En este trabajo se han llevado a cabo dos experimentos relacionados con la realización de movimientos. En el primer experimento, tres sujetos de control diestros realizaron una tarea de extensión y flexión de la muñeca de la mano derecha sentados en una silla y con el antebrazo apoyado en el brazo de la misma. Los sujetos, dos varones de 25 y 33 años y una mujer de 26 años, eligieron libremente los instantes de tiempo en los que ejecutar el movimiento después de escuchar un estímulo auditivo.

En el segundo experimento participaron cuatro sujetos diestros con temblor postural y cinético. Tres de ellos, varones de 37, 68 y 72 años, realizaron una serie de tandas de ensayos consistentes en mover periódicamente el dedo índice de la mano derecha hacia la nariz un intervalo de tiempo elegido libremente después de reproducirse una señal acústica, partiendo de una posición de reposo y retornando a ella una vez realizado el movimiento. Para el cuarto paciente, mujer de 72 años, la tarea fue la de extensión y flexión de la muñeca derecha.

En ambos experimentos y para cada sujeto, las sesiones de medida se dividieron en seis tandas con un número variable de ensayos dependiente de cada sujeto y con una duración media por tanda de 4 minutos. Los ensayos registrados que presentaban un período de tiempo inferior a 10s desde la emisión de la señal acústica hasta el inicio del movimiento fueron eliminados con el fin de que la señal existente entre movimientos consecutivos no estuviera contaminada por el potencial evocado por la señal acústica.

El registro de la señal se ha realizado mediante un sistema g.EEGcap de 65 electrodos g-tec y un amplificador g.USBamp a 256Hz, para los canales FC3, FCz, FC4, C5, C3, C1, Cz, C2, C4, C6, CP3, CPz y CP4 del sistema internacional 10-20, ubicados en el área sensorimotora. Se ha aplicado un filtro Notch (50Hz) y un filtro pasobanda (0.5Hz-100Hz). Las medidas se referenciaron al potencial común de ambas orejas y el canal Fz se empleó como tierra.

Además, se registraron los movimientos de la mano y el brazo derecho mediante sensores inerciales, de modo que el clasificador pudo disponer del tiempo de inicio y fin de cada movimiento sincronizado con la señal EEG.

##### 4.2 Procesamiento de Datos

Para llevar a cabo la interpretación de los resultados de la metodología propuesta en este artículo, los datos registrados de cada sujeto durante las sesiones sincrónicas realizadas se han empleado para simular la ICC operando de forma asincrónica.

En ambos experimentos, las seis tandas registradas para cada sujeto en una sesión se han dividido en cinco tandas de entrenamiento y una de clasificación empleando una validación cruzada de cinco subconjuntos. Sobre los ensayos contenidos en las tandas de entrenamiento se realizó el procedimiento de minería de datos anteriormente descrito. En primer lugar, para cada canal, la señal de cada tanda se procesó y se filtró en intervalos de frecuencias solapados de 2 Hz en la banda alfa desde (7-13 Hz) y en un intervalo único (20-30 Hz) de la banda beta. Para cada intervalo de frecuencia, se obtuvieron los valores de PSD y  $\Delta$ PSD de la señal en ventanas de tiempo de tamaño variable (1.5s, 2s, 3s) situadas 0.5s antes del movimiento, para los ejemplos positivos, y ventanas basales del mismo tamaño situadas en el punto medio del intervalo entre dos movimientos consecutivos, para los ejemplos negativos.

Tras la representación de todos los ensayos con respecto a estas características, se ha realizado un pre-procesamiento de todos los ejemplos positivos y negativos de cada sujeto. Un ejemplo (positivo o negativo) está afectado de artefactos cuando su valor  $v$  de PSD (o  $\Delta$ PSD) está por encima de la suma del valor de la mediana  $M$  de PSD (o  $\Delta$ PSD) de todos los ejemplos de ese

sujeto y la diferencia entre dicha mediana  $M$  y el valor menor  $m$  de PSD (o  $\Delta$ PSD) de todos los ejemplos. Es decir, si  $v$  de un ejemplo (positivo o negativo) es mayor que  $2M-m$ , ese ejemplo (positivo o negativo) y su complementario (positivo o negativo) son eliminados del análisis y, con ello, se elimina el ensayo en cuestión.

Una vez obtenidas las características óptimas mediante el procedimiento de minería de datos descrito en el apartado 4.1, la tanda de clasificación se representó de acuerdo a ellas. La clasificación de esta tanda se realizó analizando la señal cada 250ms de forma continua y calculando el valor PSD y  $\Delta$ PSD de cada característica sobre la ventana temporal óptima obtenida mediante minería de datos.

Los sensores inerciales suministraron los instantes de tiempo en los que el sujeto ejecutaba un movimiento real, necesarios tanto para situar las ventanas de tiempo de los ejemplos positivos y negativos de las tandas de entrenamiento como para calcular las medidas de efectividad del clasificador en las tandas de clasificación.

Puesto que cada 250ms el clasificador da una respuesta sobre la clase a la que pertenece la ventana de tiempo de la señal que analiza y con el fin de optimizar la efectividad del clasificador, se ha definido un parámetro, la unidad de activación (UA). La UA representa el número de muestras consecutivas en las que el clasificador, para la simulación asíncrona, detecta la clase objetivo con una probabilidad superior a un umbral, establecido empíricamente. Una UA es un verdadero positivo (TP, True Positive), si se presenta en el intervalo que comienza al menos 0.5s antes de un movimiento y puede prolongarse hasta el final del movimiento, y es un falso positivo (FP, False Positive), si se presenta en el intervalo comprendido entre el final de un movimiento y 0.5s antes del siguiente movimiento. La UA pretende recoger también la característica temporal del fenómeno fisiológico ERD considerado (Pfurtscheller and Aranibar, 1979), es decir, la duración de la caída de potencial en las bandas de frecuencia bajo estudio se mantiene durante un período de tiempo superior al tiempo de muestreo de la clasificación.

#### 4.3 Análisis de los Resultados

En el primer experimento, tras el procedimiento de selección de características y la validación cruzada, se obtiene para los tres sujetos de control considerados que el clasificador más eficaz utiliza como canales más discriminantes los canales C1, C3, Cz, C2 y C4, además de los canales CP3 y CP4. Los intervalos de frecuencia obtenidos varían dependiendo del sujeto. La diferencia entre canales no aportó ninguna mejora en la clasificación. En todos los sujetos, la mejor ventana de tiempo previa al movimiento fue la de 3s. La precisión Acc que se obtuvo, medida como el cociente entre las clasificaciones correctas para ambas clases (premovimiento y basal) y las clasificaciones correctas junto con las incorrectas para ambas clases se encontraba entre el 67% y el 82% ( $Acc = TP + TN / TP + TN + FP + FN$ , donde TP=True Positive, FP=False Positive, TN= True Negative y FN=False Negative).

Además de Acc, se calcularon otras medidas de efectividad para la clase "premovimiento" como  $Pr = TP / TP + FP$ , que mide el porcentaje de premovimientos predichos por el clasificador que se corresponden con movimientos reales registrados por los

sensores inerciales. Por ejemplo, si el clasificador detecta 5 premovimientos pero los sensores sólo han registrado 4, FP toma el valor de 1 y Pr sería igual a 0.8. Otra medida como  $Rc = TP / TP + FN$  mide el porcentaje de movimientos realmente realizados por el sujeto, y registrados por los sensores inerciales, que han sido detectados por el clasificador. Por ejemplo, si el clasificador detecta 4 premovimientos pero los sensores han registrado 6, FN toma el valor de 2 y Rc sería igual a 0.66.

La Tabla 1 recoge los datos característicos de Pr y Rc de cada sujeto de control, filas segunda y tercera, así como los rangos de frecuencia óptimos para cada sujeto en la octava fila. La cuarta fila presenta la longitud media por sujeto de las UAs verdaderas, esto es, la duración de una UA detectada por el clasificador antes del inicio de un movimiento realmente realizado. La quinta fila presenta la longitud media por sujeto de las UAs falsas, es decir, de las falsas detecciones de premovimiento hechas por el clasificador en período de reposo o basal.

**Tabla 1. Parámetros de clasificación de cada sujeto de control**

Control	C1	C2	C3	Media $\pm$ SD
Pr	0.75	0.70	0.60	0.68 $\pm$ 0.07
Rc	0.60	0.83	0.65	0.69 $\pm$ 0.12
Longitud media Verdadero UA (s)	3.50	4.13	2.50	3.37 $\pm$ 0.82
Longitud media Falso UA (s)	0.80	1.00	0.85	0.81 $\pm$ 0.16
Falsos UA/Basal (%)	2.70	5.00	4.00	3.90 $\pm$ 1.15
Tiempo Anticipo (s)	0.82	1.22	0.99	1.01 $\pm$ 0.21
Mejor Frecuencia (Hz)	11-13	11-13	9-11	

En el segundo experimento, realizado con pacientes, el clasificador más eficaz obtenido con los datos analizados emplea para los cuatro pacientes los canales C3, Cz y C4. Los intervalos de frecuencia son distintos para cada paciente y la mejor ventana para todos ellos fue la de 3s. El valor medio de Pr para los cuatro pacientes fue de 47% y el de Rc de 70%.

**Tabla 2. Parámetros de clasificación de cada paciente**

Paciente	P01	P02	P03	P04	Media $\pm$ SD
Pr	0.45	0.36	0.47	0.60	0.47 $\pm$ 0.08
Rc	0.52	0.75	0.68	0.85	0.70 $\pm$ 0.12
Longitud media Verdadero UA (s)	1.41	0.45	1.70	1.76	1.33 $\pm$ 0.50
Longitud media Falso UA (s)	0.90	1.00	0.95	0.51	0.83 $\pm$ 0.30
Falsos UA/Basal (%)	6.0	6.5	7.20	7.00	6.67 $\pm$ 0.53
Tiempo Anticipo (s)	0.29	0.55	0.16	0.30	0.32 $\pm$ 0.14
Mejor Frecuencia (Hz)	9-11	11-13	8-10 20-22	9-11	

La Tabla 2 muestra los datos de Pr y Rc para cada paciente y sus rangos de frecuencia óptimos. En el mejor de los pacientes, las medidas Pr y Rc tomaron valores del 60% y el 85%, respectivamente. La Figura 2 muestra la clasificación de una tanda de 10 movimientos para este paciente en la que se observa que el clasificador ha detectado 9 de los 10 movimientos.

Como se indica en (Townsend *et al.*, 2004) en el desarrollo de una ICC asíncrona es esencial interpretar adecuadamente los resultados de la clasificación. Las señales EEG tienen que ser analizadas y clasificadas de manera continua, detectando y discriminando el evento objetivo del ruido y de otros eventos mentales. Los trabajos de Mason y Birch (2000) y de Yom-Tov e Inbar (2003) presentan la aplicación de curvas ROC (Receiving Operating Characteristic Curve) como medida de evaluación de la respuesta de una ICC asíncrona. En ambos trabajos, uno, considerando movimientos imaginados y, el otro, movimientos reales, la tarea se realiza con una periodicidad baja, es decir, los intervalos de tiempo entre movimientos consecutivos son muy pequeños comparados con la duración del movimiento. Además, las múltiples detecciones de la categoría positiva o “premovimiento” durante un período en el que no hay movimiento real se contabilizan como un solo falso positivo (FP). Sin embargo, en el paradigma presentado en este artículo, la duración del período en el que no se realizan movimientos o período basal puede ser muy superior a la duración del movimiento y las curvas ROC no se consideran apropiadas para evaluar la respuesta de la ICC.




Figura 2. Clasificación de una sesión del paciente con mayor Rc utilizando validación cruzada de 5 tandas.

Por ello, la medida Pr, presentada anteriormente, puede no reflejar fielmente la realidad del rendimiento del clasificador ya que, para su cálculo, no se ha tenido en cuenta que el 82% del tiempo el clasificador analiza una señal que corresponde a períodos de reposo o basales y sólo el 2% corresponde a períodos de movimiento. Con el fin de presentar de forma realista la efectividad del clasificador, en lo que a generación de falsos positivos respecta en este paradigma objetivo, se ha establecido un método para valorar el número de FPs. Con un período de clasificación  $T$  y un tiempo medio  $t$  entre el final de un movimiento y  $0.5s$  antes del siguiente movimiento, el número máximo de falsos positivos que podría identificar el clasificador en dicho intervalo  $t$  sería  $FP_{m\acute{a}x}=t/T$ . El número total de falsos positivos en una sesión de  $X$  tandas de ensayos con una media de  $Y$  ensayos por tanda sería  $FP_{posibles}=X*Y*FP_{m\acute{a}x}$ . Si la duración media de las falsas UAs es  $t'$ , esta UA podría contener  $FP_{local}=t'/T$  posibles falsos positivos. Conocido el número de UAs que el clasificador ha predicho como falsos positivos y que cada UA puede contener  $FP_{local}$  falsos positivos, el valor de  $FP*FP_{local}$  representa el número de puntos en el tiempo que el clasificador ha detectado como falsos positivos. El cociente  $FP_{local}/FP_{posibles}$  representa una medida de las muestras

detectadas como falsos positivos por el clasificador en relación a todas las que podría haber detectado.

Las Tablas 1 y 2 muestran en la sexta fila (Falsos UA/Basal) el valor final medio obtenido de falsos positivos para cada sujeto. Para los sujetos de control, este valor es de  $3.9\pm 1.15\%$  y para los pacientes fue de  $6.6\pm 0.5\%$ . Esto significa, por ejemplo para los pacientes, que el clasificador en un minuto (60s) de reposo o de actividad basal del sujeto hace 240 predicciones (1 cada 250 ms) y, aproximadamente, 15 predicciones son erróneas. Este valor, dadas las características del tipo de tarea motora analizada, con grandes períodos de reposo ofrece una visión más certera de la capacidad de error del clasificador que el valor medio de Pr.

Analizando, por último, la duración media de las UAs verdaderas para los controles,  $3.37\pm 0.82s$ , y para los pacientes,  $1.33\pm 0.5s$ , en la fila cuarta de sus respectivas tablas, se observa que en el caso de los pacientes el fenómeno de la desincronización que acompaña a la realización de un movimiento voluntario tiene una duración menor. No obstante, ambos grupos corroboran la característica temporal del fenómeno fisiológico ERD considerado, es decir, que la duración de la caída de potencial previa al movimiento en las bandas de frecuencia bajo estudio un período de tiempo está en un promedio de 2s. Por otra parte, la duración media de las UAs falsas en controles (0.81s) y en pacientes (0.83s) es inferior a la de las UAs verdaderas, lo que indica que la longitud temporal de la activación también puede ser un indicativo de la detección de un movimiento real. También se observa, en la fila quinta de ambas tablas, que el valor medio del tiempo de anticipación en los pacientes ( $0.32\pm 0.14s$ ) es inferior al de los controles ( $1.01\pm 0.21s$ ), confirmándose que en los pacientes con temblor el comienzo de la desincronización se retrasa en el tiempo con respecto al inicio del movimiento.

## 5. DISCUSIÓN

La primera enseñanza extraída de este trabajo es la necesidad de establecer los parámetros óptimos de la señal EEG de forma personalizada. Construir ICCs que empleen parámetros típicos (electrodos, bandas de frecuencia, ventanas temporales), extraídos de la señal de un grupo de sujetos realizando una tarea, condena a la frustración de los sujetos atípicos cuando usan la misma y, por ende, la obtención de clasificadores con elevadas tasas de error. Para evitarlo, es necesario realizar un gran esfuerzo de experimentación, probando con diferentes protocolos y tareas. Pero también es esencial disponer de una metodología de análisis aplicable en la medida de lo posible a la mayoría de los sujetos.

El potencial de la minería de datos es enorme en este sentido. El objetivo del proceso DM es caracterizar los estados de la actividad mental contenida en la señal buscando patrones que permitan discriminar entre estados. En este trabajo, la actividad mental de interés se ha representado de acuerdo a los parámetros que caracterizan los ritmos sensorimotrices, es decir, el proceso de DM ha estado conducido por el fenómeno ERD. Otro estudio podría haberse centrado sólo en la potencia PSD sin combinar con la variación de la potencia  $\Delta PSD$  o en otro tipo de parámetros extraídos de la señal. Para solventar situaciones en las que no es posible detectar los ritmos sensorimotrices en los sujetos se puede ampliar la metodología de selección de características a más electrodos fuera de esta área cortical.

La experimentación llevada a cabo para el paradigma de este trabajo, el de controlar una neuroprótesis de miembro superior utilizando dispositivos de estimulación eléctrica funcional con el objeto de eliminar o cancelar el movimiento tembloroso de pacientes cuando realizan un movimiento voluntario en actividades de la vida diaria, ha servido también para comprobar que existen sujetos en los que resulta extremadamente difícil detectar ritmos sensorimotores.

Uno de los objetivos perseguidos con este paradigma es la integración multimodal de datos e información procedentes de distintas fuentes. En lo que respecta a la ICC, esta integración tiene lugar cuando la ICC dispone del instante de tiempo en el que tiene lugar el movimiento real y su duración gracias a la señal procedente de los sensores inerciales. Esta información permite crear, en la primera fase, el modelo informativo de los datos registrados para cada sujeto en las ventanas de tiempo adecuadas y, usando este modelo y el algoritmo clasificador, crear el modelo predictivo. En la segunda fase, en la que ya se dispone del clasificador del sujeto y debe tener lugar la clasificación continua de la señal, la información suministrada por los sensores inerciales permitirá adaptar el comportamiento del clasificador gradualmente al usuario a partir de los aciertos y/o errores identificados entre la predicción de movimiento y la detección real o no del mismo.

La otra vía de integración la proporciona la comunicación anticipada que hace el clasificador de un movimiento voluntario cuando identifica la intención en la señal, es decir, cuando clasifica la señal que analiza en la clase "premovimiento". La anticipación simboliza una señal de alerta al sistema de cancelación del temblor porque esta cancelación realmente sólo puede tener lugar cuando otros sensores, como los inerciales o la señal EMG, detectan realmente el movimiento del miembro del sujeto ya que justo ese es el momento en el que es posible calcular la componente temblorosa del movimiento para cancelarla (Rocón *et al.*, 2010). En el trabajo expuesto se consideró suficiente fijar la anticipación a 0,5s antes del movimiento.

Por esta razón es por lo que se impone al clasificador una mayor restricción para la predicción correcta y anticipada de la intención de movimiento, es decir, un valor alto de  $R_c$ , persiguiendo que el sujeto pueda realizar los movimientos voluntarios libre de temblor y, sin embargo, la generación de falsos positivos no es tan restrictiva. Los falsos positivos producen falsas alarmas que se comunican al sistema de cancelación del temblor pero si este sistema no recibe información de las otras vías que detectan el movimiento real del sujeto, el sistema no actúa sobre el mismo. De esta manera, el valor de la medida  $P_r$  no es tan crítico aunque es deseable también sea el mínimo posible. En los experimentos realizados, se han realizado diversas pruebas modificando el umbral de detección de la clase "premovimiento" que permitían mejorar el valor de  $P_r$ , manteniendo el valor de  $R_c$ . Sin embargo, esta mejora va en detrimento de la capacidad de anticipación del clasificador, esto es, la detección del premovimiento se retrasa en el tiempo.

En cualquier caso, tras un análisis detallado de los valores que toman las características de la señal en todos los sujetos y de forma más evidente en los pacientes, los falsos positivos detectados para ellos, en torno al 6.6% en media, son consecuencia de que la señal en el período de reposo presenta el

mismo fenómeno que en el período de premovimiento, es decir, que en reposo se producen intervalos de desincronización. Esto quizá pueda deberse a que la tarea o el protocolo usados provoquen en los sujetos dicho fenómeno.

El número de sujetos analizados, en concreto, los pacientes con temblor, aunque puede parecer limitado, está dentro de los márgenes con los que se opera en este tipo de experimentos. En los trabajos mencionados en el apartado 2 llevados a cabo con pacientes (Müller *et al.*, 2005; Wolpaw and McFarland, 2004) el número máximo empleado es de cuatro. Resulta complicado el acceso a los pacientes, incluso en el marco de proyectos que persiguen una aplicación para los mismos, a lo que se une el hecho de que, a pesar de que los pacientes muestren una buena disposición para los experimentos, algunos son descartados porque no se involucran en la tarea o no prestan atención y no es posible detectar sus ritmos motores ni siquiera durante el movimiento.

## 6. CONCLUSIÓN

Se ha presentado un método para seleccionar de forma continua y asíncrona las características del estado previo al movimiento de la señal EEG de un sujeto. A partir de ellas, se construye un clasificador cuya salida permite controlar un dispositivo neuroprotésico adaptándose a sus características personales y a sus circunstancias en el tiempo.

En los dos experimentos realizados se han obtenido unos buenos valores de las medidas  $R_c$  de predicción del premovimiento. Para obtener una visión más comprensible de la otra medida de efectividad,  $P_r$ , se ha calculado una medida de los falsos positivos acorde con el tipo de tarea y el protocolo llevados a cabo que refleja de forma más realista la relación entre los períodos de reposo de los sujetos y los períodos de movimiento.

La capacidad de adaptación del algoritmo predictivo ha quedado constatada con las pruebas realizadas para cada paciente en la simulación asíncrona y en diversas clasificaciones asíncronas que han tenido lugar en diferentes sesiones para un mismo paciente.

Se han abierto, a raíz de la investigación en esta línea, varias vías de trabajo futuro. Una de ellas es el estudio del número de ensayos suficientes para la construcción de un clasificador eficaz que en una sola sesión pueda obtener el modelo informativo y el modelo predictivo de los movimientos de un sujeto. Se ha constatado que, en media, las primeras dos tandas de ensayos son suficientes para construir un modelo predictivo del sujeto con una tasa de aciertos óptima. A medida que la clasificación tenga lugar y, simultáneamente, el clasificador disponga de la realimentación dada por los sensores inerciales se podrá ir actualizando el modelo informativo con los nuevos datos y, en consecuencia, el modelo predictivo. También se considera de interés analizar el papel de las diferentes características empleadas por el clasificador o concebir un clasificador de un nivel superior que discrimine entre falsos y verdaderos positivos. Otra de las vías a medio plazo es evaluar el potencial predictivo de la combinación de técnicas de filtrado espacial con otras técnicas de filtrado temporal diferentes a PSD así como la combinación con otros métodos de aprendizaje inductivo.

## AGRADECIMIENTOS

Este trabajo ha sido realizado con la financiación de la Comisión de la Unión Europea dentro del 7 Programa Marco, para el proyecto con referencia ICT-2007-224051: “TREMOR: An ambulatory BCI-driven tremor suppression system based on functional electrical stimulation” y por el Ministerio de Ciencia e Innovación, con el proyecto IMAGENeuroMAPS (TEC2006-13966-C03-03) “Integración de resonancia magnética y electroencefalografía. Aplicación al fundamento y uso de ICCs por discapacitados”.

#### REFERENCIAS

- Bai O., Lin P., Vorbach S., Li J., Furlani S. and Hallet M. (2007). Exploration of computational methods for classification of movement intention during human voluntary movement from single trial EEG. *Clinical Neurophysiology*, **118**, 2637-2655.
- Bashashati A., Fatourech M. and Ward R.K. (2007). A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals. *J. Neural Engineering*, **4**, 32-57.
- Daly J.J. and Wolpaw J.R. (2008). Brain-computer interfaces in neurological rehabilitation. *The Lancet Neurology*, **7(11)**, 1032-1043.
- Domingos, P. and Pazzani, M. (1996). Beyond independence: conditions for the optimality of the simple Bayesian classifier. *Proc. 13<sup>th</sup> International Conference on Machine Learning*, 105-112.
- Donchin E., Spencer K.M. and Wijensighe R. (2000). The mental prosthesis: assessing the speed of a P300-based brain-computer interface. *IEEE Transactions on Rehabilitation Engineering*, **8**, 174-179.
- Donoghue J.P. (2002). Connecting cortex to machines: recent advances in brain interfaces. *Natural Neuroscience*, **5**, 1085-1088.
- Drongelen, W.v. (2007). *Signal processing for neuroscientists, an introduction to the analysis of physiological signals*. Elsevier.
- Farina D., do Nascimento O.F., Lucas M.F. and Doncarli C. (2007). Optimization of wavelets for classification of movement-related cortical potentials generated by variation of force-related parameters. *J. Neuroscience Methods*, **162**, 367-363.
- Farwell L.A. and Donchin E. (1988). Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials. *Electroencephalography and Clinical Neurophysiology*, **70**, 510-523.
- Fazli S., Popescu F., Danóczy M., Blankertz B., Müller K.R. and Grozea C. (2009). Subject-independent mental state classification in single trials. *Neural Networks*, **22**, 1305-1312.
- Fayyad U.M., Piatetsky-Shapiro G. and Smyth P. (1996). The KDD process for extracting useful knowledge from volumes of data. *Communications of the ACM*, **39(11)**, 27-34.
- Flexer A. and Bauer H. (2000). Monitoring human information processing via intelligent data analysis of EEG recordings. *Intelligent Data Analysis*, **4(2)**, 113-128.
- Goldberg D. (1989). *Genetic algorithms in search, optimization and machine learning*. Addison Wesley.
- Grainmann B., Huggins J.E., Levine S.P. and Pfurtscheller G. (2002). Visualization of significant ERD/ERS patterns in multichannel EEG and ECoG data. *Clinical Neurophysiology*, **113**, 43-47.
- Gu Y., Dremstrup K. and Farina D. (2009). Single-trial discrimination of type and speed of wrist movements from EEG recordings. *Clinical Neurophysiology*, **120**, 1596-1600.
- Isa T., Fetz E.E. and Müller K.R. (2009). Recent advances in brain-machine interfaces. *Neural Networks*, **22**, 1201-1202.
- Kubler A., Kotchoubey B., Kaiser J., Wolpaw J.R. and Birbaumer N. (2000). Brain computer communication: unlocked the locked. *Psychology Bulletin*, **127(3)**, 358-375.
- Kutas M., and Hillyard, S.A. (1984). Brain potentials during reading reflect word expectancy and semantic association. *Nature*, **307**, 161-163.
- Mason S.G. and Birch G.E. (2000). A brain controlled switch for asynchronous control applications. *IEEE Transactions on Biomedical Engineering*, **47**, 1297-1307.
- Millán J., Mouriño R., Cincotti F., Babiloni F., Varsta M. and Heikkonen J. (2000). Local neural classifier for EEG-based recognition of mental tasks. *Proc. IEEE International Joint Conference on Neural Networks*, 632-636.
- Mitchell, T.M. (1997). *Machine learning*. McGraw-Hill.
- Müller G.R., Scherer R., Pfurtscheller G. and Rupp R. (2005). EEG-based neuroprosthesis control: a step towards clinical practice. *Neuroscience Letters*, **382**, 169-174.
- Pfurtscheller G. (1977). Graphical display and statistical evaluation of event-related desynchronization (ERD). *Electroencephalography and Clinical Neurophysiology*, **43**, 757-760.
- Pfurtscheller G. and Aranibar A. (1979). Evaluation of event-related desynchronization (ERD) preceding and following voluntary self-paced movements. *Electroencephalography and Clinical Neurophysiology*, **46**, 138-146.
- Pfurtscheller G. (1992). Event-related synchronization (ERS): an electrophysiological correlate of cortical areas at rest. *Electroencephalography and Clinical Neurophysiology*, **83**, 62-69.
- Pfurtscheller G., Sager G. and Wege W. (1981). Correlations between CT scan and sensorimotor EEG rhythms in patients with cerebral vascular disorders. *Electroencephalography and Clinical Neurophysiology*, **52**, 473-485.
- Pfurtscheller G., Neuper C., Guger C., Harkam W., Ramoser H., Schlogl A., Obermaier B. and Pregenzer M. (2000). Current trends in Graz brain-computer interface (BCI) research. *IEEE Transactions on Rehabilitation Engineering*, **8**, 216-219.
- Pfurtscheller G. and Neuper C. (1994). Event-related desynchronization of mu rhythm in the EEG over the cortical hand area in man. *Neuroscience Letters*, **174**, 93-96.
- Pfurtscheller G. and Lopes da Silva F.H. (1999). Event-related EEG/EMG synchronization and desynchronization: basic principles. *Clinical Neurophysiology*, **110**, 1842-1857.
- Pfurtscheller G., Brunner C., Schlögl A. and da Silva F.H. (2006). Mu rhythm (de)synchronization and EEG single-trial classification of different motor imagery tasks. *Neuroimage*, **31**, 153-159.
- Rocón E., Gallego J. A., Barrios L., Victoria A. R., Ibáñez J., Farina D., Negro F., Dideriksen J. L., Conforto S., D'Alessio T., Severini G., Belda-Lois J. M., Popovic L. Z., Grimaldi G., Manto M. and Pons J. L. (2010). Multimodal BCI-mediated FES suppression of pathological tremor. *Proc. 32nd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 3337-3340.

- Sannelli C., Braun M. and Müller K.R. (2009). Improving BCI performance by task-related trial pruning. *Neural Networks*, **22**, 1295-1304.
- Serrano J.I., del Castillo M.D. (2005). BCI Competition III. <http://www.bbci.de/competition/iii/results/index.html>
- Townsend G., Grainmann B. and Pfurtscheller G. (2004). Continuous EEG classification during motor imagery-simulation of an asynchronous BCI. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, **12(2)**, 258-265.
- Townsend G., Grainmann B. and Pfurtscheller G. (2006). A comparison of common spatial patterns with complex band power features in a four-class BCI experiment. *IEEE Transactions on Biomedical Engineering*, **53**, 642-651.
- Wang Y., Zhang Z., Li Y., Gao X., Gao S and Yang F. (2004). BCI competition 2003-Data set IV: an algorithm based on CSSD and FDA for classifying single trial EEG. *IEEE Transactions on Biomedical Engineering*, **51**, 1081-1086.
- Wolpaw J.R., Birbaumer M., Heetderks W.J., McFarland D.J., Peckham P.H., Schalk G., Donchin E., Quatrano L.A., Robinson J. and Vaughan T.M. (2000). Brain-computer interface technology: a review of the first international Meeting. *IEEE Transactions on Rehabilitation Engineering*, **8(2)**, 164-173.
- Wolpaw J.R., Birbaumer M., McFarland D.J., Pfurtscheller G. and Vaughan T.M. (2002). Brain computer interfaces for communication and control. *Clinical Neurophysiology*, **113**, 767-791.
- Wolpaw J.R. and McFarland D.J. (2004). Control of a two dimensional movement signal by a noninvasive brain-computer interface in humans. *Proc. National Academy of Sciences*, **101(51)**, 17849-17854.
- Yang J. and Honavar V. (1998). Feature subset selection using a genetic algorithm. *IEEE Intelligent Systems and their Applications*. **13(2)**, 44-49.
- Yom-Tov E. and Inbar G.F. (2003). Detection of movement-related potentials from the electro-encephalogram for possible use in a brain-computer interface. *Medical & Biological Engineering & Computing*, **41**, 85-93.