

Nuevo Enfoque para la Clasificación de Señales EEG usando la Varianza de la Diferencia entre las Clases de un Clasificador Bayesiano

Thomaz R. Botelho^{a,b,*}, Douglas Soprani^b, Camila Rodrigues^a, André Ferreira^a, Anselmo Frizzera^a

^aPrograma de Posgrado em Engenharia Elétrica, Universidade Federal de Espírito Santo (UFES), Av. Fernando Ferrari, 514, Vitória-ES, Brasil.

^bDepartamento de Electrotecnología, Instituto Federal de Educación, Ciencia y Tecnología de Espírito Santo (IFES), BR 101 Av. Norte, 58, São Mateus - ES, Brasil.

Resumen

Los avances en robótica de rehabilitación están beneficiando en gran medida a los pacientes con discapacidad física. Los dispositivos de asistencia y rehabilitación pueden basar su funcionamiento en información fisiológica de los músculos y del cerebro a través de electromiografía (EMG) y electroencefalografía (EEG), para detectar la intención de movimiento de los usuarios. En este trabajo se presenta una propuesta de interfaz multimodal para la adquisición, sincronización y procesamiento de señales EEG y de sensores inerciales, para ser aplicada en tareas de rehabilitación con exoesqueletos robóticos. Se realizaron experimentos con individuos sanos con el objetivo de analizar la intención de movimiento, la activación muscular e inicio de movimiento durante los movimientos de extensión de la rodilla. Esta propuesta es un nuevo enfoque para la clasificación de señales EEG usando un clasificador bayesiano tomando en cuenta la varianza de la diferencia entre las clases usadas. El aporte de este trabajo se sustenta con los resultados que muestran un incremento del 30 % en la precisión de clasificación con señales EEG en comparación con los enfoques tradicionales de clasificación, en un análisis off-line para el reconocimiento de la intención de movimiento de los miembros inferiores.

Palabras Clave:

Interfaz hombre-máquina, Análisis de señales, Sistemas biomédicos, Unidades de medición inercial, Cerebro humano, Movimiento.

1. Introducción

Con base a los informes de la Organización Mundial de la Salud (OMS), se espera que la población mundial con una edad superior a los 60 años se duplique en porcentaje entre el año 2000 y 2050, pasando del 11 % (aproximadamente 605 millones) al 22 % (aproximadamente 2 mil millones)¹. Además, se estima un aumento significativo en la comunidad de ancianos con edades superiores a los 80 años, cuadruplicando en número (de aproximadamente 100 a 395 millones de personas) en el mismo intervalo de tiempo (entre 2000 y 2050).

La disminución en la activación muscular voluntaria implica importantes modificaciones en la composición corporal y en la función motora (Arnold and Bautmans, 2014). El mantenimiento de la actividad motora y de la movilidad durante el en-

vejecimiento es crucial para la conservación de la salud y de las funciones cognitivas (Volkers et al., 2012).

En adición a estos datos, el número de personas con deficiencias en los miembros inferiores debido a accidentes cerebrovasculares o por lesión medular se está incrementando en los últimos años (Tsukahara et al., 2009).

De acuerdo a la OMS, cada año, cerca de 15 millones de personas sufren un accidente cerebro vascular en el mundo (Mackay and Mensah, 2004). Los sobrevivientes frecuentemente presentan discapacidad crónica, incluyendo pérdida de las funciones sensorial, motora y cognitiva.

La rehabilitación motora y la asistencia a la movilidad son también requisitos importantes en pacientes que han tenido un accidente cerebro vascular y en personas en periodos de recuperación de lesiones medulares incompletas. A nivel global, por año, cerca de 15 millones de personas sufren un accidente cerebro vascular por primera vez, de los cuales, aproximadamente 5 millones enfrentan variados grados de dificultad de movilidad, generando un impacto negativo en su capacidad para realizar tareas de la vida diaria (Strong et al., 2007).

* Autor en correspondencia.

Correo electrónico: thomazrb@ifes.edu.br (Thomaz R. Botelho)

URL: www.ifes.edu.br (Thomaz R. Botelho)

¹World Health Organization, 2014, *Facts about ageing*, <http://www.who.int/ageing/about/facts/en/>

Los accidentes son la causa más común de lesiones de médula espinal, de los cuales, aproximadamente, el 51 % son incompletas. En estos casos, no siempre existe pérdida total de las funciones sensorial y motora en los miembros inferiores de los pacientes. Sin embargo, estos individuos necesitan rehabilitación y posteriormente, asistencia para volver a caminar.

Por lo tanto, es necesario una rehabilitación efectiva que haga énfasis en la repetición, en el incremento progresivo de la dificultad de la tarea y en la práctica funcional (Husemann et al., 2007; Winstein et al., 2016). Además, los sujetos que han sufrido un accidente cerebro vascular tienden a obtener mejores resultados con un entrenamiento mecánico asistido comparado con un entrenamiento de rehabilitación clásica (Ada et al., 2010).

Para recuperar las funciones de los miembros inferiores se emplean diferentes programas de rehabilitación. Generalmente, la rehabilitación se basa en la experiencia y en las habilidades del fisioterapeuta. Sin embargo, debido al gran número de pacientes y al tiempo que debe invertirse en las terapias, el hecho de contar con un robot para asistir en el tratamiento representa un gran avance (Ju et al., 2005). Varios controladores digitales pueden proyectarse para el control de un robot para rehabilitación basado en la predicción del movimiento. Este enfoque es importante porque permite reducir el impacto que la adaptación a la tecnología asistiva puede causar al paciente (Ibáñez et al., 2013). La intención de movimiento puede ser detectada antes del desplazamiento físico de la extremidad mediante el análisis de señales de electroencefalografía (EEG) (Shibasaki and Hallett, 2006; Lu et al., 2010; Mrachacz-Kersting et al., 2012; Kirchner et al., 2014).

La predicción del movimiento a través de señales EEG usando interfaces cerebro-computador (BCI por sus siglas en inglés) puede mejorar el control de las acciones de dispositivos robóticos de rehabilitación (Kirchner et al., 2014), permitiendo que los movimientos sean ejecutados de manera más natural.

Las BCI han sido implementadas a partir de la adquisición no-invasiva de señales EEG, para analizar los eventos relacionados al ritmo sensorio-motor (SMR por sus siglas en inglés), como las características relacionadas a la desincronización y a la sincronización (Event Related Desynchronization and Synchronization ERD/ERS) (Kirchner et al., 2014; Gallego et al., 2012) o los potenciales corticales relacionados con el movimiento lento (MRCPs por sus siglas en inglés) (Jiang et al., 2015; Mrachacz-Kersting et al., 2017). La primera técnica presenta un mejor rendimiento en la detección del movimiento, sin embargo, con una precisión baja cuando se trabaja con miembros inferiores. Como resultado de este hecho, el uso de MRCP supera a SMR en términos de precisión en el control de dispositivos (Xu et al., 2016).

Con el objetivo de aprovechar la anticipación en la detección del movimiento con SMR y la precisión de detección compatible a los MRCPs, este trabajo propone un nuevo enfoque para detectar la intención de movimiento. La contribución está basada en la clasificación de señales provenientes de SMR utilizando un clasificador bayesiano con dos clases: movimiento y no-movimiento (Ibáñez et al., 2013). Esto seguido de un clasificador de umbral, alimentado con la variancia de la diferencia

entre las clases del clasificador bayesiano, para la anticipación en la detección del movimiento, apuntando a un incremento en la precisión en aplicaciones *on-line*.

Este artículo está organizado de la siguiente manera. En la Sección 2, se encuentra la descripción de los participantes del estudio, del equipo y del protocolo experimental empleado. En la Sección 3 se describen las etapas del procesamiento aplicado a la señal EEG. Finalmente, los resultados del procesamiento se presentan en la Sección 4 y la discusión y conclusiones se realizan en las Secciones 5 y 6, respectivamente.

2. Métodos

2.1. Participantes

Diez sujetos sanos (9 mujeres, 1 hombre; lado dominante derecho; $21,17 \pm 1,7$ años), participaron voluntariamente en este estudio. Este grupo fue escogido aleatoriamente de un grupo de voluntarios homogéneo en términos de género entre las edades de 18 a 25 años. Los criterios de exclusión fueron estar por fuera de este rango de edad y personas con problemas motores. Este estudio fue aprobado por el Comité Ético de Investigación con seres humanos de la UNESA, CAAE número 51685515.3.0000.5284, informe de evaluación número 1.863.539.

2.2. Materiales

El equipo empleado para la adquisición de las señales EEG fue el BrainNet[®] BNT-36 (Lynx Eletrônica, Brasil). Las señales fueron adquiridas usando un protocolo para la colocación de electrodos basado en el estándar internacional 10-20 con referencias biauriculares y una referencia de tierra localizada en la frente. Las posiciones fueron: *Fp1*, *Fp2*, *F7*, *F3*, *Fz*, *F4*, *F8*, *C3*, *Cz*, *C4* y *Pz*.

Se empleó también un sistema de sensores inerciales Tech MCS[®] (Technaid S. L., España). Este sistema proporciona una orientación espacial de los sensores en tiempo real. En los experimentos se emplearon dos sensores, uno colocado en el muslo y otro sobre la pantorrilla del sujeto. El uso de sensores inerciales o unidades de medición inercial (IMUs por sus siglas en inglés) permite validar el inicio del movimiento sin la necesidad de ambientes estructurados.




Figura 1: Diagrama de bloques del sistema.

Fueron desarrollados dos programas, uno para la adquisición y sincronía de los datos provenientes de los dos sistemas y otro programa para el procesamiento *off-line* de los datos adquiridos. La frecuencia de muestreo del BrainNet[®] BNT-36 fue

de 600Hz, que es el valor más alto que proporciona el equipo. La frecuencia de muestreo del sistema de sensores inerciales fue de 50Hz, que es compatible con el movimiento de la pierna durante los experimentos. Se considera que los movimientos naturales de las extremidades inferiores tienen componentes de frecuencia por debajo de 5Hz (Yang and Kong, 2009). La figura 1 muestra un diagrama de bloques del sistema desarrollado.

2.3. Protocolo experimental

Cada experimento constó de 30 repeticiones del movimiento de flexión-extensión de la rodilla y cada repetición duró 30 segundos. Durante todas las sesiones, los sujetos estuvieron sentados confortablemente, con las manos relajadas y los pies sin tocar el piso. Se pidió al voluntario realizar el movimiento de rodilla normalmente, manteniendo los ojos abiertos, evitando parpadear y hablar.

Las señales de las IMUs fueron usadas para detectar el inicio del movimiento, es decir, el inicio de una extensión de rodilla en cada ensayo realizado durante los experimentos. El protocolo de colocación de los sensores inerciales no requiere de una ubicación específica o de alineación de los mismos. La alineación entre los sensores se realiza de manera virtual en la etapa de procesamiento (Botelho et al., 2015).

Las señales EEG fueron usadas para estimar la intención de movimiento del sujeto, es decir, para detectar un intervalo durante el cual el sujeto intente iniciar la extensión de la rodilla a pesar de que el movimiento no se haya realizado de manera efectiva. Se emplearon las características de los eventos relacionados a la desincronización y a la sincronización (ERD/ERS), descritas por Pfurtscheller and Da Silva (1999).




Figura 2: Representación de un ensayo del experimento.

La figura 2 muestra una representación de un ensayo del experimento (30 segundos) que inicia después de una señal acústica. El sujeto realiza el movimiento voluntariamente después de una segunda señal acústica (10 segundos después de la primera). La línea base (entre el segundo 5 y 8) es un período en que el sujeto no se mueve y no tiene la intención de moverse. Los datos de las señales en la línea base se usan en la comparación con datos mientras el sujeto se mueve o tiene intención de moverse. En los clasificadores, la diferencia intrínseca entre tales momentos proporciona patrones para la diferenciación de las señales.

3. Procesamiento de datos

3.1. Evaluación del movimiento

Las señales de las IMUs fueron analizadas con un clasificador de umbral basado en el promedio y la desviación estándar

en el momento en el que no hay movimiento (línea base). Un clasificador de umbral evalúa el desplazamiento, basado en el ángulo de extensión de la rodilla. Por lo tanto, se evaluó la detección del inicio del movimiento. La ecuación (1) describe el clasificador de umbral.

$$T_N(\Delta t) = m_N(\Delta t) + p \cdot d_N(\Delta t) \quad (1)$$

En la ecuación (1), T es el umbral, m es la media, d es la desviación estándar y p es un peso dado a la desviación estándar del clasificador entre la región de ruido y el incremento de la señal real. N es el número de muestras usadas en una ventana para calcular el promedio y la desviación estándar, Δt es el intervalo de tiempo correspondiente a N muestras. Los parámetros p y N fueron escogidos a través de una etapa de selección de parámetros. El objetivo de esta selección fue encontrar la señal de movimiento que después de 10 segundos estuviera en la mayor cantidad de repeticiones. De esta manera se garantizó que los parámetros de los clasificadores estuvieran bien ajustados a la señal analizada. En la etapa de selección, el parámetro p varió de 1 a 10 y el parámetro N varió de 5 a 50, en los dos casos con incrementos de 1. Además de los parámetros p y N , se utilizó un período refractario para que el clasificador pueda clasificar el inicio del movimiento, variando de 10 a 200 muestras, con un incremento de 5. Las muestras clasificadas correctamente en secuencia fueron consideradas como un positivo. Esta técnica permitió que los falsos positivos sean reducidos en la selección de los parámetros del clasificador. El inicio de la clasificación de movimiento se refiere a la primera muestra de las ventanas que estén por encima del umbral.

3.2. Detección de la intención de movimiento

El procesamiento completo de las señales EEG consta de dos etapas. La primera es el pre-procesamiento de la señal y la segunda es la clasificación de la señal, la cual incluye el entrenamiento del clasificador. El pre-procesamiento implica la eliminación de artefactos de la señal, un filtrado espacial, un proceso de separación de fuentes lineales y un filtrado en la banda en la cual se desean observar las características deseadas (ERD/ERS). En la etapa de clasificación se propone un método que usa un clasificador bayesiano combinado con un clasificador de umbral para detectar la intención de movimiento. Este clasificador se explica a detalle en la Sección 3.2.2. En la figura 3 se muestra el diagrama de bloques del proceso para la detección de la intención de movimiento en donde se incluyen las etapas de pre-procesamiento y procesamiento de la señal EEG.

3.2.1. Pre-procesamiento de la señal EEG

Se realizó un filtrado con un filtro espacial de referencia de media común (CAR por sus siglas en inglés). Esta técnica está basada en el hecho de que las señales fuera del cerebro afectan a todos los electrodos EEG de la misma manera, debido a la gran distancia que existe entre la fuente de ruido y los electrodos colocados en la cabeza (Bertrand et al., 1985). En este procesamiento se obtiene la media entre todos los canales de EEG analizados y este valor es restado del valor de la señal de

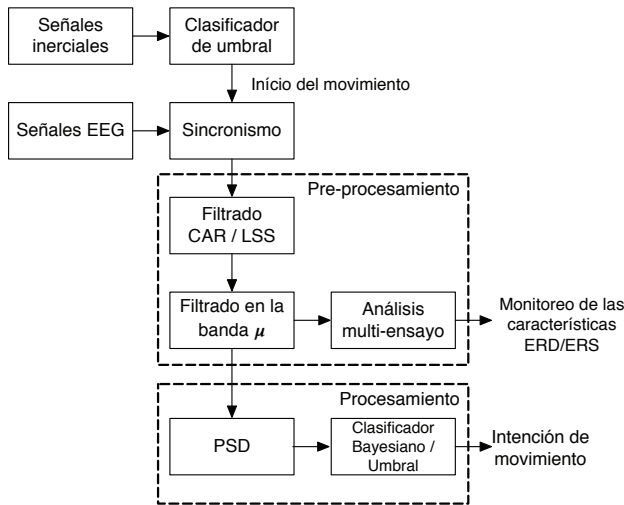


Figura 3: Pre-procesamiento y procesamiento de las señales de EEG.

cada canal, alterando el valor de la señal en cada canal, pero sin alterar la referencia inicial de los canales.

La señal resultante pasa por un proceso de separación lineal de fuente (LSS por sus siglas en inglés). Este enfoque modela las fuentes cerebrales como dipolos eléctricos perpendiculares a la superficie (Benevides et al., 2008).

La siguiente y última etapa de pre-procesamiento se ocupa del filtrado de la frecuencia en la banda μ ($8 - 12\text{Hz}$) (Cheng et al., 2004), en donde las características ERD relacionadas con la intención de movimiento ocurren predominantemente (Pfurtscheller and Da Silva, 1999).

Este método consiste en elevar las señales al cuadrado obteniendo las muestras de energía. Se calcula la media de la energía de todas las épocas y la curva es suavizada a través del cálculo de la media de los puntos en un pequeño intervalo de tiempo. Para obtener el porcentaje de ERD/ERS, se calcula la energía en la banda de frecuencia de interés A (banda μ) y la energía media de un periodo de referencia anterior al evento R (línea base). El ERD y ERS se definen como porcentajes de incremento o decremento respectivamente, de acuerdo a la ecuación (2) propuesta por Pfurtscheller and Da Silva (1999). Las señales, en esta etapa, fueron filtradas con filtros Butterworth de 4^{to} orden, tal como propuso Ibáñez et al. (2013).

$$ERD(\%) = \frac{(A - R)}{R \times 100} \quad (2)$$

3.2.2. Detección de la Intención de Movimiento usando un ensayo simple

Este trabajo utilizó un clasificador bayesiano alimentado por los valores de densidad espectral de potencia (PSD por sus siglas en inglés) de las señales EEG en la banda μ , con el fin de detectar el inicio de la intención de movimiento (Ibáñez et al., 2013). Se emplearon dos clases: la clase *movimiento* y la clase *estática*. La primera, está relacionada a los instantes de la intención de movimiento y al movimiento efectivo. Se considera movimiento a todo intervalo de la tarea, en la que el usuario

realiza la extensión de la pierna y posteriormente la flexión. La segunda clase, está relacionada a los instantes en los que el sujeto no se mueve y no tiene intención de hacerlo.

Las características escogidas para definir las clases mencionadas son los valores PSD en los canales $C4$, $C3$ y Cz en frecuencias específicas en la banda μ , con una resolución de $0,125\text{Hz}$ por muestra. Estas características generan funciones que se llaman discriminantes de las clases del clasificador. Los canales $C4$, $C3$ y Cz fueron seleccionados porque están directamente relacionados con las áreas motoras de la corteza cerebral, y son los electrodos en los que el evento relacionado con la intención de movimiento (ERD) podría ser claramente observado.

La selección de las frecuencias se realizó en el entrenamiento a partir de la mayor diferencia entre los discriminantes referentes a las clases: *movimiento* (m) y *estática* (e). Esta diferencia es calculada como una resta de la media de PSD en la banda μ entre un instante y otro, o sea, para la clase *estática* y para la clase *movimiento*, como se describe en la ecuación (3).

$$D(f_i) = \max(\text{Avg}_{j,f_k}(PSD(f_i)_e) - \text{Avg}_{j,f_k}(PSD(f_i)_m)) \quad (3)$$

En la ecuación (3), $D(f_i)$ es el mayor valor, representado por el operador \max , de la diferencia del promedio de los valores PSD entre las j ventanas (considerando los valores promedio para las frecuencias correspondientes f_k) de las clases e y m , variando las f_i frecuencias del espectro dentro de la banda μ . Para el cálculo de la diferencia entre los discriminantes se utilizaron ventanas de 100 muestras superpuestas, con un desfase de 1 a 1 muestra entre las ventanas.

Las frecuencias que representan las mayores diferencias de los valores de densidad de potencia espectral fueron las que se consideraron en el entrenamiento, y el valor PSD de estas frecuencias se utilizó en la clasificación.

La señal EEG se analizó en el intervalo de $5 - 20\text{s}$ durante cada ensayo del experimento una vez que el tiempo de movimiento depende del sujeto.

Los dos segundos iniciales fueron descartados debido a que es el periodo de estabilización de la señal y no debe ser considerado. A parte de eso, fueron detectados los segundos iniciales y finales que varían entre las repeticiones y dependen del tiempo de cada movimiento. Estos fueron descartados con el fin de sincronizar el inicio del movimiento entre las repeticiones como se indica en la figura 4. Las señales, a través de las funciones discriminantes del clasificador, son clasificadas de acuerdo a la regla de máxima similitud. Se observó que la varianza de la diferencia entre los discriminantes de la clase *estática* y la clase *movimiento* es más estable y proporciona una clasificación más precisa que sólo la diferencia entre los discriminantes. Esto ocurre porque la clasificación es para la clase con mayor discriminante. La varianza suaviza la diferencia entre discriminantes, dando lugar a una señal más estable. Esto también permite que el sistema se adapte para agregar otro análisis individual en la característica de la señal. Esta operación está descrita en la ecuación (4).

$$\text{VarDif}(i) = \text{var}(g_{c_m}(\bar{x}_j) - g_{c_e}(\bar{x}_j)) \quad (4)$$

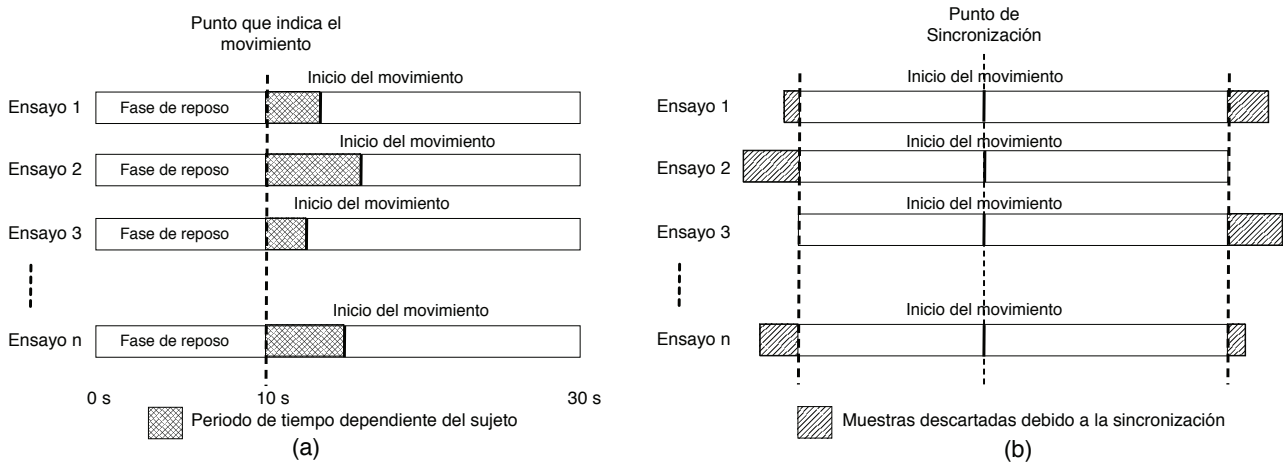


Figura 4: Sincronismo de los ensayos con base a la detección del inicio del movimiento. (a) Ensayos antes del sincronismo; (b) Ensayos después del sincronismo.

$VarDif(i)$ representa la varianza de la diferencia de las funciones discriminantes del clasificador bayesiano $g_{c_m}(\bar{x}_j)$ y $g_{c_c}(\bar{x}_j)$ en cada ventana. Como se mencionó anteriormente, se utilizaron ventanas de 100 muestras con un desfase de 1 a 1 muestra entre las ventanas. El término *var* representa la aplicación de la varianza al argumento entre paréntesis, es decir, la diferencia entre los discriminantes. La clasificación implica el análisis de la varianza y también el del mayor valor del discriminante de la clase seleccionada. Por lo tanto, se utiliza un clasificador de umbral, basado en los valores promedio y de desviación estándar de la señal resultante obtenida de la ecuación (4), en la línea base, para determinar la relevancia entre las clases. El clasificador de umbral utilizado en esta etapa es análogo al utilizado con las señales de las IMUs (Equação (1)). Para esta señal, el parámetro p varió de 0.1 a 1 con incrementos de 0.1. El parámetro N varió de 5 a 20 con un incremento de 1 y el periodo refractario que varió de 2 a 20 muestras con incrementos de 1, clasificados correctamente en secuencia para considerar un positivo. El inicio de la clasificación de movimiento se refiere a la primera muestra de las ventanas que estén por encima del umbral.

El entrenamiento y la clasificación de la señal EEG se realizaron mediante el procedimiento de validación cruzada utilizando el método *dejando-uno-fuera* (*leave-one-out*).

La señal de EEG puede sufrir variaciones entre sujetos por las diferencias en la conductividad de la piel y el cabello debido a oleosidad, temperatura y biotipo del sujeto (Latikka et al., 2001). Por esta razón, se realizó el entrenamiento del clasificador con algunas repeticiones del mismo sujeto en lugar de dividir los sujetos en un grupo para el entrenamiento y otro grupo para la clasificación de la señal.

De esta manera, para clasificar las señales EEG, es necesario dividir los ensayos de cada sujeto en 2 grupos: (1) grupo para el entrenamiento del clasificador bayesiano que está compuesto de 20 ensayos, y (2) grupo para la clasificación compuesto de 10 ensayos. Este último grupo será clasificado con base al análisis de la técnica *dejando-uno-fuera* (Gallego et al., 2012). Por lo tanto, de los 10 ensayos escogidos para la clasificación,

cada vez será clasificado 1 ensayo, mientras que los 9 restantes serán utilizados para entrenar el clasificador de umbral que es usado para identificar la intención de movimiento a partir de la varianza de la diferencia entre los discriminantes del clasificador bayesiano, como se indica en la figura 5.

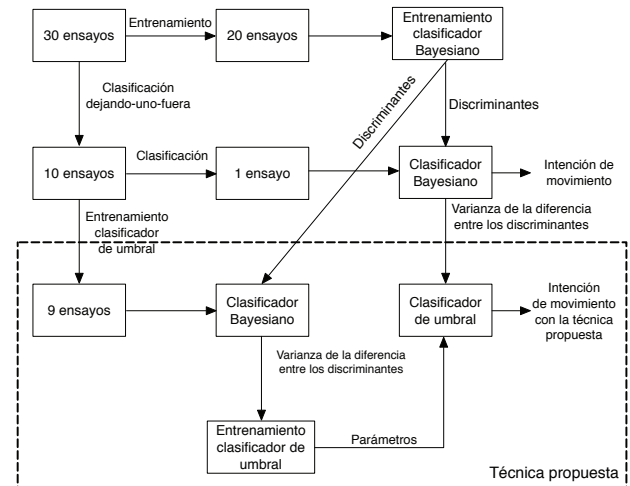


Figura 5: Clasificación de la señal EEG.

La señal EEG se considera clasificada correctamente entre 2 segundos antes del movimiento y hasta 1 segundo después del movimiento, porque la característica ERD que evalúa la intención de movimiento normalmente se presenta en este intervalo (Pfurtscheller and Da Silva, 1999; Ibáñez et al., 2013; Kirchner et al., 2014). Una vez que se desea la predicción de movimiento, el intervalo que se considera como correctamente clasificado es el intervalo antes del movimiento, entre 2 segundos antes y el movimiento en sí. A través de las detecciones en esta ventana de tiempo, la precisión del clasificador se definió por la ecuación (5), donde $P(\%)$ representa el porcentaje de precisión, E_{cc} representa la cantidad de ensayos clasificados correctamente y

E_t es la cantidad total de ensayos.

$$P(\%) = \frac{E_{cc}}{E_t} \quad (5)$$

4. Resultados

Después de aplicar el análisis cualitativo propuesto por Pfurtscheller and Da Silva (1999), al grupo de sujetos participantes durante los ensayos del experimento, no se identificaron las características ERD/ERS para el análisis de intención de movimiento en el 40 % del grupo. Se debe considerar que siempre va a existir un grupo de individuos (del 20 – 25 %) que no pueden usar sistemas BCI clásicos basados en potenciales motores de EEG, debido a que no poseen características de ERD/ERS como las presentadas por Pfurtscheller and Da Silva (1999). Por esta razón, los resultados presentados aquí son los del 60 % del grupo de sujetos que si exhiben estas características. Debido a que la plataforma desarrollada usa las características ERD/ERS para identificar la intención del movimiento, no se justifica utilizarla en sujetos en los que las características ERD/ERS no fueron identificadas en su señal EEG.

La figura 6a presenta el análisis multi-ensayo para un sujeto en el que se identificaron las características ERD coincidiendo con el inicio del movimiento (poco después de los 10 segundos de la tarea), donde se puede notar un decremento en la energía de la señal durante el movimiento. La figura 6b presenta un análisis multi-ensayo para uno de los sujetos donde las características de ERD no fueron identificadas.

En la figura 7 se pueden observar las predicciones de EEG en función del tiempo para cada una de las 30 repeticiones con el sujeto 1, en las cuales la señal de EEG fue clasificada correctamente. Se puede identificar que todos los ensayos están sincronizados en relación al inicio del movimiento (detectado por la IMU), que es considerado como “tiempo cero” para facilitar la visualización de la anticipación de las detecciones de la intención de movimiento en la señal EEG.

La figura 8a muestra la diferencia entre los discriminantes del clasificador bayesiano (clase *estática* substraída de la clase *movimiento*) para una de las repeticiones del experimento, para el sujeto 1. La figura 8b muestra el detalle de la señal proveniente de la varianza de la diferencia entre los discriminantes del clasificador bayesiano de la misma repetición (como se propone en este trabajo), señal que es aplicada en un clasificador de umbral. La figura 8c presenta la misma señal, pero con una escala diferente, en la cual es posible notar que durante el movimiento la varianza de la señal se aproxima a cero, facilitando la clasificación. Al aplicar la varianza en la señal resultante de la diferencia entre los discriminantes, es claramente visible la separación entre las clases *movimiento* y *estática*, lo cual facilita la clasificación con el clasificador de umbral y aumenta la precisión del sistema.

Considerando la ventana de tiempo definida anteriormente, la figura 9 presenta los resultados de clasificación de la anticipación de movimiento a partir de la señal EEG con el clasificador bayesiano, usando la regla de máxima similitud, en comparación con el enfoque presentado en la Sección 3.2.2, donde la

varianza de la diferencia entre los discriminantes del clasificador bayesiano es reclasificada con un clasificador de umbral. Se puede notar claramente un aumento del 30 % en el promedio de la precisión del clasificador con todos los sujetos analizados.

La figura 10 presenta un promedio del tiempo de anticipación por sujeto para la señal EEG, así como un promedio del tiempo entre los sujetos. Se muestra que el promedio de anticipación para la señal EEG es de $678,04 \pm 127,32$ ms y que la media de tiempo en el que el sistema detectó esta señal fue de 629,14 ms, resultando en un atraso medio de 50 ms aproximadamente. Este retraso se debe al ventaneo de la señal así como al uso de un periodo refractario de detección que se inicia a partir de la muestra actual en la que fue detectada la señal, hasta la muestra anterior en donde la misma se produjo. Este retraso no influye en el procesamiento después de que el sistema se ejecuta off-line.

5. Discusión

Los resultados obtenidos con este nuevo enfoque de clasificación de señales EEG a través de SMR muestran una mejora significativa en la precisión de la clasificación (30 % en este caso de estudio). Este estudio estuvo enfocado a las extremidades inferiores y en trabajos futuros serán analizados movimientos de las extremidades superiores.

Los sujetos participantes fueron en su mayoría de género femenino. Este factor no debe influenciar en los resultados, debido a que se ha publicado que no existen diferencias en las señales ERD/ERS en sujetos de género femenino y masculino (Gourab and Schmit, 2010). El hecho de que el grupo de sujetos sea de individuos jóvenes y saludables puede influenciar en los resultados en términos de precisión. Otros estudios con individuos saludables y con deficiencia motora, que usaron SMR, demostraron una diferencia en la precisión del sistema (Müller-Putz et al., 2014). En esta etapa del estudio, el factor edad no fue considerado debido a que el objetivo fue demostrar la ganancia del clasificador de EEG a partir de una variación del método tradicional de clasificación. En próximos estudios se considerarán análisis con poblaciones de ancianos y sujetos con deficiencias motoras.

Los resultados obtenidos pueden ser considerados poco satisfactorios al compararlos con los de otros trabajos que emplean SMR en las extremidades superiores. Kirchner et al. (2014) lograron una precisión cercana al 85 % con señales EEG para la predicción de movimiento en miembros superiores, mientras que Gallego et al. (2012) lograron una precisión del clasificador EEG de aproximadamente 90 % trabajando también con miembros superiores. Sin embargo, vale la pena mencionar que estos resultados fueron obtenidos con miembros superiores, mientras que al trabajar con miembros inferiores, la detección del movimiento a través de señales EEG es más compleja. Esto debido a que la adquisición de la señal EEG para la activación de los miembros inferiores es más difícil que para miembros superiores debido a las regiones fuente de la señal (Guyton and Hall, 2006). Por todo lo anterior, creemos que este estudio presenta resultados aceptables para miembros inferiores.

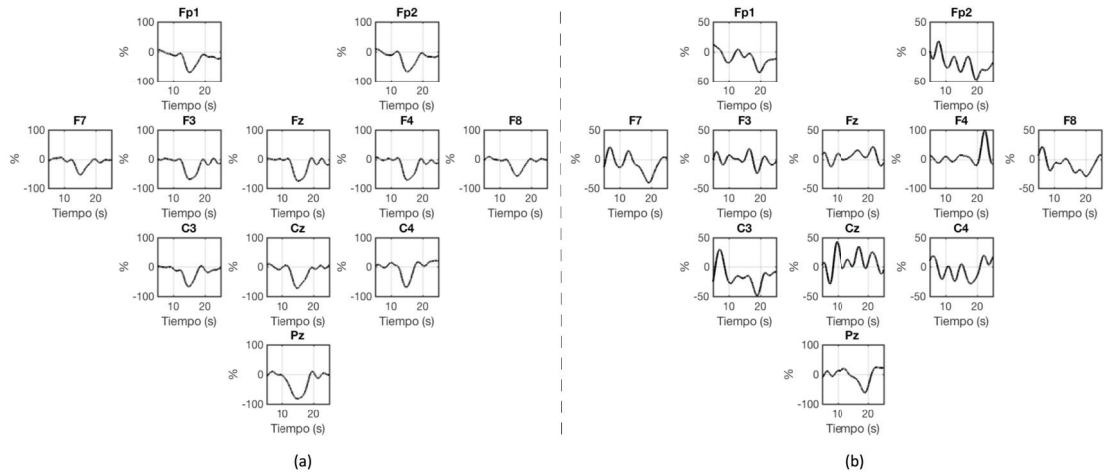


Figura 6: Señal EEG multi-ensayo en la banda μ (a) ERD se identifica; (b) ERD no se identifica.

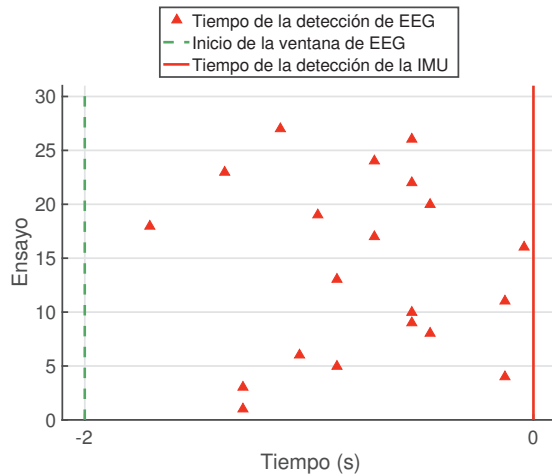


Figura 7: Distribución de la predicción basada en la clasificación de señales EEG.

BCIs motoras aplicadas al estudio de la intención del movimiento de miembros inferiores utilizando SMR son poco estudiadas, debido a su baja eficiencia en términos de precisión. Por esta razón, nuevas técnicas como MRCP han sido sugeridas para mejorar la precisión en la clasificación y que ha comenzado a ser considerada en estudios enfocados a miembros inferiores.

Jiang et al. (2015) presentó buenos resultados en términos de precisión trabajando con miembros inferiores usando MRCP en lugar de SMR. El uso de técnicas de detección de MRCP proporciona una precisión de detección del movimiento en la señal de EEG y a diferencia de ERD/ERS, este tipo de potencial se puede detectar siempre. Este hecho hace que esta técnica sea muy prometedora para detectar el movimiento a través de la MRCP incluso a pesar de tener una predicción de movimiento menor que con SMR, detectando el movimiento a través de

la señal de EEG usualmente algunos milisegundos después del inicio del movimiento (Niazi et al., 2011; Xu et al., 2014; Guger et al., 2014). Comparados con los resultados de este trabajo (precisión media aproximadamente de 43 % y anticipación media aproximadamente de 680 ms), Jiang et al. (2015) alcanzó una precisión media de $76,9 \pm 8,97$ y un tiempo medio de anticipación de 156 ± 369 ms trabajando con 9 sujetos. En este caso es importante mencionar, que para algunos sujetos la detección se obtuvo cientos de milisegundos después del movimiento.

Es importante mencionar, a pesar de que las señales ERD del SMR pueden ocurrir hasta 2 segundos antes del movimiento o durante todo el movimiento, el clasificador de este trabajo sólo consideró como correctos las señales detectadas antes del inicio del movimiento. Tal medida disminuye la tasa de precisión del clasificador en relación a los otros trabajos aquí presentados, cuyo objetivo era detectar el movimiento en señales cerebrales, sin importar si ocurrieron antes o después del movimiento.

Por este hecho, la propuesta del presente trabajo que usa SMR para miembros inferiores, se limita a la comparación con otros trabajos de la literatura, que en su mayoría usan SMR en miembros superiores o usan MRCP en miembros inferiores. Cabe resaltar nuevamente, que una de las limitaciones del uso de SMR es que siempre va a existir un grupo de individuos (del 20 al 25 %) que no presente las características descritas por Pfurtscheller and Da Silva (1999).

Partiendo de que el principal objetivo es presentar un nuevo enfoque en la clasificación de señales de SMR para obtener un aumento de la precisión y abrir la posibilidad de usarla en miembros inferiores (aprovechando la capacidad de anticipación que proporciona el análisis de SMR), los autores consideran las comparaciones entre SMR y MRCP en una BCI a partir de las limitaciones de cada una de estas técnicas.

Cuando se necesite una mejor tasa de anticipación, en lugar de una pérdida de precisión en la detección del movimiento, el uso de la señal SMR puede ser una buena alternativa, sobre todo con el enfoque propuesto en este trabajo, en el que se presentó




Figura 8: (a) Señal relativa a la diferencia entre los discriminantes del clasificador bayesiano. (b) Señal relativa a la varianza de la diferencia entre los discriminantes del clasificador bayesiano. (c) Señal relativa a la varianza de la diferencia entre los discriminantes del clasificador bayesiano para $-1 \leq y \leq 2$.

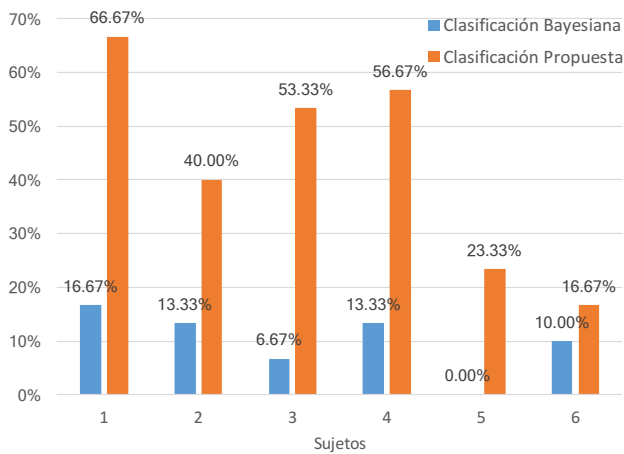


Figura 9: Gráfico comparativo entre el clasificador bayesiano y la clasificación propuesta usando la varianza de la diferencia de los discriminantes.

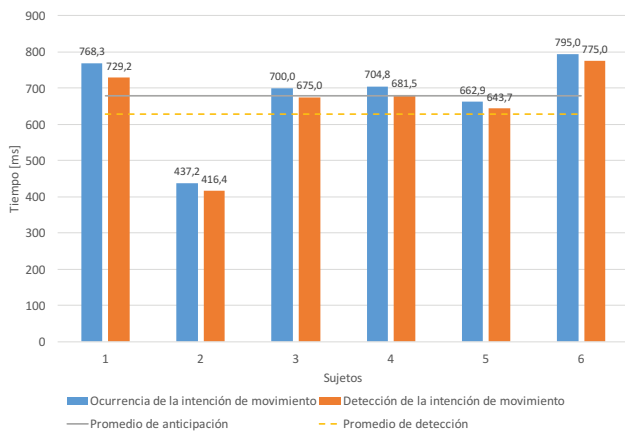


Figura 10: Tiempos de anticipación y detección del sistema.

una eficacia media del 30 % en comparación con el método de clasificación tradicional.

Cuando se requiera controlar dispositivos, es posible mejo-

rar los resultados de precisión alcanzada si se tiene en cuenta la detección desde el inicio del movimiento hasta 300 ms después del mismo, que es el período de tiempo en el que el usuario no puede percibir el retardo al usar un dispositivo (Hudgins et al., 1993). La ocurrencia de ERD es posible en el intervalo de dos segundos antes del movimiento hasta un segundo después de que el movimiento fue ejecutado (Pfurtscheller and Da Silva, 1999; Ibáñez et al., 2013; Kirchner et al., 2014).

Esta anticipación puede permitir una cadena de más comandos de control en un intervalo de tiempo para un movimiento más natural y ágil del usuario. Permitiría también el uso de sistemas de control más complejos, en los que el sistema pueda trabajar con un mayor tiempo de decisión entre los comandos. Esta anticipación podría ofrecer la posibilidad del uso de sistemas de control en sistemas embarcados con bajo poder de procesamiento.

6. Conclusión

Los resultados muestran que puede ser viable trabajar con señales SMR de EEG para predecir la intención de movimiento, incluso trabajando con los miembros inferiores.

Por lo tanto, el análisis SMR puede ser una alternativa para la predicción de movimiento incluso en comparación con el uso de MRCP (Jiang et al., 2015) cuando es necesario un mejor tiempo de anticipación. Estos resultados pueden ser usados en el control de dispositivos robóticos para apoyar las tareas de rehabilitación con un adecuado nivel de detección sin sobrecargar el sistema de control.

Se propuso también un protocolo experimental, aplicado en sujetos sanos para adquirir los datos a través de la interfaz desarrollada. En la perspectiva del trabajo actual, es posible programar una acción de control en dispositivos de rehabilitación para asistir el movimiento, apoyado en el intervalo de predicción de movimiento logrado. En el protocolo no se consideró la concentración del sujeto al realizar las tareas. La portabilidad del protocolo se considera aceptable, porque el gorro de EEG es del estándar internacional 10-20 y además porque depende solamente de dos sensores inerciales, que no presentan limitaciones al colocarlos debido a que su alineación se realiza de manera virtual.

El método de clasificación de EEG se llevó a cabo basado en la frecuencia y el tiempo con un clasificador bayesiano y posteriormente con un clasificador de umbral con la varianza de la diferencia de estos discriminantes. Este método logró una eficiencia satisfactoria de aproximadamente 30 % en relación a los métodos tradicionales de clasificación SMR, llegando a ser mayor a 50 % en precisión para algunos casos, pudiendo implementarse en otros sistemas que incluyan este tipo de señal.

Los resultados presentados fueron obtenidos a partir de un procesamiento *off-line*. Como trabajo futuro, esta plataforma será empleada en el control de un exoesqueleto que se está construyendo. Se desarrollará la detección *on-line* de movimiento con un sistema de retroalimentación y la adopción de estrategias de control en tiempo real.

English Summary

New Approach to the EEG Signals Classification using the Variance of the Difference between the Classes of a Bayesian Classifier.

Abstract

Patients with physical disabilities can benefit from robotic rehabilitation. This improves the efficiency of recovery and, therefore, the rehabilitation of the patient. Assistive and rehabilitation devices can make use of physiological data, such as electromyography (EMG) and electroencephalography (EEG), in order to detect movement intentions. This work presents a multimodal interface for signal acquisition, synchronization and processing of EEG and inertial sensors signals, to be applied in rehabilitation robotic exoskeletons. Experiments were performed with healthy individuals executing knee extension. The goal is to analyze movement intention, muscle activation and movement onset. It was proposed a new approach to the EEG signals classification using a Bayesian classifier taking into account the variance of the difference between the classes used. This contribution presents an average improvement of about 30 % in the EEG classification accuracy in comparison to the traditional classifier approach. In this work an offline analysis was conducted.

Keywords:

Human-machine interface, Signal analysis, Biomedical systems, Inertial measurement units, Human brain, Movement.

Agradecimientos

Los autores desean agradecer a CNPq (308529/2013-8), CAPES (88887.095626/2015-01) y FAPES (67566480 y 72982608) por dar soporte a esta investigación.

Referencias

Ada, L., Dean, C. M., Vargas, J., Ennis, S., 2010. Mechanically assisted walking with body weight support results in more independent walking than

- assisted overground walking in non-ambulatory patients early after stroke: A systematic review. *Journal of Physiotherapy* 56 (3), 153–161. DOI: 10.1016/S1836-9553(10)70020-5
- Arnold, P., Bautmans, I., 2014. The influence of strength training on muscle activation in elderly persons: A systematic review and meta-analysis. *Experimental Gerontology* 58, 58–68. DOI: 10.1016/j.exger.2014.07.012
- Benevides, A. B., Bastos Filho, T. F., Sarcinelli Filho, M., 2008. Mental Task Recognition Based on EEG for Commanding a Robotic Wheelchair. In: 3rd Applied Robotics and Collaborative Systems Engineering (Robocontrol 08). p. 8.
- Bertrand, O., Perrin, F., Pernier, J., 1985. A theoretical justification of the average reference in topographic evoked potential studies. *Electroencephalography and clinical neurophysiology* 62 (6), 462–464. DOI: 10.1016/0168-5597(85)90058-9
- Botelho, T., Soprani, D., Schneider, P., Carvalho, C., Vargas, L., Frizzera, A., 2015. Uma Proposta De Protocolo De Colocação De Sensores Inerciais Utilizando Alinhamento Virtual Para Aplicações Em Análise De Movimento De Membros Inferiores. In: Anais do V Encontro Nacional de Engenharia Biomecânica - ENEBI 2015. Uberlândia, Brasil, pp. 511–515.
- Cheng, M., Jia, W., Gao, X., Gao, S., Yang, F., 2004. Mu rhythm-based cursor control: An offline analysis. *Clinical Neurophysiology* 115 (4), 745–751. DOI: 10.1016/j.clinph.2003.11.038
- Gallego, J. Á., Ibáñez, J., Dideriksen, J. L., Serrano, J. I., del Castillo, M. D., Farina, D., Rocon, E., 2012. A multimodal human-robot interface to drive a neuroprosthesis for tremor management. *IEEE Transactions on Systems, Man, and Cybernetics* 42 (6), 1159–1168.
- Gourab, K., Schmit, B. D., 2010. Changes in movement-related u-band EEG signals in human spinal cord injury. *Clinical Neurophysiology* 121 (12), 2017–2023. DOI: 10.1016/j.clinph.2010.05.012
- Guger, C., Vaughan, T., Allison, B., 2014. Brain-Computer Interface Research: A State-of-the-Art Summary 3. SpringerBriefs in Electrical and Computer Engineering. Springer International Publishing. DOI: 10.1007/978-3-319-09979-8
- Guyton, A. C., Hall, J. E., 2006. Textbook of medical physiology, 11th Edition. Elsevier Saunders, Philadelphia.
- Hudgins, B., Parker, P., Scott, R. N., 1993. A New Strategy for Multifunction Myoelectric Control. *IEEE Transactions on Biomedical Engineering* 40 (1), 82–94. DOI: 10.1109/10.204774
- Husemann, B., Müller, F., Krewer, C., Heller, S., Koenig, E., 2007. Effects of locomotion training with assistance of a robot-driven gait orthosis in hemiparetic patients after stroke: A randomized controlled pilot study. *Stroke* 38 (2), 349–354. DOI: 10.1161/01.STR.0000254607.48765.cb
- Ibáñez, J., Serrano, J., del Castillo, M., Gallego, J., Rocon, E., nov 2013. Online detector of movement intention based on EEG-Application in tremor patients. *Biomedical Signal Processing and Control* 8 (6), 822–829. DOI: 10.1016/j.bspc.2013.07.006
- Jiang, N., Gizzi, L., Mrachacz-Kersting, N., Dremstrup, K., Farina, D., 2015. A brain-computer interface for single-trial detection of gait initiation from movement related cortical potentials. *Clinical Neurophysiology* 126 (1), 154–159. DOI: 10.1016/j.clinph.2014.05.003
- Ju, M.-S., Lin, C.-C. K., Lin, D.-H., Hwang, I.-S., Chen, S.-M., sep 2005. A Rehabilitation Robot With Force-Position Hybrid Fuzzy Controller: Hybrid Fuzzy Control of Rehabilitation Robot. *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society* 13 (3), 349–58. DOI: 10.1109/TNSRE.2005.847354
- Kirchner, E. A., Tabie, M., Seeland, A., jan 2014. Multimodal movement prediction - towards an individual assistance of patients. *PloS one* 9 (1), e85060. DOI: 10.1371/journal.pone.0085060
- Latikka, J. A., Hyttinen, J. A., Kuurne, T. A., Eskola, H. J., Malmivuo, J. A., 2001. The conductivity of brain tissues: Comparison of results in vivo and in vitro measurements. *Annual Reports of the Research Reactor Institute, Kyoto University* 1, 910–912. DOI: 10.1109/IEMBS.2001.1019092
- Lu, M.-K., Jung, P., Bliem, B., Shih, H.-T., Hseu, Y.-T., Yang, Y.-W., Ziemann, U., Tsai, C.-H., apr 2010. The Bereitschaftspotential in essential tremor. *Clinical Neurophysiology* 121 (4), 745–751. DOI: 10.1016/j.clinph.2009.11.038

- nical neurophysiology : official journal of the International Federation of Clinical Neurophysiology 121 (4), 622–630.
DOI: 10.1016/j.clinph.2009.12.014
- Mackay, J., Mensah, G., 2004. Global Burden of Stroke. In: The Atlas of Heart Disease and Stroke. World Health Organization, Ch. The Burden, pp. 50–51.
- Mrachacz-Kersting, N., Kristensen, S. R., Niazi, I., Farina, D., apr 2012. Precise temporal association between cortical potentials evoked by motor imagination and afference induces cortical plasticity. The Journal of physiology 590 (Pt 7), 1669–82.
DOI: 10.1113/jphysiol.2011.222851
- Mrachacz-Kersting, N., Stevenson, A. J. T., Aliakbarhosseinabadi, S., Lundgaard, A. C., Jørgensen, H. R., Severinsen, K., Farina, D., 2017. An Associative Brain-Computer-Interface for Acute Stroke Patients. Springer International Publishing, Cham, pp. 841–845.
DOI: 10.1007/978-3-319-46669-9_137
- Müller-Putz, G. R., Daly, I., Kaiser, V., 2014. Motor imagery-induced EEG patterns in individuals with spinal cord injury and their impact on brain-computer interface accuracy. Journal of neural engineering 11 (3), 035011.
DOI: 10.1088/1741-2560/11/3/035011
- Niazi, I. K., Jiang, N., Tiberghien, O., Nielsen, J. F., Dremstrup, K., Farina, D., oct 2011. Detection of movement intention from single-trial movement-related cortical potentials. Journal of Neural Engineering 8 (6), 066009.
DOI: 10.1088/1741-2560/8/6/066009
- Pfurtscheller, G., Da Silva, F. L., nov 1999. Event-related EEG/MEG synchronization and desynchronization: basic principles. Clinical neurophysiology : official journal of the International Federation of Clinical Neurophysiology 110 (11), 1842–57.
- Shibasaki, H., Hallett, M., nov 2006. What is the Bereitschaftspotential? Clinical neurophysiology : official journal of the International Federation of Clinical Neurophysiology 117 (11), 2341–56.
DOI: 10.1016/j.clinph.2006.04.025
- Strong, K., Mathers, C., Bonita, R., 2007. Preventing stroke: saving lives around the world. Lancet Neurology 6 (2), 182–187.
DOI: 10.1016/S1474-4422(07)70031-5
- Tsukahara, A., Hasegawa, Y., Sankai, Y., jun 2009. Standing-up motion support for paraplegic patient with Robot Suit HAL. 2009 IEEE International Conference on Rehabilitation Robotics, 211–217.
DOI: 10.1109/ICORR.2009.5209567
- Volkers, K. M., de Kieviet, J. F., Wittingen, H. P., Scherder, E. J. A., 2012. Lower limb muscle strength (LLMS): Why sedentary life should never start? A review. Archives of Gerontology and Geriatrics 54 (3), 399–414.
DOI: 10.1016/j.archger.2011.04.018
- Winstein, C. J., Stein, J., Arena, R., Bates, B., Cherney, L. R., Cramer, S. C., Deruyter, F., Eng, J. J., Fisher, B., Harvey, R. L., Lang, C. E., Mackay-lyons, M., Ottenbacher, K. J., Pugh, S., Reeves, M. J., Richards, L. G., Otr, L., Stiers, W., Rp, A., 2016. AHA / ASA Guideline: Guidelines for Adult Stroke Rehabilitation and Recovery.
DOI: 10.1161/STR.0000000000000098
- Xu, R., Jiang, N., Lin, C., Mrachacz-Kersting, N., Dremstrup, K., Farina, D., 2014. Enhanced low-latency detection of motor intention from EEG for closed-loop brain-computer interface applications. IEEE Transactions on Biomedical Engineering 61 (2), 288–296.
DOI: 10.1109/TBME.2013.2294203
- Xu, R., Jiang, N., Mrachacz-Kersting, N., Dremstrup, K., Farina, D., 2016. Factors of influence on the performance of a short-latency non-invasive brain switch: Evidence in healthy individuals and implication for motor function rehabilitation. Frontiers in Neuroscience 9 (JAN), 1–9.
DOI: 10.3389/fnins.2015.00527
- Yang, S., Kong, L., 2009. Research on characteristic extraction of human gait. 3rd International Conference on Bioinformatics and Biomedical Engineering, iCBBE 2009, 2–5.
DOI: 10.1109/ICBBE.2009.5163328