

Extracción de Intención de Movimiento en Señales Electroencefalográficas para el Control de una Prótesis de Mano

J. M. Cervantes-Pelayo¹, M. Vázquez-Evangelista¹, R. A. Salido-Ruiz^{1*}

¹Departamento de Electrónica del Centro Universitario de Ciencias Exactas e Ingenierías de la Universidad de Guadalajara, Jalisco, México.

²Departamento de Ciencias Computacionales del Centro Universitario de Ciencias Exactas e Ingenierías de la Universidad de Guadalajara, Jalisco, México.

ricardo.salido@academicos.udg.mx

Resumen

Un paradigma conocido en las Interfaces Cerebro-Computador es la Imaginación Motora, en éste paradigma un sujeto imagina que realiza algún movimiento y regiones cerebrales se activan en bandas de frecuencia específicas que forman patrones espaciales similares a aquellos que se hubiesen formado si el movimiento se ejecutara realmente. La detección y procesamiento de estos eventos permite controlar dispositivos como prótesis, sillas de ruedas o guiar tratamientos de rehabilitación. Hasta ahora estudios basados en este paradigma extraen características de éstos patrones de las señales electroencefalográficas mediante la Transformada de Fourier de Período Corto o Transformada Wavelet. Sin embargo, no se ha encontrado en la literatura que se utilice una combinación de ambas técnicas para lograr este objetivo. En este trabajo presentamos una metodología que combina la Transformada de Fourier de Período Corto con la Transformada Continua de Wavelet, con el fin de mejorar la detección de la intención de movimiento en tareas de Imaginación Motora para el control básico offline de una prótesis en miembro superior. Esta propuesta, es un nuevo enfoque para la clasificación de señales electroencefalográficas, en la detección de la intención de iniciar y detener un movimiento con un desempeño promedio de 82.5%.

Palabras clave: CWT, Intención de Movimiento, Prótesis de Mano, STFT.

1. Introducción

La electroencefalografía (EEG) es una técnica que nos permite adquirir señales provenientes de distintas regiones del cerebro mediante la colocación de electrodos en el cuero cabelludo. Esta es utilizada principalmente para la detección de patologías como la epilepsia [1], el Alzheimer [2], la esquizofrenia [3], entre otros trastornos cerebrales. Otros usos del EEG han sido realizados para el reconocimiento de emociones [4] y la interacción con dispositivos electrónicos [5]. Este último uso del EEG concierne a las Interfaces Cerebro-Computadora (BCI, del inglés *Brain-Computer Interfaces*) [5]. Un Sistema BCI provee al cerebro de un nuevo canal, no muscular, de comunicación y control [6]. De la definición anterior surge la siguiente pregunta: ¿cómo puede generar el usuario de un Sistema BCI los comandos al mundo exterior? La respuesta radica en los mecanismos neurológicos o procesos empleados por el usuario para generar las señales de control, denominados fuentes electrofisiológicas. Las más utilizadas son, los potenciales corticales lentos (SCP), los potenciales evocados visuales (VEP) y la Imaginación Motora (MI) [7]. En ésta última un sujeto imagina que realiza algún movimiento y regiones cerebrales se activan en bandas de frecuencia específicas. En general, los ritmos alfa tienen una banda de

frecuencia de 8 – 12 Hz, mientras que un ritmo beta se encuentra en el rango de 12 – 30 Hz [8], siendo de gran importancia y de las más usadas en la MI. No obstante, estas bandas de frecuencia pueden variar dependiendo del sujeto, formando patrones espaciales similares a aquellos que se hubiesen formado si el movimiento se ejecutara realmente. Estos patrones detectados como señales EEG contienen características que los definen y que deben de ser extraídas para ser transformadas en señales de control en un Sistema BCI [8]. La mayoría de las aplicaciones biomédicas de esta tecnología tienen como objetivo que las personas que sufren parálisis severa puedan prescindir de las vías motoras interrumpidas y operar las prótesis de extremidades superiores directamente desde el cerebro. Convertir la actividad del sistema nervioso central en acciones ejecutables contribuye a un método efectivo, como se establece en [9].

No obstante, detectar la intención de iniciar y detener un movimiento utilizando señales de EEG obtenidas antes de que ocurra el evento, son necesarios para aplicaciones BCI en tiempo real, como prótesis y neurorehabilitación [10]. En ese trabajo, los autores utilizaron la Transformada Wavelet (WT) para extraer la información relacionada con eventos en las bandas alfa y beta en una representación tiempo-frecuencia, logrando una exactitud en detección de intención de movimiento del 80,67%. La referencia [11] se centra en identificar los movimientos de las manos con MI, haciendo uso de la Transformada de Fourier de Período Corto (STFT). Esta brinda la oportunidad de ver el espectro de la señal en diferentes marcos de tiempo o ventanas, donde los resultados manifiestan que el rendimiento del método propuesto es comparable con otros algoritmos con una exactitud del 83,71%. Un estudio en [12], cuyo objetivo es agrupar correctamente las señales EEG provenientes de distintas regiones cerebrales, indica que es posible identificar los movimientos imaginados utilizando la WT para la extracción de características de la actividad cerebral, con una exactitud media de hasta el 76,19%. Un resumen de los objetivos y técnicas de procesamiento así como el desempeño obtenido en los trabajos antes mencionados se muestra en la Tabla 1.

Tabla 1: Comparación de la efectividad de métodos para extracción de Imaginación Motora (MI).
BCI basado en MI para control de prótesis

Cita	Objetivos	Procesamiento	Resultados
[10]	Detectar la intención de iniciar y detener un movimiento (marcha) utilizando señales de EEG obtenidas antes de que ocurra el evento (necesarios para la aplicación de BCI en tiempo real).	Transformada Wavelet (WT)	Efectividad del 80,67%
[11]	Identificar los movimientos de las manos con imaginación motora, extrayendo las características adecuadas de las señales de EEG.	Transformada de Fourier de tiempo corto (STFT)	Efectividad de 83,71%.
[12]	Sistema inteligente es capaz de identificar movimientos imaginados utilizando sólo la actividad cerebral.	Transformada Wavelet (WT)	Efectividad de 76,19%

En este contexto, el presente trabajo se enfoca en desarrollar como primera aproximación una metodología en el contexto de MI en un sistema BCI para el control off-line de una mano protésica, a partir de la extracción de características de la señal EEG combinando los métodos STFT y WT.

2. Metodología

En esta sección presentamos los materiales, herramientas computacionales y la metodología utilizada en este estudio.

2.1 Materiales

El control para el prototipo de prótesis se implementó bajo la tarjeta de desarrollo Arduino®, [13]. Se utilizó un servomotor como actuador, que permite realizar el movimiento mecánico del prototipo de mano robótica mediante un sistema de poleas que simula la acción de abrir y cerrar la mano.

El procesamiento de los datos (filtros digitales, Análisis de Componentes Independientes (ICA), representaciones tiempo-frecuencia, promediado en bandas de frecuencia y correlación cruzada) y los algoritmos de control (modulación por ancho de pulso y comunicación serial) fueron implementados en MATLAB®.

2.2 Métodos

Para el procesamiento completo de las señales EEG se diseñó una interfaz gráfica que consta de cuatro etapas como se muestra en el esquema de la Fig. 1:

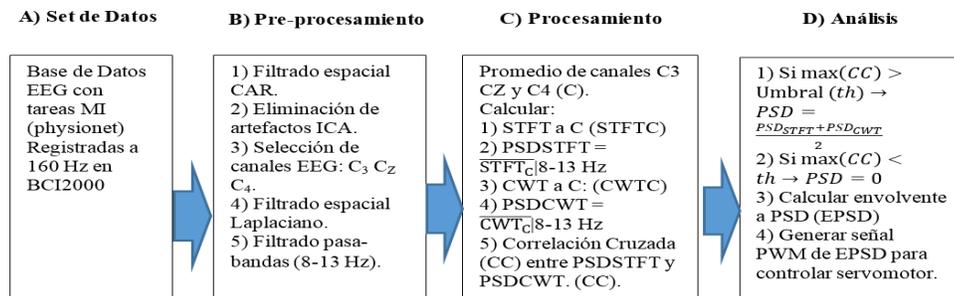


Fig. 1. Diagrama de metodología para procesamiento final.

A. Base de datos

Se optó por descargar un set de datos que contiene más de 1,500 registros de EEG obtenidos de 109 voluntarios que realizaron diferentes tareas de MI [14], el cual se encuentra en PhysioNet, que consiste en un repositorio de datos de investigación médica disponibles gratuitamente [14], donde menciona que se registró utilizando el Sistema BCI2000 [14] que se utiliza para controlar la adquisición de señales, procesamiento de señales y la retroalimentación para el usuario [15]. De los cuales se seleccionaron sólo 10 registros EEG de 64 canales sin procesar, posicionados según el Sistema Internacional 10-10, registrados a una frecuencia de muestreo establecida en 160 Hz. De esta manera, cada sujeto realizó 14 series experimentales, de las cuales sólo elegimos 2 series para nuestro estudio. La primera serie de 1 minuto (EEG base), la cual consiste en identificar un objeto del lado izquierdo o derecho de la pantalla, el sujeto abre y cierra la mano correspondiente hasta que el objeto desaparece y entonces el sujeto se relaja. La segunda serie de 2 minutos (EEG en tarea 1) consiste en identificar un objeto del lado izquierdo o derecho de la pantalla, el sujeto imagina abrir y cerrar la mano correspondiente hasta que el objeto desaparece y entonces el sujeto se relaja. Lo anterior con la intención de comparar ambas series experimentales e identificar patrones espaciales similares en el movimiento imaginado de la mano a aquellos que se hubiesen formado si el movimiento se ejecutara realmente [8].

B. Pre procesamiento del EEG

Las señales fueron re-referenciadas a una referencia promedio (CAR) para eliminar el ruido común a todos los electrodos [16]. Además, debido a que las señales EEG presentaron artefactos (oculares, musculares, movimiento de electrodos, ruido gaussiano e interferencia de señales ECG, entre otros), se

implementó un Análisis de Componentes Independientes mediante el algoritmo FastICA, para identificar señales fuentes estadísticamente independientes y eliminar mediante inspección visual las fuentes de artefactos [9]. En el caso de MI se utilizan menos electrodos de los totales, ya que la mayor parte de la información útil extraíble proviene de la corteza motora [8], que es la región de la corteza cerebral responsable de los procesos de planificación, control y ejecución de los movimientos, por lo tanto, teniendo en cuenta que la actividad que se quiere adquirir se encuentra en la corteza motora, los electrodos de interés en nuestro estudio fueron: C₃, C₄ y C_Z, debido a su localización en el plano coronal [7]. Para resaltar los potenciales en estos electrodos, éstos fueron representados en un montaje Laplaciano, restando la media de las señales provenientes de los 4 electrodos vecinos más cercanos a los electrodos de interés. Finalmente, se aplicó un filtro pasa bandas IIR de fase 0 y de orden 16, en las ondas alfa (8 – 13 Hz) del EEG, ya que este rango de frecuencias es parte de la actividad sensorial motora [17].

C. Procesamiento del EEG

Las señales EEG (C₃, C₄ y C_Z) previamente filtradas fueron promediadas para obtener C la cual fue procesada mediante la STFT dada por (1). Donde $C[n]$ es la señal EEG discreta, $w[n]$ es la ventana y m es el índice de tiempo discreto que usualmente no se expresa con tan alta resolución como con el tiempo n .

$$STFT\{C[n]\} = C(m, w) = \sum_{n=-\infty}^{\infty} C[n]w[n-m]e^{-jwn} \quad (1)$$

La señal promedio C también fue procesada con la Transformada Continua de Wavelet (CWT) que está dada por (2). Donde la variable a controla el ancho o soporte efectivo de la función $\psi(t)$ y la variable b nos da la ubicación en el dominio del tiempo de ψ .

$$CWT(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} C(t)\psi\left(\frac{t-b}{a}\right) dt \quad (2)$$

Para ambas representaciones se calcula el promedio de la PSD en la banda de 8 a 13 Hz, obteniendo dos vectores de datos \overline{PSD}_{STFT} , \overline{PSD}_{CWT} con la PSD promedio para el intervalo de tiempo estudiado.

D. Análisis

Se calcula la correlación entre datos \overline{PSD}_{STFT} y \overline{PSD}_{CWT} a fin de conocer si ambos métodos coinciden en la detección de la intención de movimiento y decidir si ésta es correcta o si se trata de un falso positivo. Si el valor de correlación supera un umbral (ht), \overline{PSD}_{STFT} y \overline{PSD}_{CWT} se promedian para obtener una sola PSD y de ésta obtener las ventanas de inicio y fin del evento. Después se calcula la envolvente a la PSD resultante (E_{PSD}) que será utilizada para generar una señal de modulación por ancho de pulsos (PWM), que consiste en generar una onda cuadrada formada por pulsos positivos, modificando su ciclo de trabajo o el ancho relativo de su parte positiva en relación con el período [9] y con esto mover el servomotor para generar la fuerza mecánica suficiente y controlar el movimiento off-line del prototipo de mano protésica.

Para estimar la efectividad se contabilizó el número de detecciones de intenciones de movimiento correctas e incorrectas y con ello se obtuvo el porcentaje de aciertos para cada sujeto y se promedió.

3. Resultados y Discusión

Después de aplicar la metodología propuesta en 10 estudios EEG del set de datos para prueba piloto, se lograron detectar los picos de Densidad Espectral de Potencia (PSD), los cuales se utilizan como característica para la extracción de la MI. Un procedimiento similar al que expone [9].

En la Fig. 2 se muestra el espectrograma 3D de la señal EEG (*C*), utilizando STFT que brinda la oportunidad de ver el espectro de la señal en diferentes marcos de tiempo (rectángulos rojos), donde se visualiza la intención de movimiento del sujeto al imaginar abrir y cerrar la mano.

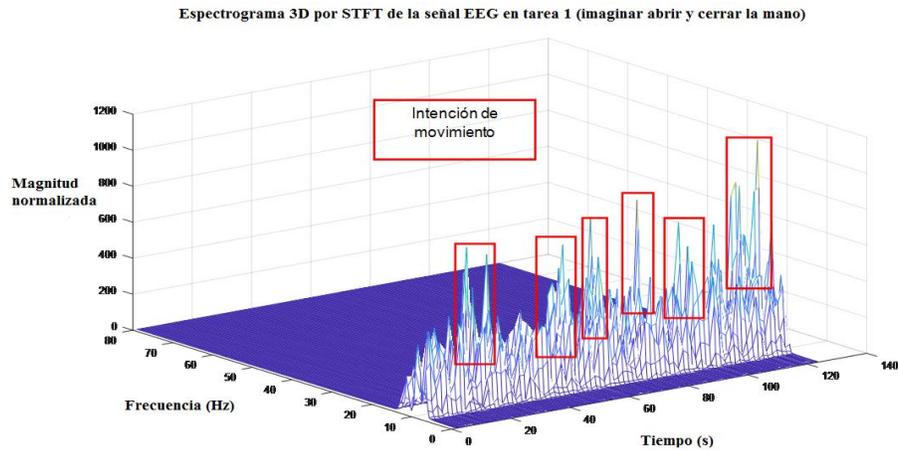


Fig. 2. Espectrograma STFT en representación 3D de la señal EEG de sujeto de prueba 1.

En la Fig. 3 se muestra el espectrograma de la señal EEG (*C*), utilizando CWT donde se visualiza la intención de movimiento del sujeto al imaginar abrir y cerrar la mano, reflejado en los puntos de mayor magnitud de PSD (rectángulos rojos).

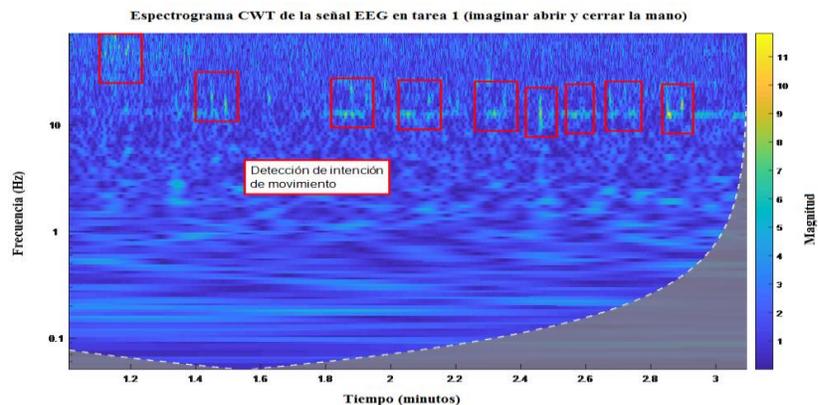


Fig. 3. Espectrograma de la señal EEG por CWT de sujeto de prueba 1.

En la Fig. 4 se muestra el rango de variación de la envolvente de las PSD normalizada en 10 sujetos, donde se identifica un rango en el que se encuentran la mayoría de los sujetos de entre 0.3 y 0.85 de magnitud normalizada, varios sujetos tienen traslape en rango pero otros no, por lo que para cada uno

de ellos es necesario adecuar un umbral personalizado para la detección del movimiento imaginado. Sin embargo, se debe considerar que siempre va a existir un grupo de individuos del 20 al 25% que no pueden usar Sistemas BCI basados en potenciales motores de EEG, debido a que no poseen características de ERD/ERS (Desincronización Relacionada a Eventos/Sincronización) [16], por lo que también se observan valores atípicos en el análisis. Como ejemplo, para el sujeto 3 se eligió un umbral, tomando en cuenta el rango de variación de la envolvente observado en la Fig. 4 y con él se construyó una señal de modulación por ancho de pulsos (PWM). Esta se utilizó para mover un servo motor mediante una BCI (una conexión entre el software MATLAB y Arduino), como se puede observar en la Fig. 5. Esto con el fin de simular la intención de movimiento (abrir y cerrar el puño izquierdo o derecho) en un prototipo de prótesis de mano. Un ejemplo de la utilidad de la PWM es mencionada por [11], quien hace hincapié en que es una técnica extendida para muchas aplicaciones que al aplicarla a las señales de EEG puede ser utilizada para interpretar la intención de los usuarios y traducirlo a una acción.

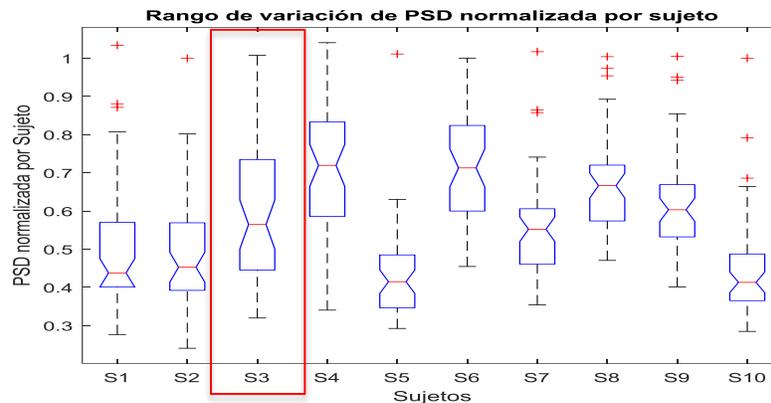


Fig. 4. Rango de variación de PSD normalizada en 10 estudios EEG diferentes.

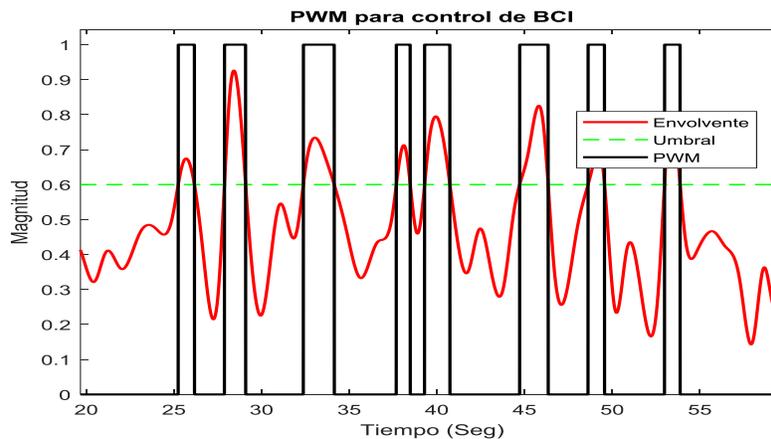


Fig. 5. PWM para control de BCI (Sujeto 3).

La efectividad de los resultados obtenidos en la detección de MI con la metodología propuesta, comparando las anotaciones (instantes de tiempo en los que se hicieron las tareas de MI) de los estudios realizados, fue para cada sujeto de 75%, 91.66%, 91.66%, 83.33%, 75%, 91.66%, 83.33%, 83.33%, 75%, y 75% respectivamente para dar en promedio del 82.5 con una desviación estándar de ± 7.3 en la detección de MI como se muestra en la Tabla 2.

Tabla 2: Análisis estadístico de la efectividad del método para la detección de la MI.

Efectividad del método			
Estudios de prueba	Efectividad en detección de MI	Error-promedio (segundos)	Desviación estándar (segundos)
S1	75%	2	±1.41
S2	91.66%	1.27	±1.60
S3	91.66%	1.83	±1.77
S4	83.33%	1.81	±1.58
S5	75%	0.6	±1.20
S6	91.66%	1.16	±1.40
S7	83.33%	1.36	±1.66
S8	83.33%	1.27	±1.48
S9	75%	0.66	±1.33
S10	75%	0.66	±1.33
Promedio	82.5%	1.26	± 0.48

4. Conclusiones

Los resultados preliminares son prometedores, ya que demuestran que el método propuesto alcanza un rendimiento estadístico similar (82.5 %) con respecto a otros métodos (ver sección introducción). Por lo anterior, este estudio presenta resultados aceptables en cuanto a la detección de movimientos imaginarios, sin embargo, a manera de conclusión podemos decir que, debido a que las señales EEG presentan gran cantidad de información, es necesario ejecutar una caracterización más robusta de MI presentes en estas señales. Además, se necesita impulsar el desarrollo de nuevas tecnologías o implementaciones que conlleven a un mejor aprovechamiento de información (libre de ruidos y artefactos) que podrían ser una mejora relativamente alta en la eficiencia de Sistemas BCI o prototipos, como el presente.

Declaración de conflictos de interés

Los autores declaran no tener ningún conflicto de interés para este trabajo.

Agradecimientos

El autor J. M. agradece a su familia por apoyarlo siempre, no importando que tan lejos esté. El autor M. agradece a J. M. por compartir su conocimiento y por su paciencia infinita. El autor R. A. agradece a sus alumnos por el esfuerzo y dedicación en el trabajo realizado.

Referencias

- [1] Deivasigamani, S., Senthilpari, C. & Yong, W.H. (2020). *Machine learning method based detection and diagnosis for epilepsy in EEG signal*. Obtenido de Biblioteca Digital: <https://doi-org.wdg.biblio.udg.mx:8443/10.1007/s12652-020-01816-3>
- [2] Al-Jumeily D., Iram S., Hussain A.J., Francois-Benois V. & Fergus P. (2014). *Early Detection Method of Alzheimer's Disease Using EEG Signals*. Obtenido de Biblioteca Digital: https://doi-org.wdg.biblio.udg.mx:8443/10.1007/978-3-319-09330-7_4

- [3] Deivasigamani, S., Senthilpari, C. & Yong, W.H. (2020). *Machine learning method based detection and diagnosis for epilepsy in EEG signal*. Obtenido de Biblioteca Digital: <https://doi-org.wdg.biblio.udg.mx:8443/10.1007/s12652-020-01816-3>
- [4] Matlis, Sean Eben Hill (2016). *Functional network and spectral analysis of clinical EEG data to identify quantitative biomarkers and classify brain disorders*. Obtenido de Biblioteca Digital: <http://wdg.biblio.udg.mx:2048/login?url=https://www.proquest.com/docview/1853453348?accountid=28915>
- [5] Hubert, B., Rishabh, G. & Tiago H. (2017). *Mental Task Evaluation for Hybrid NIRS-EEG Brain-Computer Interfaces*. Obtenido de Biblioteca Digital: <http://dx.doi.org/10.1155/2017/3524208>
- [6] Ozdenizci, Ozan (2020). *Statistical learning and inference in neural signal processing: Applications to brain interfaces*. Obtenido de Biblioteca Digital: <http://wdg.biblio.udg.mx:2048/login?url=https://www.proquest.com/docview/2438895614?accountid=28915>
- [7] Astigarraga, A., Arruti, A., Muguerza, J., Santana, R., Martin, J. I., & Sierra, B. (2016). *User Adapted Motor-Imaginary Brain-Computer Interface by means of EEG Channel Selection Based on Estimation of Distributed Algorithms*. Obtenido de Biblioteca Digital: <https://doi.org/10.1155/2016/1435321>
- [8] King, C. E. (2014). *Brain-computer interface systems for neurorehabilitation*. Obtenido de Biblioteca Digital: <http://wdg.biblio.udg.mx:2048/login?url=https://search.proquest.com/docview/1609013804?accountid=28915>
- [9] Mariacarla, S., Maurizio, G. & Fanny, F. (2019). *Network Approach for a BCI-Based Robotic Prosthetic Control*. Obtenido de Biblioteca Digital: <https://doi-org.wdg.biblio.udg.mx:8443/10.1007/s12369-019-00576-1>
- [10] Shafiu, H., Masudur, S., Roozbeh, A., Rodrigo, R., J. Sebastian, M. & Ou, B. (2020). *Prediction of gait intention from pre-movement EEG signals: A feasibility study*. Obtenido de Biblioteca Digital: <http://dx.doi.org/10.1186/s12984-020-00675-5>
- [11] Syed, K. & Mohammed, I. (2016). *Classification of motor imagery movements using multivariate empirical mode decomposition and short time Fourier transform based hybrid method*. Obtenido de Biblioteca Digital: <https://doi.org/10.1016/j.jestch.2016.04.009>
- [12] Andrade, M. K., Santana M. A, Moreno, G. & Olivera I. (2020). *An EEG Brain-Computer Interface to Classify Motor Imagery Signals*. Obtenido de Biblioteca Digital: https://doi-org.wdg.biblio.udg.mx:8443/10.1007/978-981-13-9097-5_5
- [13] Cho, J. I., Wang, X., Xu, Y., & Sun, J. (2019). *LISA: A MATLAB package for longitudinal image sequence analysis*. Obtenido de Biblioteca Digital: <https://search.proquest.com/docview/2186324195?accountid=28915>
- [14] Schalk, G., McFarland, D.J., Hinterberger, T., Birbaumer, N., Wolpaw, J.R. (Septiembre de 2009). *EEG Motor Movement/Imagery Dataset*. Obtenido de PhysioNet: <https://www.physionet.org/content/eegmidb/1.0.0/>
- [15] Niknamian, S. (2019). *Designing a hybrid brain computer interface system: An introduction*. Obtenido de Biblioteca Digital: <http://wdg.biblio.udg.mx:2048/login?url=https://search.proquest.com/docview/2275866123?accountid=28915>
- [16] Botelho, T. R. (2017). *Nuevo Enfoque para la Clasificación de Señales EEG usando la Varianza de la Diferencia*. Revista Iberoamericana de Automática e Informática Industrial, 362–371.
- [17] Barón, D. F. (2011). *Reconocimiento de Imaginación Motora de Señales EEG en el Dominio Temporal aplicando Modelos Paramétricos*. Obtenido de Biblioteca Digital: <https://inaoe.repositorioinstitucional.mx/jspui/bitstream/1009/672/1/DcrozBD.pdf>