



SISTEMA BCI QUE PERMITA EL CONTROL DE UN EXOESQUELETO DE MIEMBRO INFERIOR A TRAVÉS DEL PROCESAMIENTO DE SEÑALES ELECTROENCEFALOGRÁFICAS

Sebastián Cardona Castro, Diego Alejandro Ramírez Marroquín, Catalina Aguirre Grisales

**Universidad del Quindío
Armenia, Colombia**

Resumen

En este artículo se propone el control de un exoesqueleto de miembro inferior, a través del procesamiento de las señales electroencefalográficas (EEG), utilizando técnicas de imaginación motora (MI). Para esto, la señal EEG fue adquirida por medio de una interfaz cerebro computador (BCI) utilizando el sistema Nautilus16. Para ello, se hace uso de un exoesqueleto a escala de miembro inferior con dos grados de libertad, basado en el modelo de un CPWalker diseñado y fabricado en el programa de Ingeniería Electrónica de la Universidad del Quindío. Para el control del exoesqueleto, se implementó una máquina de vector de soporte (SVM), utilizando el kernel de Función de Base Radial (RBF), el cual permite identificar la intención de movimiento (miembro derecho o izquierdo), a partir del análisis de los ritmos motores cerebrales. Finalmente, para generar el movimiento en el exoesqueleto se hace uso de una interfaz serial, la cual comunica el entorno de desarrollo de Python con una tarjeta Arduino Uno, donde se envían los comandos de control a los motores del exoesqueleto, conforme a la respuesta generada por el modelo de clasificación. Para evaluar el prototipo, se realizaron una serie de pruebas piloto con dos usuarios totalmente sanos, con un rango de edad de 22 a 25 años. Las señales EEG de los participantes, fueron filtradas, segmentadas y procesadas de acuerdo a los parámetros de entrenamiento del modelo generado, obteniendo resultados de exactitud del 91%.

Palabras clave: EEG-BCI; SVM; exoesqueleto

Abstract

This paper proposes the control of a lower limb exoskeleton through the processing of electroencephalographic (EEG) signals using motor imagery (MI). For this, the EEG signal was acquired using a brain computer interface (BCI) using the Nautilus 16 system. For this, a lower limb exoskeleton system with two degrees of freedom is used, based on the model of a CPWalker designed and manufactured in the Electronic Engineering program of the Universidad del Quindío. For the exoskeleton control, a support vector machine (SVM) was implemented, using the Radial Basis Function (RBF) kernel, which allows to identify the movement intention (right or left limb), based on the cerebral motor rhythms analysis. Finally, to produce the movement in the exoskeleton a serial interface is used, which allows to communicate the python development environment with an Arduino Uno board, where the control commands are sent to the exoskeleton motors, in accordance with the classification model's response. For prototype evaluation, a series of pilot tests were made with two healthy users, with an age range of 22 to 25 years old. EEG signals collected from the participants, were filtered, segmented and processed according to the training parameters given by the model, obtaining accuracy results of 91%.

Keywords: EEG-BCI; support vector machine; exoskeleton

1. Introducción

Novedosas formas de comunicación entre el humano y las máquinas, han permitido la codificación de diversas señales fisiológicas en un amplio rango de aplicaciones enfocadas en un principio a los mecanismos de asistencia de personas con diferentes tipos de limitaciones físicas. Entre dichas formas de comunicación, se encuentran las interfaces cerebro computador (Brain-computer-Interface, BCI), las cuales permiten codificar la actividad cerebral humana para el control de dispositivos externos. Esta interfaz opera a través del procesamiento de las señales electroencefalográficas (EEG), descubiertas por Hans Berger en el año 1929 (Shipton, 1975). Dentro de las principales aplicaciones de las BCI, se encuentra la rehabilitación de movilidad de pacientes que hayan sufrido accidentes cerebrovasculares, apoyado por exoesqueletos de las extremidades corporales o robots guías de dos dimensiones (2D) con el fin de cerrar el circuito sensorial-motor y así restaurar la función motora (Xu, 2016; Irimia, 2016; Qin, 2019; Lisi, 2016).

En Colombia, a través del Registro de Localización y Caracterización de Personas con Discapacidad (RLCPD), desde el 2002 al 2017 se han registrado 1.342.222 personas con algún tipo de discapacidad, donde aproximadamente el 34% de ellos presenta problemas de movilidad de sus extremidades superiores o inferiores (MinSalud, 2017). En el cual, muchos de los problemas de función motora de los pacientes son causados por accidentes cerebro-vasculares, enfermedades neurodegenerativas, traumas de accidente, entre otros. Por lo que, estas personas deben realizar un proceso de rehabilitación motora que integre diferentes estrategias de rehabilitación, entre las que se encuentra el entrenamiento motor activo (AMT), donde el paciente debe utilizar la actividad motora remanente en las extremidades afectadas para emular el movimiento (Quiles, 2020). Teniendo en cuenta los casos de pacientes que no cuentan con los remanentes de actividad motora, se opta por apoyar su proceso de rehabilitación con la técnica de Imaginación de Movimiento



(Motor Imagery, MI), la cual consiste en la evocación de un movimiento, donde se busca una activación cerebral similar a la ejecución del mismo, siendo esta una alternativa de rehabilitación eficaz (Gordleeva, 2017).

Es así como en este trabajo, se propone controlar un modelo a escala de un exoesqueleto de miembros inferiores, a través del procesamiento de señales EEG adquiridas por un sistema BCI. Para esto, el usuario debe imaginar el movimiento de la extremidad inferior correspondiente (pierna izquierda o derecha) que desee ejecutar, la señal de EEG es procesada de tal forma que se puede clasificar entre el miembro inferior izquierdo o derecho según la intención inicial del usuario. Para determinar esta intención de movimiento, se utiliza el algoritmo de máquina de vector de soporte como clasificador, donde se busca diferenciar la respuesta neuronal del cerebro entre dos patrones generados por el usuario, el movimiento del miembro inferior derecho e izquierdo.

Este artículo está estructurado de la siguiente manera: sección 1 introducción, sección 2 materiales y métodos; sección 3. resultados y discusión; y finalmente, sección 4, conclusiones.

2. Materiales y métodos

2.1. Protocolo de experimentación

El protocolo de experimentación diseñado tiene como objetivo evocar las señales de MI del usuario correspondiente a sus extremidades inferiores. Este protocolo fue implementado en el software OpenVIBE y funciona de la siguiente manera: Primero se otorgan 10 s de preparación con el fin de que el usuario adquiera una posición cómoda para realizar la prueba, luego se presenta en la pantalla la imagen de una cruz de color verde durante 1 s la cual simboliza el inicio de la prueba, seguido se presenta durante 3 s de manera pseudoaleatoria la imagen de un pie ya sea el izquierdo o el derecho indicando al usuario la MI que debe de generar, finalmente se proyecta en pantalla el mensaje "Descanso" con una duración de 5 s, tiempo en el cual el usuario podrá descansar y prepararse para ejecutar la siguiente instrucción. El proceso descrito anteriormente es repetido diez veces por sesión como se puede apreciar en la en la *Figura 2.A*. Este protocolo es utilizado tanto en pruebas de MI como de movimiento activo y se realizan cinco sesiones por participante de las cuales tres de ellas corresponden a pruebas de MI y dos de movimiento activo, como se muestra en la *Figura 2.B*.

Para la toma de los datos dos participantes masculinos, sanos y en un rango de edad de 22 a 25 años fueron instruidos para iniciar el proceso de prueba, en el cual debían realizar las instrucciones proyectadas en un ordenador a partir de su MI (ver *Figura 1*), proceso en el cual el usuario debía estar lo más cómodo y concentrado posible para realizar la correcta MI de la extremidad inferior indicada.





Figura 1. Sesión de experimentación de los dos participantes.

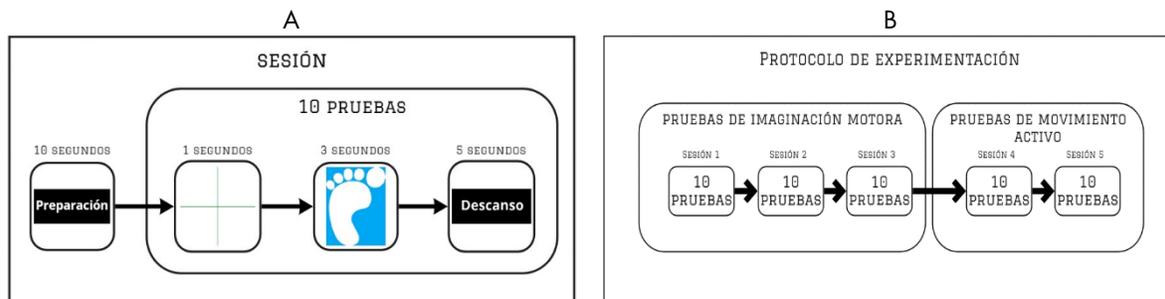


Figura 2. A: Diagrama del protocolo de experimentación por sesión, B: Diagrama del protocolo de experimentación de cada participante.

2.2. Adquisición de señales EEG

Las señales EEG son adquiridas a través del sistema g.Nautilus 16 Research de la compañía g.tec (g.tec), el cual cuenta con 16 canales EEG y 2 tierras, los 16 canales utilizados para la adquisición de las señales EEG fueron posicionados en FP1, FP2, F3, F4, Fz, T7, T8, C3, C4, Cz, P3, P4, Pz, PO7, PO8, Oz, según el sistema internacional 10-20 (Abdulkader, 2015). El sistema g.Nautilus Research está configurado con un filtro pasa banda de 0.3 a 50 Hz, un filtro notch a 60 Hz con el fin de eliminar la interferencia de la red eléctrica, una resolución de 2250000 μV y una frecuencia de muestreo de 250 Hz. Como parte de la preparación para la adquisición de las señales EEG, se configura y verifica que la impedancia de cada electrodo sea $\leq 10 \text{ K}\Omega$, esto se hace con la ayuda de una de las herramientas de g.tec llamada g.NEEDacces-Demo Client (g.tec). Posteriormente con la ayuda del software OpenVIBE, el protocolo de experimentación descrito anteriormente y la unión con el sistema g.Nautilus Research se registra y almacena las señales EEG de cada participante en un archivo con extensión CSV.

2.3. Preprocesamiento de las señales EEG

Para realizar el preprocesamiento de las señales EEG previamente adquiridas en el archivo con extensión CSV, se realiza el siguiente procedimiento: Primero, se utiliza el canal Pz como referencia de la señal con el resto de canales, lo que genera que las unidades de la amplitud sean adimensionales, posteriormente las señales EEG pasan a través de un filtro pasa bajas Butterworth de cuarto orden con una frecuencia de corte de 45 Hz y una frecuencia de muestreo de 250 Hz. Una vez las señales son filtradas, estas son separadas en dos grupos de señales (MI izquierdo y



MI derecho) por canal, de acuerdo a un identificador asignado en la etapa de adquisición de las señales EEG. La separación de la señal adquirida permite procesar únicamente las señales de EEG con su respectivo MI evocados por el usuario, eliminando los periodos de preparación, inicio de prueba y descanso. Finalmente, a los dos grupos de señales EEG se normalizan y se pasan del dominio temporal al frecuencial, utilizando Transformada Rápida de Fourier (FFT) con el fin de saber su potencia espectral (Planelles, 2014).

2.4. Procesamiento de las señales EEG y extracción de características

Se extraen los ritmos cerebrales Delta, theta, Alfa y Beta por medio de un filtro pasa bandas Butterworth de cuarto orden, cuyas frecuencias de corte dependen del rango de frecuencias de cada ritmo como se observa en la *Tabla 1*. Luego, se calcula la energía promedio de cada subbanda de cada canal, y se extraen patrones de energía característicos al movimiento del miembro inferior izquierdo o derecho calculando índices de asimetría entre electrodos complementarios (FP1-FP2, F3-F4, C3-C4, P3-P4, T7-T8, PO7-PO8). Los resultados de estos índices se almacenan en una matriz de Nx6, donde el valor de N depende de la cantidad de pruebas realizadas por la cantidad de subbandas trabajadas.

Tabla 1. Rango de frecuencias de los ritmos cerebrales.

Ritmo	Delta	Theta	Alfa	Beta
Frecuencia (Hz)	0.5 - 4	4 - 7	8 - 13	14 - 30

El procedimiento de la sección 2.3 y 2.4 se realiza tomando una muestra o pequeños grupos de datos con el fin de evidenciar la separabilidad de la MI izquierda y MI derecha tanto en pequeños y grandes grupos de datos, cabe destacar que este proceso se realiza a todos los datos y todos los canales.

2.5. Clasificador SVM

Para implementar el clasificador SVM se crea una matriz de características a partir de los ritmos procesados de las señales EEG-MI y un vector de etiquetas de ceros y unos referidos a MI izquierda y MI derecha respectivamente. Una vez se tienen los datos organizados se realiza la gráfica de la figura 7 donde a través de un análisis visual es posible deducir que tipo de kernel ideal para utilizar en el clasificador a implementar, es el kernel de Función de Base Radial (RBF), debido a que este genera un hiperplano de separación adecuada, conforme a la distribución de los datos en el espacio (Benítez, 2014). Con el fin de tener mejores resultados de clasificación, se optimizan los parámetros del clasificador utilizando la función "GridSearchCV" "estos parámetros son optimizados mediante una búsqueda de cuadrícula con validación cruzada sobre una cuadrícula de parámetros" (scikitlearn), finalmente se realiza el entrenamiento y se verifican los resultados de clasificación a través de las métricas de clasificación y matrices de confusión, esto gracias a las herramientas de Python tales como: `confusion_matrix` y `classification_report` proporcionada por la biblioteca "sklearn.metrics".

El proceso descrito en los numerales 2.3, 2.4 y 2.5 se puede observar en el esquema de la *Figura 3*.



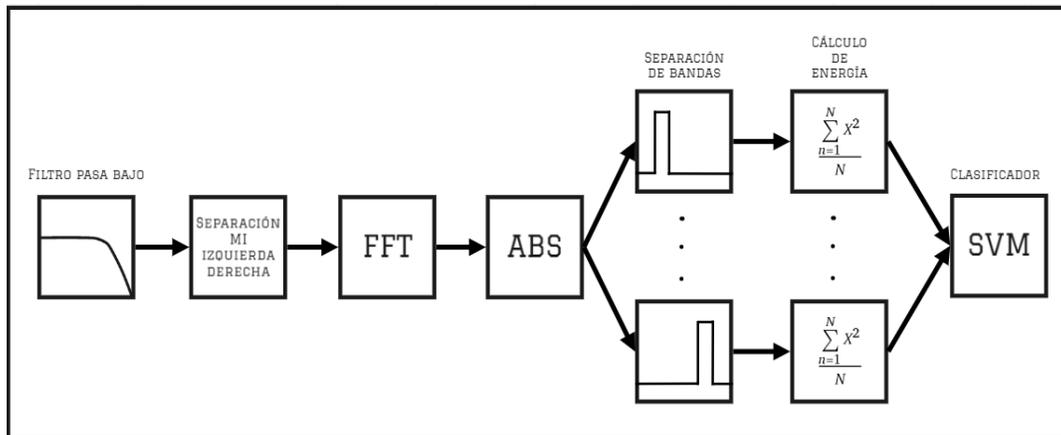


Figura 3. Descripción general de la etapa de procesamiento y clasificación del sistema.

2.6. Exoesqueleto

En el programa de ingeniería electrónica de la universidad del Quindío, se realizó un prototipo a escala funcional de un exoesqueleto basado en la plataforma CPWalker. Este dispositivo tiene los componentes principales de la plataforma original los cuales son el exoesqueleto y el smart-walker (Medina Lee, 2018).

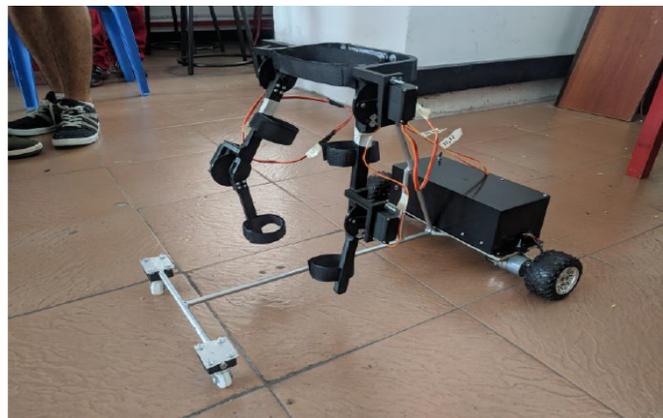


Figura 4. Exoesqueleto basado en CPWalker realizado en la Universidad del Quindío (Medina Lee, 2018).

El exoesqueleto cuenta con dos grados de libertad en cada pierna, uno en la cadera y el otro en la rodilla, cada articulación o grado de libertad cuenta con un servomotor de alto torque, todas las piezas del exoesqueleto son impresas en 3D y la separación entre las piernas es ajustable en cuatro niveles.

- Servomotores torque de 9 Kg/cm controlado con PWM.
- peso liviano.

El sistema de control del exoesqueleto a través de señales EEG está programado en Python y C++ en el IDE de Arduino, donde en Python se realiza todo el proceso de preprocesamiento, procesamiento y clasificación de las señales EEG adquiridas, en el proceso de clasificación de la MI izquierda o derecha se etiqueta con 0 para MI izquierda y 1 para MI derecha, por lo cual el



resultado de clasificación será uno de estos valores (0 o 1), este valor será enviado a una tarjeta Arduino Uno a través de una interfaz serial, para posteriormente en el IDE de Arduino elaborar un script el cual realiza el proceso de recepción, el dato recibido será comparado con el fin de identificar si el exoesqueleto realizará un movimiento de la extremidad izquierda o derecha.

3. Resultados

A partir del protocolo de experimentación propuesto se recolectan y almacenan los datos en CSV, los cuales fueron posteriormente importados para su análisis, donde a uno de estos archivos se le toma una muestra de las señales EEG almacenadas, con el fin de realizar un análisis de las características de energía de los ritmos cerebrales (delta, theta, alfa y beta) el cual permite observar cómo estos ritmos varían su nivel de energía dependiendo de la MI generada por el usuario, las características de energía resultantes presentadas en la *Tabla 2* corresponden a la muestra de la señal del canal C3 y en la figura 6 se puede observar la muestra de señal EEG usada para este análisis.

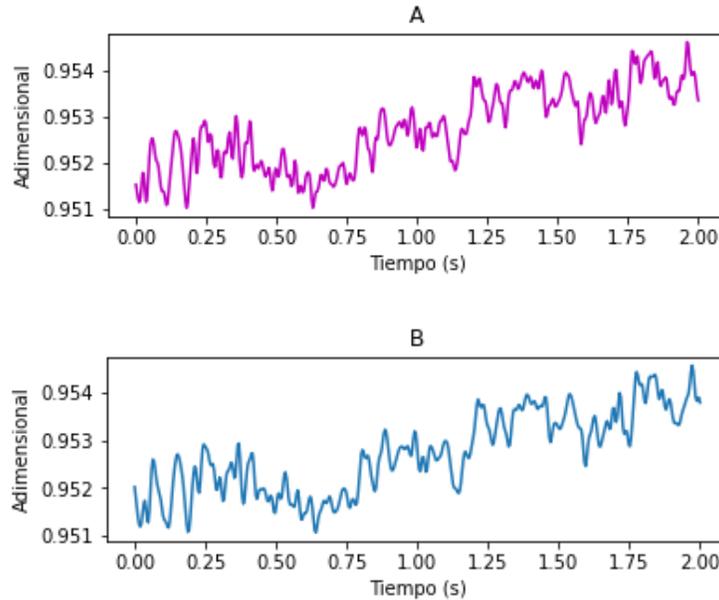


Figura 5. Señal normalizada del canal C3 donde la señal de A corresponde a la señal pura del canal, y B corresponde a la señal normalizada del canal filtrado con un filtro pasa bajo de cuarto orden.

Tabla 2. Energías del canal C3.

Ritmos	energía MI derecha (Adimensional)	Energía MI izquierda (Adimensional)
Delta	25.58935372125831	26.00286735723764
Theta	22.60488753325754	22.96783861246577
Alfa	30.89305999465862	31.38451227103649
Beta	117.6021041075697	119.42388376279627



Después de analizar las características de los ritmos y evidenciar que existe una diferencia en los niveles de energía de la muestra seleccionada, se procede a realizar una resta o diferencia entre los electrodos complementarios (ver *Figura 6*), la cual se realiza para evidenciar que entre ellos exista una separabilidad entre MI izquierda y MI derecha.

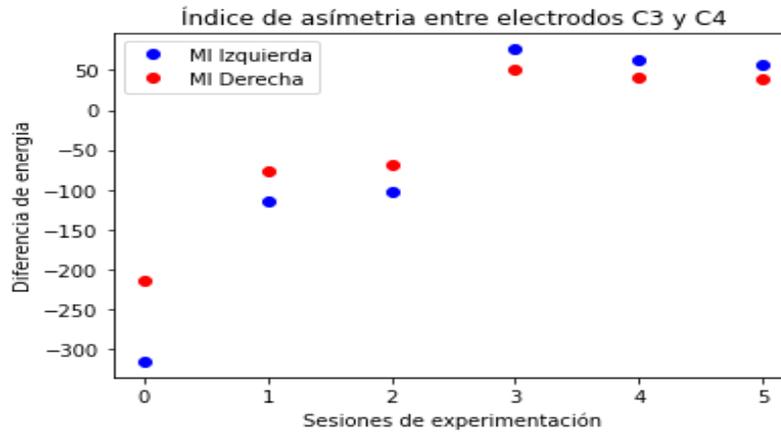


Figura 6. Diferencia niveles de energía entre el electrodo C3 y C4, los puntos azules corresponden a la MI Izquierda y los rojos a MI Derecha. Esta diferencia de electrodos complementarios fue realizada a toda la señal de los electrodos C3 y C4 de seis (6) sesiones.

Para este caso se implementa un clasificador SVM con un kernel "RBF" debido a que los datos recolectados (*Figura 6*) se están interpolando y este kernel fue diseñado para este tipo de casos, por lo cual este es el más indicado para generar un hiperplano de separación adecuado (Bishop, 2006); este análisis se hizo partiendo de la observación de la distribución de los datos presentados en la *Figura 6*.

Como se mencionó en la sección 2.5, la función "GridSearchCV" fue utilizada para estimar los mejores parámetros del clasificador, donde finalmente son obtenidos los siguientes parámetros para entrenar el clasificador SVM: SVC(C= 200000.0, cache_size= 1000, class_weight= 'balanced', decision_function_shape= 'ovr', gamma= 2e-05, kernel = 'rbf', tol= 0.001). Una vez diseñado el clasificador se procede a realizar la etapa de entrenamiento partiendo de la función "train_test_split" la cual separa los datos en conjuntos de entrenamiento y de prueba, donde el clasificador se entrena con el conjunto de datos de entrenamiento y se valida con el conjunto de dato de prueba. En la *Tabla 3* y *Tabla 4* se presentan los datos del reporte de clasificación el cual permite observar importantes parámetros como lo son la precisión, exactitud, sensibilidad y otros, con los cuales es posible determinar la calidad del clasificador.

Tabla 3. Reporte de clasificación con datos de entrenamiento.

	Precision	Recall	F1-score	Support
Izquierda	0.97	1.00	0.99	38
Derecha	1.00	0.98	0.99	51
Accuracy			0.99	89



Tabla 4. Reporte de clasificación con datos de prueba.

	Precision	Recall	F1-score	Support
Izquierda	1.00	0.89	0.94	18
Derecha	0.71	1.00	0.83	5
Accuracy			0.91	23

En la *Tabla 3* y *Tabla 4*, se observa el reporte de clasificación donde se pueden observar las métricas más relevantes a la hora de evaluar la eficiencia de un clasificador, también indica la cantidad de datos o características utilizados tanto en entrenamiento como en prueba siendo ochenta y nueve (89) y veintitrés (23) respectivamente, esta figura está dividida en dos secciones, la primera sección hace referencia a la etapa en la que el modelo es entrenado a partir del conjunto de datos de entrenamiento, donde es posible observar que los resultados de entrenamiento del clasificador altamente confiables con unos porcentajes de clasificación F1-score y exactitud del 99%. La segunda sección hace referencia a la etapa de validación, en la que el modelo debe de predecir la MI del usuario a partir del conjunto de señales de prueba, en donde se puede observar que el modelo presenta un 71% de precisión en la detección de la MI izquierda y un 89% en la sensibilidad de detección de la MI derecha, aun así los resultados en F1-score siguen siendo superiores al 80% y una exactitud del 91% de la clasificación de las MI lo que genera una alta confiabilidad en el modelo obtenido.

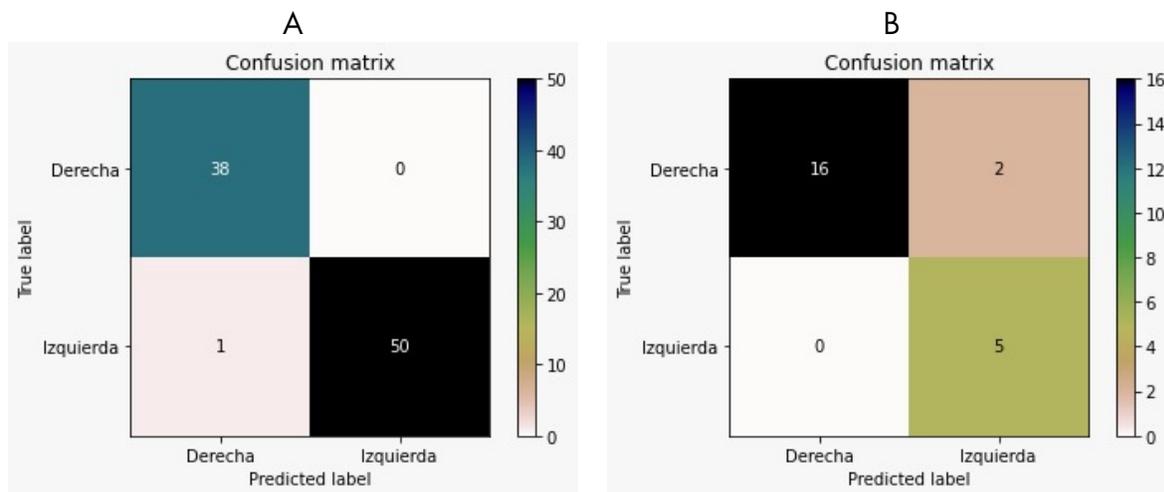


Figura 7. Matriz de confusión de entrenamiento (A) y prueba (B).

En la *Figura 7*, se observan dos imágenes, la imagen A corresponde a la matriz de confusión que se obtuvo al momento de realizar el entrenamiento del clasificador se tiene como resultados tasas de TP = 100%, TN = 98.04%, FP = 0% y FN = 1.96%; la imagen B corresponde a la matriz de confusión obtenida al momento de utilizar los datos de prueba en el clasificador, en este se obtiene una tasa de TP = 88.9%, TN = 100%, FP = 11.1% y FN = 0%. Por lo cual, los resultados de las matrices de confusión soportan los resultados de las métricas obtenidas en la *Figura 7*.



4. Conclusiones

En este artículo, se propone un sistema BCI que permita la adquisición de las señales EEG con el objetivo de controlar un exoesqueleto a escala de miembros inferiores a través de la MI. Para esto, la señal EEG es analizada y procesada de tal manera que sea posible separar los movimientos de MI izquierda y derecha, para luego analizar las características energéticas en los ritmos cerebrales (*Tabla 1*). A partir de esto un clasificador SVM fue diseñado con el fin de realizar las predicciones de dicha MI, donde debido a la distribución de los datos los cuales se interpolan en algunos casos se opta por usar el kernel RBF el cual fue diseñado para este tipo de problemas, por lo cual el entrenamiento del clasificador SVM solo se pudo realizar con el kernel RBF ya que con los kernels LINEAR, SIGMOID y POLY el clasificador convergía.

En este artículo no se presentan resultados con el exoesqueleto visto en la *Figura 4*, debido a que este proyecto aún se encuentra en etapa de desarrollo, donde hasta ahora se ha trabajado hasta la etapa de predicción de los datos con el clasificador SVM, pero se desea probar con otros clasificadores tales como redes neuronales y LDA para finalmente poner a prueba el clasificador con mejores resultados en la detección de un movimiento y que este se vea reflejado en el exoesqueleto, el cual se realizará mediante una comunicación serial desde el entorno de desarrollo de Python hacia una tarjeta Arduino Uno.

5. Referencias

- Abdulkader, S. N.-S. (2015). Brain computer interfacing: Applications and challenges. *Egyptian Informatics Journal*, 213–230.
- Benítez, R. a. (2014). Inteligencia artificial avanzada. *Editorial UOC*, 214.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- g.tec. (s.f.). g.tec. Obtenido de g.tec, BRAIN-COMPUTER INTERFACE & NEUROTECHNOLOGY: www.gtec.at/
- Gordleeva, S. Y. (2017). Exoskeleton control system based on motor-imaginary brain-computer interface. *Современные технологии в медицине*, 3.
- Irimia, D. C. (2016). Controlling a FES-EXOSKELETON rehabilitation system by means of brain-computer interface. *2016 International Conference and Exposition on Electrical and Power Engineering (EPE)*, 352–355.
- Lisi, G. a. (2016). Dry-wireless EEG and asynchronous adaptive feature extraction towards a plug-and-play co-adaptive brain robot interface. *2016 IEEE International Conference on Robotics and Automation (ICRA)*, 959–966.
- Medina Lee, o. (2018). *Prototipo a escala funcional de un exoesqueleto basado en la plataforma. Armenia-Quindío*.
- MinSalud. (2017). *Sala situacional de las Personas con Discapacidad (PCD)*.
- Planelles, D. a. (2014). Evaluating classifiers to detect arm movement intention from EEG signals. *Sensors*, 18172–18186.
- Qin, Z. a. (2019). econhand: A wearable brain-computer interface system for stroke rehabilitation. *2019 9th International IEEE/EMBS Conference on Neural Engineering (NER)*, 734–737.
- Quiles, E. a.-K. (2020). Low-Cost Robotic Guide Based on a Motor Imagery Brain-Computer Interface for Arm Assisted Rehabilitation. *International journal of environmental research and public health*, 699.



- scikitlearn. (s.f.). *scikit-learn.org*. Obtenido de https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.GridSearchCV.html
- Shipton, H. W. (1975). EEG analysis: A history and a prospectus. *Annual review of biophysics and bioengineering*, 1-13.
- Xu, R. a.-K. (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*, 527.

Sobre los autores

- **Sebastián Cardona Castro**, Estudiante de ingeniería electrónica, Universidad del Quindío, scasdonac@uqvirtual.edu.co
- **Diego Alejandro Ramírez Marroquín**, Estudiante de ingeniería electrónica, Universidad del Quindío, daramirezm_2@uqvirtual.edu.co
- **Catalina Aguirre Grisales**. Ingeniera Electrónica, Universidad del Quindío. Magister en Ingeniería Eléctrica, Universidade Federal do Rio Grande do Sul UFRGS. Candidata a Doctora, Universidad Autónoma de Manizales. caaguirre@uniquindio.edu.co

Los puntos de vista expresados en este artículo no reflejan necesariamente la opinión de la Asociación Colombiana de Facultades de Ingeniería.

Copyright © 2021 Asociación Colombiana de Facultades de Ingeniería (ACOFI)

