

CARACTERIZACIÓN Y CLASIFICACIÓN DE SEÑALES ELECTROENCEFALOGRÁFICAS PARA APLICACIONES DE INTERFAZ CEREBRO-COMPUTADOR



WILMER CASTRO

**UNIVERSIDAD DE NARIÑO
FACULTAD DE INGENIERIA
DEPARTAMENTO DE INGENIERIA ELECTRONICA
SAN JUAN DE PASTO
2019**

**CARACTERIZACIÓN Y CLASIFICACIÓN DE SEÑALES
ELECTROENCEFALOGRÁFICAS PARA APLICACIONES
DE INTERFAZ CEREBRO-COMPUTADOR**

WILMER CASTRO

**TRABAJO DE GRADO PARA OPTAR EL TÍTULO DE INGENIERO
ELECTRÓNICO**

**ASESOR
PhD. DIEGO HERNAN PELUFFO ORDOÑEZ
INGENIERO ELECTRÓNICO**

**UNIVERSIDAD DE NARIÑO
FACULTAD DE INGENIERÍA
DEPARTAMENTO DE INGENIERÍA ELECTRÓNICA
SAN JUAN DE PASTO
2019**

NOTA DE RESPONSABILIDAD

“La Universidad de Nariño no se hace responsable por la opiniones o resultados obtenidos en el presente trabajo y para su publicación priman las normas sobre el derecho de autor.”

Acuerdo 1. Artículo 324. Octubre 11 de 1966, emanado del honorable consejo directivo de la Universidad de Nariño.

NOTA DE ACEPTACIÓN

Firma del presidente del jurado

Firma del jurado

Firma del jurado

San Juan de Pasto, 17/05/19

DEDICATORIA

A Dios dedico este triunfo, su bondad permitió que pudiera cumplir el sueño de ser un ingeniero, me llenó de fortaleza y me levanto en los momentos más difíciles, a él toda la gloria. A mi madre por ser ese motor y fuente de inspiración, gracias por todo el apoyo brindado, tú me motivas para convertirme cada día en mi mejor versión.

AGRADECIMIENTOS

Agradezco a todas las personas que de una u otra manera aportaron su grano de arena para que este trabajo finalmente rindiera frutos. A mi asesor Diego Hernán Peluffo por confiar y creer en mí, su asesoría ha culminado pero mi amistad y agradecimientos serán para siempre. A Camilo Andrés Piñeros por la colaboración brindada en esta última etapa. A las señoritas Karolina Puerres y Liliana Coral, su apoyo fue de vital importancia en los momentos finales de este proceso. A la Universidad de Nariño, mi segundo hogar, gracias por todos estos años de continuo aprendizaje.

RESUMEN

Desde su primera aplicación, la electroencefalografía ha sido una técnica usada fundamentalmente para lograr comprender el comportamiento del cerebro. Estudiando las señales electroencefalográficas (EEG) se ha tratado de descifrar las intenciones de una persona y las acciones que pueda ejercer sobre ciertos dispositivos solo con imaginarlo. Este concepto es lo que se conoce como interfaz cerebro-computador o BCI, sistemas que actualmente se usan con gran expectativa en personas dependientes o con alto grado de discapacidad, dado que se presenta como una nueva forma de comunicación, logrando que individuos con parálisis parcial o total de sus extremidades puedan realizar tareas como: escribir en un monitor, desplazarse en una silla de ruedas, manejar prótesis entre otras.

La función básica de un sistema BCI es medir las señales eléctricas provenientes del cerebro, procesarlas, extraer características y permitir que el usuario interactúe con el entorno por medio de un dispositivo físico. La extracción de estas características conlleva a un análisis profundo de la señal EEG a fin de encontrar patrones característicos, es decir aquellos relacionados con las intenciones del usuario y que serán usados como comandos de salida. Es aquí donde aún se ve restringida la eficiencia de un sistema BCI, debido a que las señales EEG al momento de ser adquiridas son afectadas por ruido y artefactos, además de presentar una baja resolución espacial, evitando una correcta caracterización de los fenómenos fisiológicos y derivando en extenuantes horas de entrenamiento por parte del usuario antes de efectuar de manera precisa las intenciones que desea realizar.

En este proyecto de grado se propuso una metodología alternativa que permitió analizar y procesar señales EEG con propósitos aplicativos en sistemas BCI. Para ello se desarrolló un proceso comparativo de diferentes métodos de caracterización, selección de características y reducción de dimensión, a fin de determinar un modelo de clasificación de señales EEG equilibrado entre eficacia y coste computacional.

ABSTRACT

Since its first application, electroencephalography has been a technique used primarily to understand the behavior of the brain. Studying the electroencephalographic (EEG) signals has tried to decipher the intentions of a person and the actions that can be exercised on certain devices just by imagining it. This concept is what is known as a brain-computer interface or BCI, systems that are currently used with great expectation in people with disabilities or with a high degree of disability, given that it is presented as a new form of communication, making individuals with partial paralysis or total of their limbs can perform tasks such as: write on a monitor, move in a wheelchair, handle prosthesis among others.

The basic function of a BCI system is to measure the electrical signals coming from the brain, process them, extract characteristics and allow the user to interact with the environment through a physical device. The extraction of these characteristics leads to a deep analysis of the EEG signal in order to find characteristic patterns, that is, those related to the user's intentions and that will be used as output commands. This is where the efficiency of a BCI system is still restricted, because the EEG signals at the moment of being acquired are affected by noise and artifacts, besides presenting a low spatial resolution, avoiding a correct characterization of the physiological phenomena and deriving in strenuous hours of training by the user before accurately performing the intentions you want to perform.

In this work an alternative methodology is proposed that allows to analyze and process EEG signals for application purposes in BCI systems. For this, a comparative process of different characterization methods, feature selection and dimension reduction was developed, in order to determine a model of EEG signal classification balanced between efficiency and computational cost.

CONTENIDO

Introducción	14
Descripción del problema	17
Planteamiento del problema	17
Justificación	17
Contribución de esta tesis	18
Organización del documento	18
Objetivo general	19
Objetivos específicos.....	19
Marco teórico	19
La neurona	20
Estructura de una neurona	20
Potencial de acción	21
Registro de la actividad cerebral	23
Magnetoencefalografía (MEG)	24
Electrocorticografía (ECoG)	24
Electroencefalografía (EEG).....	24
Señales EEG	25
Ondas o ritmos EEG	26
Ruido y artefactos	27
Sistema 10-20	28
Montajes.....	29
Interfaz cerebro computador (BCI)	31
Configuración BCI	31
Adquisición	32
Preprocesado	32
Caracterización	32
Selección de características.....	35
Clasificación	36
1. DESARROLLO DE LA INVESTIGACIÓN.....	38

1.1	SEÑALES EEG.....	38
1.2	PREPROCESAMIENTO.....	39
1.2.1	Filtrado	39
1.2.2	Supresión de artefactos.....	40
1.2.3	Selección de canales.....	41
1.2.4	Normalización.....	42
1.2.5	Segmentación	42
1.3	CARACTERIZACIÓN.....	43
1.3.1	Descomposición en coeficientes wavelet	43
1.3.2	Extracción de características.....	47
1.3.3	Selección de características	48
1.4	CLASIFICACIÓN	49
2.	MARCO EXPERIMENTAL	50
2.1	EVALUACION Y MEDIDAS DE DESEMPEÑO	50
2.2	PRUEBAS APLICADAS AL VECTOR DE CARACTERISTICAS.....	51
3	RESULTADOS	53
4	CONCLUSIONES Y TRABAJO FUTURO	64
	BIBLIOGRAFÍA.....	66
	ANEXOS	72
	ANEXO 1. Código fuente para la caracterización y clasificación de señales EEG para aplicaciones de interfaz cerebro computador BCI.	72
	ANEXO 2. Artículo enviado y aprobado para socialización en las III Jornadas Internacionales de investigación FICA de la Universidad Técnica del Norte en Ibarra-Ecuador.....	83
	ANEXO 3. Certificado de participación como ponente en las III jornadas internacionales FICA en la UTN	88
	ANEXO 4. Certificado de participación como ponente en el evento Datavis Day de la Universidad Autónoma de Nariño.	88

LISTA DE FIGURAS

Figura 1: Funcionamiento del electroencefalograma.	15
Figura 2. Interfaz cerebro-computador (BCI).....	16
Figura 3 La neurona.....	20
Figura 4 Potencial de acción de la neurona	23
Figura 5 Señales EEG	26
Figura 6. Ondas o ritmos EEG.	26
Figura 7. Sistema internacional 10-20.....	28
Figura 8. a) Montaje bipolar. b) montaje unipolar o referencial.	29
Figura 9. Montaje bipolar longitudinal con tres tipos de arreglo para las derivaciones.....	30
Figura 10. Montaje bipolar transversal con dos maneras de arreglo para las derivaciones.....	30
Figura 11. Diagrama de bloques del funcionamiento básico de una BCI.	32
Figura 12. Transformación de una señal del dominio temporal al espectral.	33
Figura 13. Metodología para la caracterización y clasificación de señales EEG...	38
Figura 14. Artefacto producido por parpadeo o movimiento ocular.....	40
Figura 15. Artefacto producido por señal ECG.....	41
Figura 16. Selección de canales	42
Figura 17. Distribución de eventos en las señales.	43
Figura 18. a) Wavelets Coiflets. b) Wavelets Daubechies.	44
Figura 19 Descomposición en niveles wavelet.	45
Figura 20. Descomposición wavelet en 4 niveles usando Coif 4, donde S es la señal y a y d son los coeficientes de aproximación y detalle respectivamente.	46
Figura 21. Relación entre ondas Alfa y beta y coeficientes de detalle.	47
Figura 22. Matriz de características y vector de etiquetas.	48
Figura 23. Gráfica de comportamiento de los clasificadores con la rutina 1.	61
Figura 24. Gráfica de comportamiento de los clasificadores con la rutina 2.	62
Figura 25 Error de clasificación para la rutina 1.....	62
Figura 26 Error de clasificación para la rutina 2.	63

LISTA DE TABLAS

Tabla 1 Comparación entre MEG, ECoG y EEG	25
Tabla 2. Rutinas experimentales para la adquisición de las señales EEG.	39
Tabla 3. Coeficientes de aproximación y detalle.	46
Tabla 4. Matriz de confusión.....	50
Tabla 5. Medidas de desempeño usando coif2 y SVM.....	53
Tabla 6. Medidas de desempeño usando coif4 y SVM.....	54
Tabla 7. Medidas de desempeño usando db2 y SVM.	54
Tabla 8. Medidas de desempeño usando db4 y SVM	55
Tabla 9. Medidas de desempeño usando coif2 y Clasificador Fisher.....	55
Tabla 10. Medidas de desempeño usando coif4 y Clasificador Fisher.....	56
Tabla 11. Medidas de desempeño usando db2 y Clasificador Fisher.	56
Tabla 12. Medidas de desempeño usando db4 y Clasificador Fisher.	57
Tabla 13. Medidas de desempeño usando coif2 y Clasificador Logístico.	57
Tabla 14. Medidas de desempeño usando coif4 y Clasificador Logístico.	58
Tabla 15. Medidas de desempeño usando db2 y Clasificador Logístico.	58
Tabla 16. Medidas de desempeño usando db4 y Clasificador Fisher.	59
Tabla 17. Mejores desempeños de los clasificadores para los eventos de la rutina 1.....	59
Tabla 18. Mejores desempeños de los clasificadores para los eventos de la rutina 2.....	60

GLOSARIO

BCI: Interfaz cerebro-computador.

Machine learning o Aprendizaje automático: Conjunto de algoritmos computacionales que permite que las maquinas aprendan de la experiencia.

Aprendizaje supervisado: conjunto de algoritmos de machine learning que permiten entrenar un sistema, a fin de que pueda hacer predicciones basados en experiencia o datos previamente etiquetados.

Aprendizaje no supervisado. Algoritmos de machine learning que permiten el agrupamiento de datos con características similares.

Clase: Agrupación de objetos que tiene características comunes.

Características: Se refiere a los atributos que describen las instancias del conjunto de datos.

Algoritmo: Conjunto definido de reglas o procesos que llevan a la solución de un problema en un número determinado de pasos.

Pre-procesamiento: Es un proceso donde se filtra información de las bases de datos usando diferentes mecanismos como el filtraje, normalización, entre otros.

Selección de características: Hace referencia al proceso de elegir información relevante de un conjunto de datos

Dimensión: En términos generales la dimensión de una base de datos es definida como la cantidad de mediciones, características o atributos tiene cada registro.

INTRODUCCIÓN

Las enfermedades neuromusculares o neurológicas degenerativas como la Distrofia Muscular y la Esclerosis Lateral Amiotrófica, son afecciones crónicas que generan gran discapacidad de la autonomía personal y que aún no disponen de tratamientos efectivos ni cura definitiva limitando físicamente a aquellas personas que las padecen. Se presentan en cualquier etapa de la vida y sus efectos en la mayoría de los casos, perduran para siempre. Su principal característica es la afección de los nervios que controlan los músculos voluntarios como es el caso de brazos y piernas, y se originan cuando las células nerviosas también llamadas neuronas, se enferman o mueren interrumpiendo la comunicación entre el sistema nervioso y los músculos. Aunque el movimiento de extremidades sea nulo o casi nulo, la actividad cerebral se mantiene normal provocando pequeños potenciales eléctricos^{1 2}.

En los últimos años las investigaciones se han centrado en el desarrollo de técnicas que permitan leer y comprender estos potenciales a fin de descifrar el comportamiento del cerebro. Algunas de estas técnicas como la resonancia magnética funcional (fMRI), la Tomografía por emisión de positrones (PET) y la espectroscopia por infrarrojo cercano funcional (fNRI) se basan en la obtención de imágenes del lugar donde se origina la actividad cerebral, otras como la magnetoencefalografía (MEG) se basan en el registro del campo magnético, y están la Electroencefalografía (ECoG) y la electroencefalografía (EEG) que obtienen registros del potencial eléctrico del cerebro³.

La EEG es la técnica de mayor uso en el registro de la actividad cerebral debido a su fácil acceso y bajo costo comparado con las técnicas de registro de imágenes o de campo magnético, además de no requerir de métodos quirúrgicos e invasivos como la ECoG, que implanta los electrodos directamente en la superficie del cerebro, aumentando el riesgo de provocar una infección durante su prolongado contacto. La EEG permite el registro de la actividad eléctrica originada por las neuronas cerebrales, por medio de electrodos ubicados de manera estándar sobre el cuero cabelludo y siguiendo una denominación internacional, de tal forma que los

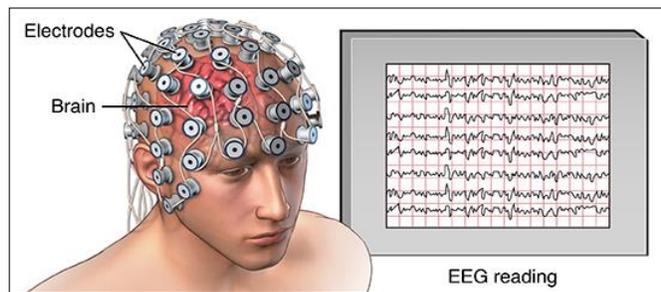
¹ SERRANO, J. Ignacio, DEL CASTILLO, M. Dolores, RAYA, Rafael, BAYÓN, Cristina, ROCON, Eduardo. *BCI basado en la facilitación asociativa de la actividad cortical para el inicio de la marcha en Parálisis Cerebral*. En: Cognitive Area Networks. Vol. 2, No 1 (Junio. 2015); p. 31-34.

² UBEDA, Andrés, AZORIN, José M., RAYA, Rafael, CERES, Ramón, BRUNETTI, Fernando, NUNES, Margarita, AZEVEDO, Luis. *Plataforma iberada de acceso alternativo al computador para personas con discapacidad*. En: Cognitive Area Networks. Vol. 2, No 1 (Junio. 2015); p. 9-14.

³ GUTIERREZ MARTINEZ, Josefina, CANTILLO NEGRETE, Jessica, CARIÑO ESCOBAR, Ruben, ELIAS VIÑAS, David. *Los sistemas de interfaz cerebro-computadora: una herramienta para apoyar la rehabilitación de pacientes con discapacidad motora*. En: Investigación en discapacidad. Vol. 2, No 2(Mayo-Agosto. 2013); p. 62-69.

registros puedan ser interpretables, reproducibles y comparables en cualquier lugar del mundo. Es una prueba sencilla e indolora, donde se estudia y analiza la diferencia de potencial de los electrodos, así como la frecuencia, amplitud, morfología de su curva y variación con respecto al tiempo a fin de detectar alteraciones en el cerebro⁴.

Figura 1: Funcionamiento del electroencefalograma.



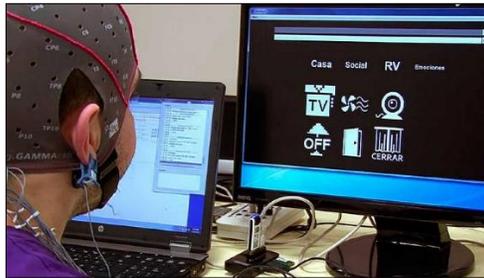
Fuente: Electroencephalogram (EEG). [En línea]. [Consultado: 26 Jul. 2017].
Disponible en: <http://www.saintlukeshealthsystem.org/health-library/electroencephalogram-eeeg>.

Desde que se aplicó por primera vez, la EEG ha sido para médicos y científicos un procedimiento indispensable que ayuda a diagnosticar trastornos y evaluar traumas como: la epilepsia, alzhéimer, narcolepsia, apoplejía y la lesión medular. Facilita la supervisión de pacientes en estado de coma o durante intervenciones quirúrgicas, y permite estudiar el comportamiento del cerebro con el propósito de descifrar pensamientos voluntarios esperando que una persona pueda realizar ciertas acciones a través de dispositivos físicos solamente con imaginarlo. Es así como nace el concepto de interfaz cerebro-computador (*Brain Computer Interface, BCI*), un sistema que a partir de las señales EEG obtiene ciertas características, las procesa y las traduce en comandos de salida permitiendo controlar ciertos dispositivos y convirtiéndose en una nueva alternativa de comunicación con amplias posibilidades para las personas discapacitada⁵. En la figura 2. Se puede observar un sistema básico de interfaz cerebro computador BCI.

⁴ RAMOS ARGUELLES, F., MORALES, G., EGOZCUE, S., PABON, R. M., ALONSO, M. T. *Técnicas básicas de electroencefalografía: principios y aplicaciones clínicas*. En: Sist. Sanit. Navar. No 32 (supl. 3. 2009); p. 69-82.

⁵ SANTANA, D., RAMIREZ, M., OSTROSKY SOLIS, F. *Novedades en tecnología de la rehabilitación: una revisión acerca de la interfaz cerebro-computadora*. En: Revista de Neurología. No 39 (5, 2005); p. 447-450.

Figura 2. Interfaz cerebro-computador (BCI).



Fuente: Ibáñez Álvaro (2013). *BrainAble: un proyecto cerebro-ordenador para personas con discapacidad funcional severa* (23.05.2013). Disponible en: <http://www.rtve.es/noticias/20130523/brainable-proyecto-cerebro-ordenador-para-personas-discapacidad-funcional-severa/669780.shtml>

Durante los últimos años ha crecido el interés científico por los sistemas BCI, vaticinando un futuro con usos y aplicaciones limitadas únicamente por la imaginación de quien quiera emplearlos. Actualmente estos sistemas están presentes en áreas de la robótica, domótica, videojuegos, medicina y la rehabilitación. Como resultado de algunas investigaciones, se ha logrado que personas con capacidades motoras reducidas mejoren su calidad de vida y puedan realizar tareas como escribir en un monitor, seleccionar objetos de una pantalla, desplazarse en una silla de ruedas, controlar electrodomésticos, manejar prótesis entre otras, las cuales se las considera como todo un récord teniendo en cuenta la prematura etapa en la que se encuentra el desarrollo de esta tecnología⁶. Asegurando la comodidad del usuario al momento de registrar la actividad cerebral, la mayoría de sistemas BCI hacen uso de la EEG por ser sencilla, portátil y no invasiva, pero tener estas ventajas representan un enorme sacrificio en la calidad de la señales EEG, puesto que el contacto de los electrodos con el cuero cabelludo las hace propensas a registrar artefactos; señales como las producidas por los latidos del corazón, contracción muscular, movimiento ocular y el parpadeo, además del ruido de la línea de tensión o cualquier otro dispositivo eléctrico presente en el entorno donde se hace la adquisición. El resultado es una señal que necesita de un tedioso y no del todo efectivo proceso de filtrado, causando que la caracterización no sea la adecuada y el acierto al momento de controlar el dispositivo carezca de precisión, requiriendo extenuantes jornadas de entrenamiento por parte del usuario⁷. Aunque existen técnicas que ofrecen aciertos cercanos al 90% al momento de interpretar las intenciones, aún no se dispone de una metodología definitiva que permita una correcta caracterización y clasificación de los fenómenos fisiológicos, siendo este el principal inconveniente al que se enfrentan los sistemas BCI actuales.

⁶ COSTA, Á., Asin-Prieto, G., Shimoda, S., Iáñez, E., Moreno, J. C., Pons, J. L., & Azorin, J. M. Integración de interfaz cerebro-computador y exoesqueleto de miembro inferior orientado a la rehabilitación.

⁷ SANSEI, S., & Chambers, J. A. (2013). *EEG signal processing*. John Wiley & Sons.

En este proyecto de grado se realizó un estudio comparativo de los diferentes métodos de caracterización y clasificación de señales EEG para usos en sistemas BCI, con el fin de determinar el que presente mejor equilibrio entre robustez, efectividad, costo computacional y acierto al momento de discriminar entre diferentes tareas mentales.

DESCRIPCIÓN DEL PROBLEMA

Planteamiento del problema

Las interfaces cerebro-computador son sistemas que permiten a personas con capacidades motoras limitadas, facilitar la ejecución de tareas básicas reduciendo la total dependencia de sus cuidadores o acompañantes. Realizar la adquisición de las ondas cerebrales por medio de EEG requiere de un gran periodo de entrenamiento por parte del usuario a fin de que el sistema aprenda a reconocer sus intenciones. Dado que, este tipo de señales varían significativamente entre cada persona y sumado al hecho de que son contaminadas por excesivo ruido y artefactos, lograr una correcta caracterización y clasificación de lo que se desea realizar aun no es del todo efectivo.

Durante la etapa de procesado los sistemas BCI incluyen técnicas de reconocimiento de patrones y machine learning como la transformada wavelet, algoritmos genéticos, redes neuronales, clasificador bayesiano, k-vecinos más cercanos, entre otras, y aunque se logran resultados aceptables en la clasificación de las intenciones, disponer de un sistema que implemente una metodología robusta de caracterización y clasificación frente a las diferentes tareas mentales a realizar sin necesidad de fatigantes entrenamientos cognitivos, sigue siendo un problema sin solución definitiva.

Justificación

Aunque el desarrollo de los sistemas BCI en los últimos años fue motivado por el deseo de brindar mejores condiciones de vida a las personas con capacidades motoras limitadas, en la actualidad esta tecnología ha despertado el interés en muchos otros sectores, debido a sus potenciales usos y aplicaciones, pero dadas las desventajas que presenta las señales EEG en cuanto a su calidad y baja resolución espacial, disponer de una metodología que permita realizar una correcta caracterización y clasificación de las mismas y las pueda transformar en comandos de salida claros y precisos, resulta imperioso en una disciplina que está empezando a tomar auge.

Dado que existen diferentes modelos computacionales para el procesado de señales EEG, estos aún no disponen de la efectividad que requieren los sistemas BCI para ejecutar las tareas mentales. Por tal motivo, conviene realizar un estudio comparativo de los diferentes métodos de caracterización y clasificación de señales EEG a fin de aplicar el que presente mejor equilibrio en cuanto a robustez y costo computacional.

Contribución de esta tesis

Para la comunidad académica y científica son un aporte los resultados arrojados por este trabajo investigativo, el cual consiste en un modelo computacional que facilita el análisis, caracterización y clasificación de señales EEG correspondiente a intenciones de tareas motoras, además que sirven como base para futuras investigaciones en las áreas de procesamiento, caracterización y clasificación de señales EEG y sistemas BCI, motivando a seguir con el desarrollo de esta tecnología, a fin de beneficiar a personas limitadas físicamente, en la ejecución de tareas cotidianas.

También son un aporte a nivel formal y técnico los algoritmos explorados y la metodología desarrollada en este trabajo para el área de procesamiento de señales biomédicas, específicamente en el análisis de señales EEG puesto que sirve de base para profundizar o mejorar los resultados obtenidos.

Organización del documento

El presente documento se divide en 7 secciones principales: Introducción, objetivos, marco teórico, metodología, resultados y discusión, conclusiones y recomendaciones.

- En la **sección 2**, se expone el objetivo general y los objetivos específicos, planteados como logros al inicio de este trabajo de grado.
- En la **sección 3**, se describe el marco teórico para la temática desarrollada en esta investigación.
- En la **sección 4**, se describe la metodología propuesta para el desarrollo de esta investigación,
- En la **sección 5**, se presenta el marco experimental donde se exponen el tipo de pruebas realizadas.
- En la **sección 6**, se da a conocer los resultados obtenidos de la investigación realizada.

- En la **sección 7**, se exponen las conclusiones obtenidas de este trabajo y se mencionan recomendaciones para posibles trabajos futuros, con el fin de mejorar los resultados obtenidos.

Objetivo general

Desarrollar una metodología para la caracterización y la clasificación de intenciones en señales EEG usando técnicas de caracterización espectral y reconocimiento de patrones.

Objetivos específicos

- Establecer el conjunto de características de señales EEG empleando técnicas de caracterización espectral y morfológica que representen adecuadamente el comportamiento eléctrico del cerebro.
- Determinar un subconjunto de características adecuado para aplicaciones de BCI usando técnicas de selección de características y reducción de dimensión.
- Implementar un sistema de clasificación para reconocer señales EEG asociadas con intenciones para aplicaciones BCI usando técnicas de reconocimiento de patrones.

Marco teórico

Una interfaz cerebro-computador (*BCI*), es un sistema que traduce los potenciales eléctricos del cerebro convirtiéndolos en comandos de salida para facilitar el control de algún dispositivo. Su funcionamiento consiste en procesar señales provenientes de la actividad neuronal cerebral, extraer características representativas, clasificarlas y ejecutar una tarea. Sus usos y aplicaciones van desde el ocio y entretenimiento hasta el control de prótesis y control de entornos. Son sistemas que pueden resultar muy útiles para personas dependientes, con discapacidades motrices o amputaciones, ya que se presenta como una alternativa de comunicación⁸. La mayoría de las BCI usan la electroencefalografía como método de adquisición del potencial de acción de las neuronas, debido a que es sencilla, no invasiva y de bajo costo, no obstante, la naturaleza de esta técnica hace a las

⁸ HORNERO, Roberto, Corralejo, Rebeca, Álvarez, Daniel. *Brain-Computer Interface (BCI) aplicado al entrenamiento cognitivo y control doméstico para prevenir los efectos del envejecimiento* [en línea]. Disponible en: http://www.fgcsic.es/lychnos/es_es/articulos/Brain-Computer-Interface-aplicado-al-entrenamiento-cognitivo

señales EEG propensas a contaminarse de ruido y artefactos, lo que conlleva a una incorrecta caracterización y clasificación de las mismas.

El propósito de este trabajo de grado fue el de desarrollar una metodología que procese y permita discriminar señales EEG correspondientes a diferentes movimientos imaginarios, usando técnicas que permitan obtener una señal lo menos contaminada posible y faciliten la etapa de caracterización y clasificación.

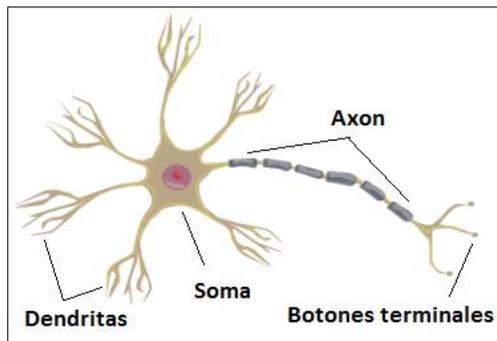
La neurona

La neurona es un tipo de célula nerviosa que se especializa en transmitir información a través del cuerpo en forma de impulsos eléctricos llamados potenciales de acción. Es el constituyente básico del sistema nervioso y su estructura es similar al de otras células. Existen diferentes tipos de neuronas que cumplen diversos objetivos, por ejemplo, las neuronas sensoriales transmiten la información desde las células receptoras del cuerpo hasta el cerebro, y las neuronas motoras transmiten información desde el cerebro hasta los músculos del cuerpo^{9 10}.

Estructura de una neurona

Las neuronas varían unas a otras en tamaño, forma y características, sin embargo, están formadas de cuatro partes básicas:

Figura 3 La neurona



Fuente: La neurona. Ambientech [imagen]. Disponible en:
<https://ambientech.org/blog/la-neurona/>

⁹ Neurons and their role in the nervous system. Verywell mind [en línea]. Disponible en:
<https://www.verywellmind.com/what-is-a-neuron-2794890>

¹⁰ Neuron action potentials: The creation of a brain signal. Khan Academy [en línea]. Disponible en:
<https://www.khanacademy.org/test-prep/mcat/organ-systems/neuron-membrane-potentials/a/neuron-action-potentials-the-creation-of-a-brain-signal>

- **Las dendritas:** son como las ramas de un árbol que ayudan a incrementar el área superficial del cuerpo de la neurona, se encargan de recibir información de neuronas vecinas y transmiten estimulación eléctrica al soma.
- **El cuerpo celular (soma):** es donde las señales provenientes de las dendritas son llevadas, no desempeña un papel importante en la transmisión de señal neuronal, pero su estructura sirve para mantener el funcionamiento de la célula.
- **El axón:** es una fibra alargada que se extiende desde el soma hasta los terminales finales y transmiten la señal neuronal, cuanto más grande sea su diámetro, más rápido se transmite información. Algunos axones están cubiertos con una sustancia grasa llamada mielina, la cual permite transmitir información más rápido que otras neuronas.
- **Botones terminales:** están localizados al final de la neurona y se encargan de enviar la señal a otras neuronas. Al final de cada botón terminal hay una brecha conocida como sinapsis. la señal es llevada a través de la sinapsis hacia otras neuronas por medio de neurotransmisores que se definen como mensajes químicos.

Potencial de acción

Es parte del proceso de transmisión que ocurre cuando una neurona al disparar un impulso eléctrico envía señales a todo el cuerpo. Durante este proceso, parte de la membrana neuronal se abre permitiendo el flujo repentino de iones de sodio y potasio hacia adentro y fuera de la neurona^{11 12}.

Gradiente de concentración

La parte fundamental de un potencial de acción es el gradiente de concentración iónico, una diferencia de concentración de iones dentro y fuera de la neurona. Se habla de un gradiente de concentración alto, cuando se tiene una concentración de iones cargados positivamente alta fuera de la neurona en comparación con su interior y viceversa. Los iones siguen la dirección que mantiene el gradiente equilibrado, por lo tanto, la carga de los iones no es importante¹³.

¹¹ Neurons and their role in the nervous system. Verywell mind [en línea]. Disponible en: <https://www.verywellmind.com/what-is-a-neuron-2794890>

¹² Action potential and how neurons fire. Verywell mind [en línea]. Disponible en: <https://www.verywellmind.com/what-is-an-action-potential-2794811>

¹³ Neuron action potentials: The creation of a brain signal. Khan Academy [en línea]. Disponible en: <https://www.khanacademy.org/test-prep/mcat/organ-systems/neuron-membrane-potentials/a/neuron-action-potentials-the-creation-of-a-brain-signal>

Potencial de membrana en reposo

La mayor parte del tiempo, hay más iones cargados positivamente fuera de la neurona que dentro de ella, lo que se conoce como gradiente de concentración negativa o potencial de membrana en reposo, y se caracteriza por haber más iones de sodio fuera de la neurona que dentro de ella, y más iones de potasio dentro de la neurona que fuera de ella. La neurona mantiene un gradiente de concentración negativo que se encuentra entre los -50 y -70 mV, como la membrana celular de la neurona es muy permeable a los iones de potasio y poco permeable a los iones de sodio, al querer mantener ese potencial negativo, bombea a la misma vez potasio hacia adentro de la célula y sodio hacia afuera de ella. Por tanto, los iones están moviéndose dentro y fuera de la neurona a fin de balancear sus concentraciones. Al momento de ingresar a la membrana el ion de sodio hará que se vuelva menos negativo. Esto se conoce como **despolarización**, lo que significa que el potencial de membrana se mueve hacia cero^{14 15}.

Principio de un potencial de acción

El gradiente de concentración de sodio está tan alto que continúa ingresando a la neurona incluso después que el potencial de membrana se haya vuelto cero. Cuando los iones de sodio hayan ingresado a la neurona, el potencial de membrana alcanzará los 30 mV y un potencial de acción se dispara enviando una señal al final del axón. Las neuronas se disparan siempre con mucha fuerza, esto garantiza que la señal pueda ser transferida con toda su intensidad a la siguiente neurona sin que esta se debilite o pierda. Al dispararse el potencial de acción los iones de potasio comienzan a abandonar la neurona llevando con ellos la carga positiva y haciendo que el potencial de membrana retroceda hasta su potencial de reposo, -70mV, esto se conoce con el nombre de **repolarización**. Mientras los iones de potasio alcanzan el equilibrio, el potencial de membrana estará por debajo de los -70mV por lo que se produce un periodo de **hiperpolarización**. Después que la neurona se haya disparado, no es posible enviar otro potencial hasta que la neurona regrese gradualmente hasta su potencial de reposo y se pueda repetir el ciclo nuevamente^{16 17}. En la figura 4 se muestra la gráfica de un potencial de acción.

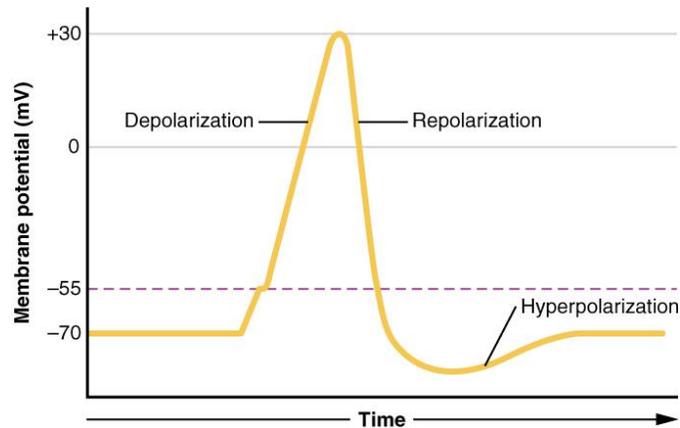
¹⁴ How neurons communicate. Lumen Boundles Biology [en línea]. Disponible en: <https://courses.lumenlearning.com/boundless-biology/chapter/how-neurons-communicate/>

¹⁵ The nervous system and nervous tissue. Anatomy and physiology [en línea]. Disponible en: <https://opentextbc.ca/anatomyandphysiology/chapter/12-4-the-action-potential/>

¹⁶ How neurons communicate. Lumen Boundles Biology [en línea], [revisado septiembre 15 de 2018]. Disponible en: <https://courses.lumenlearning.com/boundless-biology/chapter/how-neurons-communicate/>

¹⁷ The nervous system and nervous tissue. Anatomy and physiology [en línea], [revisado septiembre 15 de 2018]. Disponible en: <https://opentextbc.ca/anatomyandphysiology/chapter/12-4-the-action-potential/>

Figura 4 Potencial de acción de la neurona



Fuente: The nervous system and nervous tissue. Anatomy and physiology [imagen]. Disponible en: <https://opentextbc.ca/anatomyandphysiology/chapter/12-4-the-action-potential/>

Registro de la actividad cerebral

La actividad cerebral puede ser monitoreada con el propósito de obtener información que permita comprender el funcionamiento de nuestro cerebro. Existen técnicas que obtienen el registro de diferentes formas, ya sea por medio de potenciales eléctricos, campos magnéticos o imágenes. De estas técnicas las más usadas para el registro de actividad cerebral en interfaces cerebro-computador son: La magnetoencefalografía (MEG), la electrocorticografía (ECoG) y la Electroencefalografía (EEG), debido a que adquieren la actividad producida por los potenciales neuronales. Otras Técnicas como la imagen por resonancia magnética funcional (fMRI) y la tomografía por emisión de positrones (PET), aunque son de vital importancia en la medicina, hasta ahora son poco relevantes en el campo de las BCI ya que registran otros parámetros como la cantidad de oxígeno y glucosa presente en la sangre que fluye en el cerebro, y no la actividad neuronal¹⁸. A continuación se mencionan las principales características de la MEG, ECoG y la EEG.

¹⁸ SIDELKIVSKA, Valerie. Neuroimaging: *What is it and how can it map the brain?* Cognifit: health, brain & neuroscience [en línea]. Disponible en: <https://blog.cognifit.com/neuroimaging/>

Magnetoencefalografía (MEG)

Es una técnica de imagen que permite medir los campos magnéticos producidos por los potenciales eléctricos del cerebro sin necesidad de procedimientos quirúrgicos. De alta resolución espacial y temporal. Necesita de equipo especializado y utiliza un proceso llamado imágenes de fuente magnética (MSI) para registrar las fuentes de la actividad cerebral en imágenes proporcionadas por resonancia magnética¹⁹.

Electrocorticografía (ECoG)

Es una técnica que permite medir la actividad eléctrica del cerebro por medio de un arreglo de electrodos ubicados directamente sobre el tejido cerebral. Se caracteriza por tener alta resolución temporal y debido el pequeño tamaño de sus electrodos (2mm), el área de registro debajo de cada uno de ellos, se asemeja al del tamaño estándar de un vóxel (unidad mínima procesable que usan los métodos de neuroimagen), brindando una dinámica más cercana de los potenciales cerebrales con alta relación señal ruido^{20 21}.

Electroencefalografía (EEG)

Es una técnica que permite medir los potenciales eléctricos provenientes de distintas partes del cerebro por medio de electrodos ubicados de manera estándar sobre la cabeza. No necesita de procedimientos quirúrgicos o de equipo muy especializado y las señales adquiridas poseen alta resolución temporal más no espacial. Las señales adquiridas por este método son altamente propensas a contaminarse de otras señales fisiológicas y ruido²².

¹⁹ SUTHERLING, William. Magnetoencephalography [en línea]. En: AMINOFF, Michael. *Aminoff's Electrodiagnosis in clinical neurology*. 6ta edición. San Francisco, California: Elsevier Saunders, 2012. P. 219-229. Disponible en: <https://www.sciencedirect.com/science/article/pii/B9781455703081000108>

²⁰ BOLDY, Melanie, GOSSERIES, Olivia, MASSIMINI, Marcello, ROSANOVA, Mario. Chapter 2 – *Functional Neuroimaging Techniques* [en línea]. En: LAUREYS, Steven, GOSSERIES, Olivia, TONONI, Giulio. *The Neurology of Consciousness: Cognitive neuroscience and neuropathology*. 2da edición. Academic Press. 1 septiembre de 2015. P. 31-47. Disponible en: <https://www.sciencedirect.com/science/article/pii/B9780128009482000029>

²¹ GUGER, Christoph, KAPPELLER, Christoph, OGAWA, Hiroshi, PRUCKL, Robert, GRUNWALD, Johannes, KAMADA, Kyouzuke. Chapter 9 – *Electrocorticogram base brain-computer Interfaces* [en línea]. En: DIEZ, Pablo. *Smart Wheelchairs and Brain-Computer Interfaces: Mobile Assistive Technologies*. Academic Press. 2018. P. 197-227. Disponible en:

<https://www.sciencedirect.com/science/article/pii/B9780128128923000091>

²² BAARS, Bernard J., CAGE, Nicole M. Chapter 5 – *Braining Imaging* [En línea]. En: *Fundamentals of Cognitive Neuroscience: A Beginner's Guide*. Academic Press. 2013. P. 109-140. Disponible en: <https://www.sciencedirect.com/science/article/pii/B9780124158054000059>

Tabla 1 Comparación entre MEG, ECoG y EEG

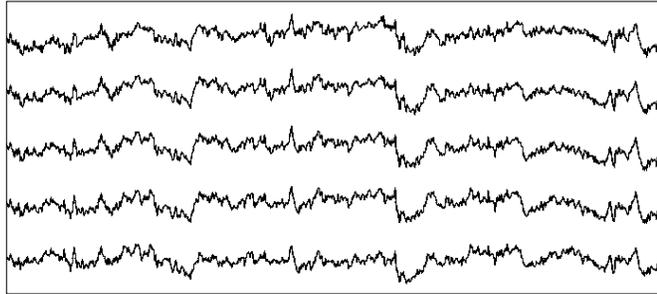
Técnica	Ventajas	Desventajas
Magnetoencefalografía (MEG)	Alta resolución espacial y temporal. No invasiva.	Se necesita de cuartos y equipos especializados. No es portátil. De alto costo.
Electrocorticografía (ECoG)	Alta resolución espacial y temporal. Alta relación señal ruido. Poca degradación de la señal por el cuero cabelludo u otros tejidos	Invasiva. Requiere de procedimiento quirúrgico. Se corre riesgo de infecciones No es portátil. De alto costo.
Electroencefalografía (EEG)	Alta resolución temporal. Portátil No invasiva De bajo costo	Baja resolución espacial. Baja relación señal ruido. Degradación de la señal debido a ruido externo.

Como se aprecia en la tabla1: La EEG posee grandes desventajas a nivel de resolución espacial y relación señal ruido en comparación con la MEG y la ECoG; sin embargo su costo, fácil acceso, portabilidad y no invasividad la hacen la técnica de más uso en el campo investigativo de las interfaces cerebro-computador.

Señales EEG

El electroencefalograma es el instrumento que permite medir la actividad eléctrica del cerebro por medio de sensores que se colocan sobre el cuero cabelludo. Estos sensores o electrodos, recogen cada uno las pequeñas fluctuaciones eléctricas, luego se amplifican, se registran y se muestran en un monitor como un conjunto de ondas continuas, llamadas señales EEG, cuyo valor potencial es cercano a los 50uV y su rango de frecuencias se encuentra entre los 0.2 y 100Hz.

Figura 5 Señales EEG

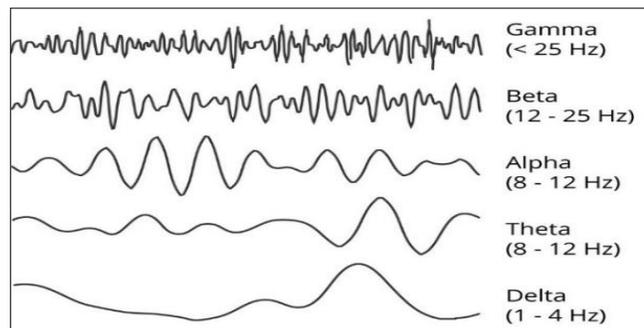


Fuente: Elaboración propia.

Ondas o ritmos EEG

Existen patrones oscilatorios en las señales EEG llamados ondas o ritmos, que juegan un papel importante a la hora de comprender el funcionamiento del cerebro. Estos patrones son sensibles y varían según el estado o tarea que esté realizando el sujeto, por ejemplo: en estados de concentración, estrés, sueño profundo o enfermedades que impliquen daño del cerebro, estos ritmos variarían drásticamente por lo que su análisis sirve como herramienta de diagnóstico^{23 24}.

Figura 6. Ondas o ritmos EEG.



Fuente: HEHE, Joshua. Brain waves [Imagen]. Gamma Brainwaves –The science of Enlightened Minds. Sep. 15, 2018. [Consultado septiembre de 2018]. Disponible en: <https://medium.com/@joshuashawnmichaelhehe/gamma-brainwaves-be319acf6dea>

²³KUMAR, Satheesh J., BHUVANESWARI, P. Analysis of electroencephalography (EEG) signals and its categorization-A study. En: Procedia Engineering. 2012. Volume 38. P. 2525-2536.

²⁴KROPOTOV, Juri D. Functional Neuromarkes for psychiatry – Applications for diagnosis and treatment. Academic press. 2016.

- **Ondas Delta α :** son las más lentas de todas las ondas, con frecuencias entre los 0.5-4Hz. Aparecen cuando el sujeto está dormido y su amplitud es mayor en etapas de sueño profundo.
- **Ondas Teta θ :** sus frecuencias comprenden los 4-8Hz. y están principalmente relacionadas con estados de somnolencia y actividad subconsciente. También se asocian a inspiración creativa, meditación, relajación profunda y resolución de problemas matemáticos como sumas y restas.
- **Ondas Alfa α :** asociadas a estados de relajación, despiertos, pero con los ojos cerrados, se encuentran entre los 8-12Hz. Comúnmente se originan sobre la región occipital del cerebro como una señal redonda o sinusoidal. Un tipo de onda alpha es la conocida onda **Mu μ** (10Hz), el cambio de actividad de esta onda se produce debido a la sincronización de grupos de neuronas en la región de la corteza motora del cerebro. Cuando las extremidades del cuerpo (manos o pies) se encuentran quietas, las ondas

Mu presentan actividad, pero cuando las extremidades se mueven esta actividad decrece, lo que se conoce como desincronización. Estos atributos se usan en BCI para detectar movimientos imaginarios.

- **Ondas Beta β :** son ondas de baja amplitud y frecuencias variables (12-30Hz). Se las asocia con pensamiento activo, atención activa o resolución de problemas concretos. Son normalmente encontradas en personas adultas como registros espontáneos de actividad sobre el área sensoriomotora. Un alto nivel de ondas betas se observan cuando las personas se encuentran en estado de alta actividad.
- **Ondas Gamma γ :** son ondas de baja potencia y cuya banda de frecuencias comprende los 30-100Hz. aparecen cuando hay alta actividad mental y pánico.

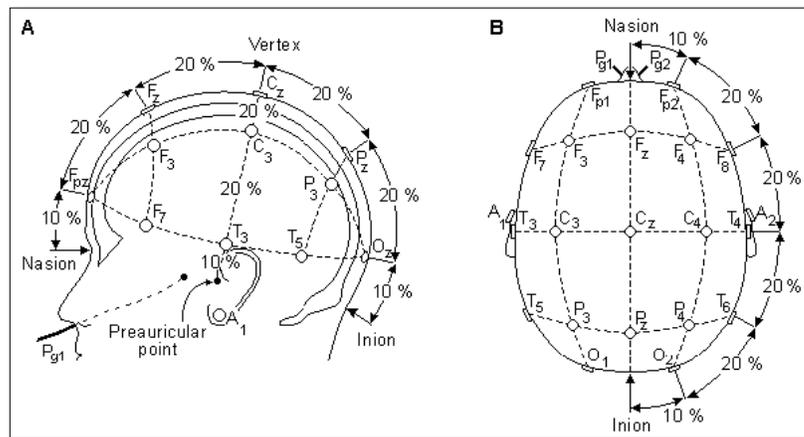
Ruido y artefactos

Durante el proceso de adquisición la señal EEG es contaminada por otras señales y ruido proveniente de otras fuentes. Este ruido es lo que se conoce comúnmente como artefactos, los cuales son originados por parpadeo o movimiento ocular (EOG), latidos del corazón (EEG), movimiento del cuerpo (EMG) y ruido de línea (60Hz) de tensión o de cualquier otro aparato presente en el lugar donde se hace la adquisición de la señal.

Sistema 10-20

Con el fin de que los registros de las señales EEG puedan ser reproducidos y comparados en cualquier parte de mundo, se vio la necesidad de normalizar la manera de colocar los electrodos sobre el cuero cabelludo. Es así como el sistema 10-20 se vuelve un estándar para aplicaciones clínicas e investigaciones. Este sistema se basa en una subdivisión del cráneo en semicircunferencias teniendo como referencia los puntos Nasion, Inion, preauricular derecho y preauricular izquierdo. Los números 10 y 20 indican que la distancia que hay entre electrodos adyacentes es del 10% o 20% de la distancia medida teniendo en cuenta los puntos de referencia mencionados. Por ejemplo: de adelante hacia atrás y de izquierda a derecha. Los electrodos son etiquetados con letras y números que corresponden al área anatómica donde están ubicados: *Prefrontal (Fp)*, *Frontal (F)*, *temporal (T)*, *Central (C)*, *Parietal (P)* y *occipital (O)*. Los números pares corresponden al lado derecho de la cabeza mientras los impares corresponden al lado izquierdo. Los electrodos del vértice llevan el subíndice z (de Zero)^{25 26 27}.

Figura 7. Sistema internacional 10-20.



Fuente: *The international system 10-20 [Imagen]. National Center for Adaptive Neurotechnologies. Disponible en:*

https://www.bci2000.org/mediawiki/index.php/User_Tutorial:EEG_Measurement_Setup

²⁵ KULKARNI, Nilesh, BAIRAGI, Vinayak. Chapter Two – Electroencephalogram and Its Use in Clinical Neuroscience [En línea]. En: EEG-Based Diagnosis of Alzheimer Disease. Academic Press. 2018. P. 25-35.

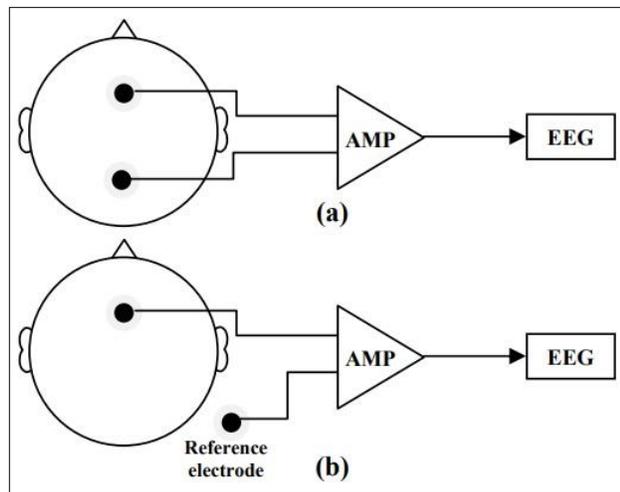
²⁶ KLEM, George H., LUDERS, Hans Otto, JASPER, H.H., ELGER, C. The ten-twenty electrode system of the International Federation. 1999.

²⁷ SEECK M., KOESSLER, L., BAST, T., LEIJTEN, F., MICHEL, C., BAUMGARTNER, C., HE, B., BENICZKY, S. The standardized EEG electrode array of the IFCN. Clinical Neurophysiology. Vol. 128. October 2017. P. 2070-2077.

Montajes

Para la adquisición de las señales EEG el equipo de electroencefalografía hace uso de amplificadores diferenciales, debido a que estos poseen un alto rechazo al modo común, es decir: si un par de electrodos A y B, se ubican en la superficie de la cabeza, la actividad común a ambos electrodos será rechazada y la diferencia será amplificada para su posterior análisis. En cambio, si el electrodo B, se ubica en una parte neutral o donde no haya actividad cerebral, la señal EEG obtenida será del valor que contenga el electrodo A, ubicado en la superficie de la cabeza donde se registre actividad. Estos dos modos se conocen como **montaje bipolar** y **montaje unipolar o referencial** respectivamente²⁸²⁹. Para el montaje unipolar no existe en el cuerpo humano una ubicación neutral de referencia, por tanto el electrodo referencial se puede ubicar en partes donde en teoría se tenga potencial cero: mastoides, lóbulos de las orejas o mentón.

Figura 8. a) Montaje bipolar. b) montaje unipolar o referencial.



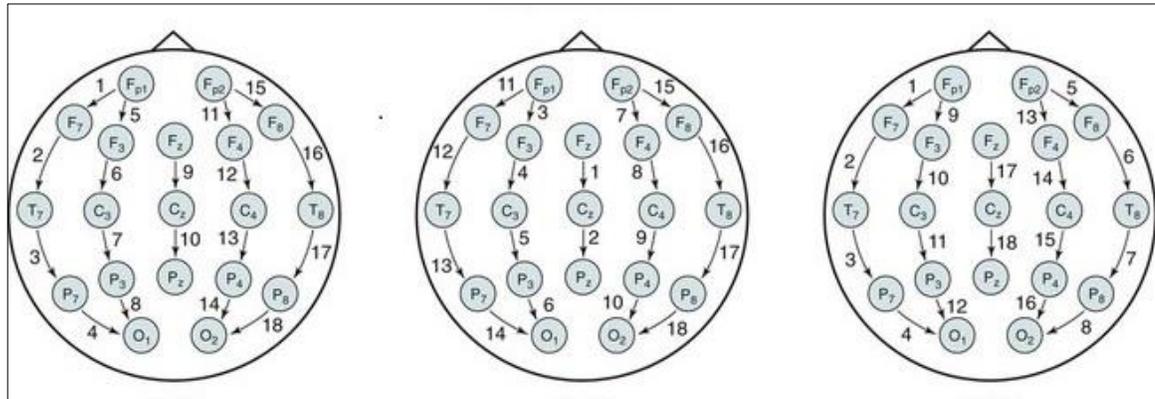
Fuente: DIEZ, Pablo F., MUT, Vicente, LACIAR, Eric, AVILA, Enrique. A comparison of monopolar and bipolar EEG recordings for SSVEP detection. 2010. PMID: 21096910.

²⁸ SAAB, Marc. Basic concepts of surface Electroencephalography and Signal Processing as Applied to the Practice of Biofeedback. Special issue. Vol. 36. 2009. P. 128-133.

²⁹ DIEZ, Pablo F., MUT, Vicente, LACIAR, Eric, AVILA, Enrique. A comparison of monopolar and bipolar EEG recordings for SSVEP detection. 2010. PMID: 21096910.

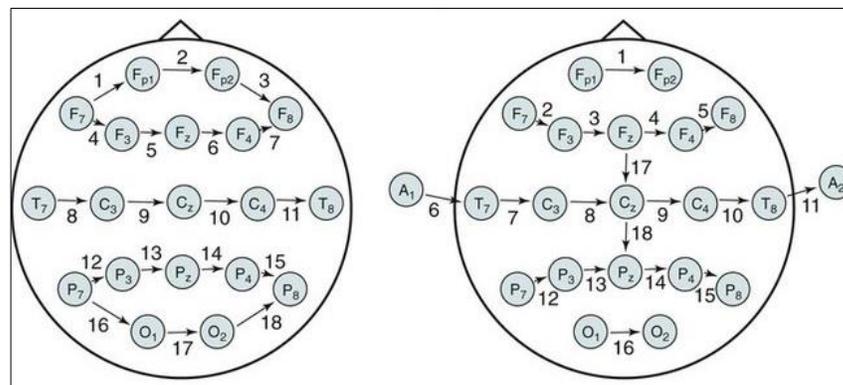
Los montajes bipolares han sido clasificados como Longitudinales o Transversales, en el primero la actividad cerebral se registra en pares de electrodos ubicados de atrás hacia delante en cada mitad de la cabeza. Figura 8. En los transversales los pares de electrodos se ubican de manera transversal como se indica en la Figura 9.

Figura 9. Montaje bipolar longitudinal con tres tipos de arreglo para las derivaciones.



Fuente: Clinical Electroencephalography and Nocturnal epilepsy [Imagen].
 [Consultado septiembre de 2018]. Disponible en:
<https://neupsykey.com/clinical-electroencephalography-and-nocturnal-epilepsy/>

Figura 10. Montaje bipolar transversal con dos maneras de arreglo para las derivaciones.



Fuente: Clinical Electroencephalography and Nocturnal epilepsy [Imagen].
 Disponible en: <https://neupsykey.com/clinical-electroencephalography-and-nocturnal-epilepsy/>

Interfaz cerebro computador (BCI)

Una interfaz cerebro computador (BCI) es un sistema que permite la comunicación directa entre el cerebro humano y un computador, proporcionando al usuario una alternativa para controlar su entorno por medio de su actividad cerebral. Su funcionamiento se basa en el análisis y procesamiento de señales EEG con las cuales se generan comandos de control que son interpretados y ejecutados por unidades electrónicas, pero sin la intervención de movimientos musculares³⁰. Se la considera de mucha importancia en el campo de la rehabilitación, debido a que mejoran la calidad de vida de los usuarios que padecen de enfermedades motrices, siendo esta una nueva manera de comunicarse con su entorno. Los sistemas BCI se los puede clasificar en dos tipos diferentes dependiendo de la naturaleza de la señal registrada.

- **BCI Exógeno:** dependen de la actividad neuronal evocada por estímulos externos, visuales o auditivos. Estos sistemas analizan patrones característicos en las señales EEG como: la onda **P300** o los **SSVEP**, por lo que su configuración es más sencilla y no requiere entrenamiento intensivo por parte del usuario.
- **BCI Endógeno:** estos sistemas no requieren de estímulo externo y se basan principalmente en análisis de las ondas **Mu** o ritmos sensorios motrices de las señales EEG y otros patrones o características de las mismas. Para la implementación de este tipo de sistema muchas veces se necesita que el usuario requiera de un entrenamiento para adquirir la habilidad de producir los patrones que serán procesados por el sistema.

Configuración BCI

Aunque los sistemas BCI se desarrollen teniendo en cuenta las tareas que vayan a ejecutar y se clasifiquen según la señal adquirida, su funcionamiento y configuración básica es para todos igual. Un sistema BCI se compone de 5 partes principales como se muestra en la figura 11.

³⁰ Silva-Sauer, L. D., Valero-Aguayo, L., Velasco-Álvarez, F., Ron-Angevin, R., & Sancha-Ros, S. (2013). Brain-computer interface: Proposal of a shaping-based training. *Revista Brasileira de Engenharia Biomédica*, 29(2), 123-132.

Figura 11. Diagrama de bloques del funcionamiento básico de una BCI.



Fuente: Elaboración propia.

Adquisición

Como se mencionó en la introducción, los sistemas BCI capturan las señales provenientes del cerebro por medio de electroencefalografía EEG, debido a que esta técnica es de bajo costo, no invasiva y de fácil acceso.

Preprocesado

El objetivo de esta etapa es el de eliminar o atenuar el ruido y los artefactos con el propósito de adecuar la señal EEG sin que esta pierda información importante y se facilite la extracción de patrones característicos. El pre-procesamiento básicamente consiste en:

- Filtrar la señal usando filtros pasa-altas, pasa-bajas y rechaza-banda, con el fin de limitar la señal a un cierto rango de frecuencias.
- Normalizar la señal garantizando que mantenga cierto rango en su amplitud.
- Eliminar artefactos por medio de otras técnicas como el análisis de componentes independientes (ICA).
- Seleccionar los mejores canales de los registros EEG.
- Dividir la señal en segmentos más pequeños para facilitar su análisis y caracterización.

Caracterización

Consiste en analizar y hacer medidas en las señales con algoritmos específicos a fin de obtener patrones y características relevantes. Es la etapa más importante de una BCI puesto que un conjunto de características representativas de la señal derivara en una buena clasificación. El análisis puede ser del tipo temporal, espectral, morfológico y estadístico.

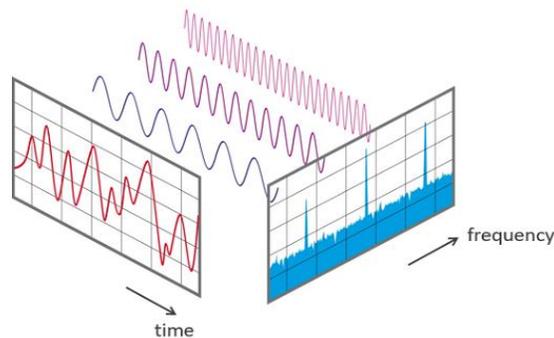
Análisis temporal.

Las señales EEG están en función del tiempo por lo que algunas características se pueden estimar de manera directa, sin embargo, estas características temporales no son de uso frecuente en aplicaciones BCI debido a que las señales EEG no presentan un patrón o morfología definida. Algunos parámetros del dominio del tiempo son: longitud, Amplitud, regularidad, continuidad y sincronicidad.

Análisis espectral.

Consiste en descomponer la señal en varios componentes espectrales y así obtener patrones característicos como: densidad de potencia espectral PSD y potencia máxima en diferentes anchos de banda. Para convertir la señal del dominio temporal al espectral se hace uso de herramientas como la transformada de Fourier.

Figura 12. Transformación de una señal del dominio temporal al espectral.



Fuente: Fast Fourier Transform FFT-Basics. [Imagen]. Disponible en internet: <https://www.nti-audio.com/en/support/know-how/fast-fourier-transform-fft>

- **Transformada de Fourier (FT):** permite descomponer la señal en sinusoides de diferentes frecuencias. Una desventaja de la FT es que al pasar la señal al dominio de la frecuencia se pierde toda información relacionada al tiempo; es decir, cuando analizamos las componentes espectrales de una señal, es imposible determinar en qué instante de tiempo ocurre el evento asociado a estas frecuencias. Esta desventaja no es de mucha relevancia cuando se analiza señales estacionarias, pero en el caso de las señales EEG, limita la extracción de información importante³¹.

³¹ CORTÉS, J. A., Medina, F. A., & Chaves, J. A. (2007). Del análisis de fourier a las wavelets análisis de fourier. *Scientia et technica*, 1(34).

- **Transformada Rápida de Fourier (FFT):** mediante un ventaneo la FFT permite analizar una pequeña parte de la señal en un determinado tiempo, pero el uso de esta herramienta implica un compromiso entre buena resolución temporal o buena resolución espectral, ya que nos dice el instante y la frecuencia en que ocurre algún evento con una precisión limitada por el ancho de la ventana³².

Análisis tiempo-frecuencia

Permite la extracción de características que proveen información temporal y espectral simultáneamente en una señal. La herramienta más común para el análisis multiresolución de señales es la transformada wavelet.

- **Transformada Wavelet:** esta técnica fue desarrollada con el fin de superar las desventajas que presenta la transformada de Fourier (FT) y poder representar una señal tanto en el dominio temporal como el espectral, de manera simultánea y con una buena resolución. Permite el uso de intervalos temporales grandes, en aquellos segmentos donde se requiere mayor precisión en baja frecuencia, e intervalos temporales pequeños donde se requiera más información de alta frecuencia³³.

El funcionamiento de la transformada wavelet consiste en filtrar la señal en el dominio del tiempo por medio de filtros pasa bajo y pasa alto, permitiendo que se eliminen ciertas componentes y separar las porciones de alta frecuencia de las de baja frecuencia. Para las señales resultantes el proceso se repite de la misma manera hasta que la señal se ha descompuesto a un nivel previamente definido. Al final se obtiene conjunto de señales que representan la señal original, pero con bandas de frecuencia diferente. Al usar la transformada wavelet las altas frecuencias tienen mejor resolución en el dominio del tiempo mientras que las bajas frecuencias tienen mejor resolución en el dominio de la frecuencia^{34 35}.

³² KOURO, S., & Musalem, R. (2002). Tutorial introductorio a la Teoría de Wavelet. *Artículo presentado como trabajo de la asignatura Técnicas Modernas en Automática.*

³³ MARTINEZ, J., & Castro, J. (1995). Análisis de la teoría de ondículas orientada a las aplicaciones en ingeniería eléctrica: Fundamentos. *ETS Industriales Departamento de Ingeniería Eléctrica, Madrid.*

³⁴ KOURO, S., & Musalem, R. (2002). Tutorial introductorio a la Teoría de Wavelet. *Artículo presentado como trabajo de la asignatura Técnicas Modernas en Automática.*

³⁵ CORTÉS, J. A., Medina, F. A., & Chaves, J. A. (2007). Del análisis de fourier a las wavelets análisis de fourier. *Scientia et technica, 1(34).*

Análisis estadístico

Las señales EEG muestran un comportamiento dinámico y se caracterizan por ser caóticas, no lineales y no estacionarias. Para caracterizar estos atributos se requiere del uso de herramientas como: la entropía que permite evaluar el estado de caos de un sistema dinámico. **La entropía** es una medida de incertidumbre que nos brinda una noción de que tan desordenada está una señal. El concepto de entropía es descrito como la cantidad de información almacenada en una distribución de probabilidad general. El nivel de caos también puede ser medido usando la entropía, una alta entropía representa una alta incertidumbre y por tanto un sistema más caótico.

Otras herramientas de análisis estadístico usadas como método de caracterización de señales EEG son: el **análisis de componentes principales (PCA)** y el **análisis de componentes independientes (ICA)**, la primera usa información de segundo orden estadístico mientras que la segunda usa información de orden superior. Ambas herramientas son principalmente usadas en la separación de fuentes ciegas (BBS-Blind Source Separation), esta técnica permite la separación de señales origen desde una señal mezclada, sin información previa o con muy poca información sobre el origen de las señales y el proceso de mezclado. En la práctica esta técnica es muy útil a la hora de descomponer una señal EEG y localizar el origen de determinados eventos.

Selección de características

Durante la caracterización, muchos atributos son extraídos de las señales EEG, derivando en un vector de características de alta dimensionalidad. La selección de características es el proceso donde se escogen los atributos más representativos de los datos y que más aportan a la predicción del clasificador. Al igual que la caracterización, es uno de las etapas más importantes en el procesamiento de señales EEG, puesto que las características usadas para entrenar el modelo, impactarán notablemente en el rendimiento y porcentaje de acierto al momento de clasificar. Una incorrecta selección de características hace que el modelo aprenda basado en información irrelevante, afectando negativamente el desempeño del clasificador, tanto en acierto como en tiempo de ejecución. A continuación, se da una breve descripción de algunos de los métodos de selección de características más usados en el Aprendizaje automático:

- **IG:** es un método de selección muy popular para datos de alta dimensión.
- **CFS:** es un rápido y sencillo método de selección de un conjunto de características.

- **ReliefF:** es un método que clasifica las características basado en que tan bien distingue entre los casos que está cerca uno del otro.
- **Consistency:** es un método que busca combinaciones de características que están principalmente asociadas con la misma clase.
- **1RR:** está basado en el algoritmo de clasificación 1R, el cual genera una regla de clasificación que prueba los valores de una característica única.
- **ANOVA Ranking:** método que se lo aplica para características individuales usando pruebas de ambas clases a fin de determinar el nivel de diferencia significativa entre los medios de cada clase.
- **Forward selection:** es una técnica estándar para encontrar las mejores características analizando el rendimiento de cierto subconjunto de características usando el mismo algoritmo de aprendizaje que después es usado para clasificación.
- **Genetic Algorithm GA:** es un procedimiento de optimización que sirve para establecer si cierto conjunto de características es el más eficiente.

Clasificación

El objetivo de la clasificación es describir un límite entre las clases y las etiquetas según las características medidas. Es un proceso global que abarca una estrategia para determinar qué características seleccionar y como combinarlas para optimizar el rendimiento del modelo. Este proceso utiliza algoritmos de aprendizaje automático supervisado, algunos de los algoritmos más usados en procesamiento de señales EEG se listan a continuación:

- **Logistic Regresion:** ajusta un modelo que puede predecir la probabilidad de una respuesta binaria perteneciente a una clase u otra.
- **k NEarest Neighbor (kNN):** categoriza objetos basado en las clases de sus vecinos más cercanos en el conjunto de datos.
- **Support Vector Machine (SVM):** clasifica los datos encontrando un límite de decisión lineal que separa todos los puntos de datos de una clase de aquellos pertenecientes a la otra clase.
- **Neural Network:** es una técnica inspirada en el cerebro humano que consiste en redes de neuronas altamente conectadas que relaciona las entradas con las salidas deseadas.

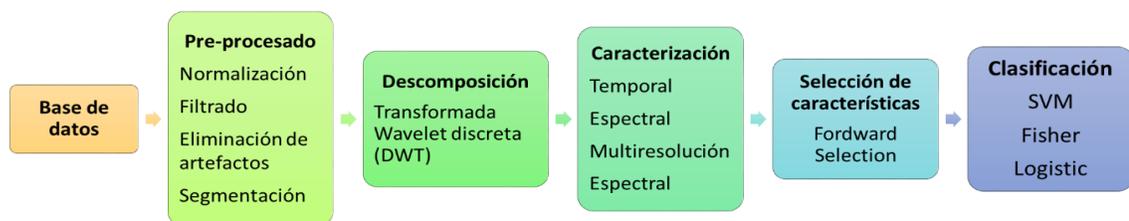
- **Naive Bayes:** este clasificador asume que la presencia de una particular característica en una clase no está relacionada a la presencia de cualquiera otra característica.
- **Discriminante Análisis:** clasifica los datos encontrando combinaciones lineales de características, además asume que diferentes clases generan datos basados en distribuciones gaussianas.
- **Decision Tree:** permite predecir respuestas a los datos siguiendo las decisiones en el árbol desde la raíz bajando al nodo de la hoja.

1. DESARROLLO DE LA INVESTIGACIÓN

Un resumen de la metodología propuesta para la caracterización y clasificación de señales EEG con fines aplicativos de interfaz cerebro computador, se aprecia en la figura 13 y está constituida de las siguientes etapas: pre-procesamiento, caracterización, selección de características y clasificación.

1.1 SEÑALES EEG

Figura 13. Metodología para la caracterización y clasificación de señales EEG.



Fuente: Elaboración propia.

La base de datos utilizada en este trabajo es la EEG Motor Movement/Imagery Dataset, la cual fue creada por los desarrolladores de BCI 2000 Instrumentation System^{36 37} y contribuida a PhysioNet³⁸ de donde fue adquirida. La base de datos original está compuesta por alrededor de 1500 registros EEG, de entre uno y dos minutos de duración, obtenidos de 109 voluntarios. Para el presente trabajo solo se tuvo en cuenta los registros de 70 voluntarios. El protocolo experimental para la adquisición de las señales se menciona a continuación.

Los 70 voluntarios ejecutaron diferentes tareas de movimientos imaginarios, mientras 64 canales o electrodos ubicados sobre el cuero cabelludo y siguiendo el estándar internacional 10-20, registraban la actividad cerebral usando el sistema

³⁶ Schalk, G., McFarland, D.J., Hinterberger, T., Birbaumer, N., Wolpaw, J.R. BCI2000: A General-Purpose Brain-Computer Interface (BCI) System. IEEE Transactions on Biomedical Engineering 51(6):1034-1043, 2004. [In 2008, this paper received the Best Paper Award from IEEE TBME.]

³⁷ BCI2000, Ncan Schalk Lab. [En línea]. Disponible en: <http://www.schalklab.org/research/bci2000>

³⁸ Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PCh, Mark RG, Mietus JE, Moody GB, Peng C-K, Stanley HE. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. Circulation 101(23):e215-e220 [Circulation Electronic Pages; <http://circ.ahajournals.org/cgi/content/full/101/23/e215>]; 2000 (June 13).

BCI2000. Cada sujeto ejecutó 2 rutinas experimentales como se muestra en la tabla 2.

Tabla 2. Rutinas experimentales para la adquisición de las señales EEG.

Número de ejecuciones	Tipo de rutina	Duración de la rutina
1	Rutina 1: Un objetivo aparece en el lado izquierdo o derecho de la pantalla. El sujeto imagina abrir y cerrar la mano correspondiente hasta que el objetivo desaparece. Luego el sujeto se relaja.	2 min.
1	Rutina 2: Un objetivo aparece en la parte superior o inferior de la pantalla. El sujeto imagina mover ambas manos, si el objetivo está arriba de la pantalla o ambos pies, si el objetivo está abajo hasta que este desaparece. Luego el sujeto se relaja.	2 min.

Fuente: Elaboración propia.

Los registros están en formato EDF+, y contienen las señales EEG de los 64 canales, cada uno muestreado a 160 Hz. Cada registro viene con un archivo de anotaciones (con el sufijo “.event”). Los archivos de anotación incluyen las siguientes etiquetas: T0, T1 y T2, las cuales aparecen de manera aleatoria durante los 2 minutos de registro de cada señal.

- **T0** corresponde a descanso (en ambas rutinas).
- **T1** corresponde a movimiento imaginario de mano izquierda (rutina 1) o ambas manos (rutina 2).
- **T2** corresponde a movimiento imaginario de mano derecha (rutina 1) o ambos pies (rutina 2).

1.2 PREPROCESAMIENTO

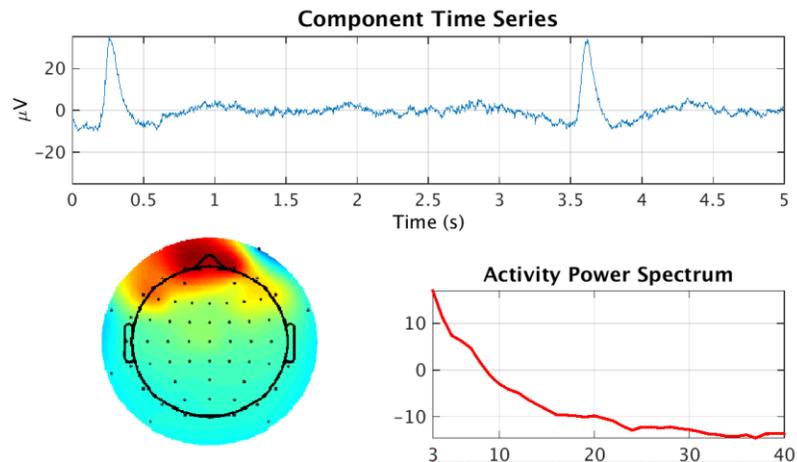
1.2.1 Filtrado

El rango de frecuencias donde se encuentra la mayor parte de la actividad cerebral relacionada a movimiento de extremidades se encuentra entre los 0.5Hz y 30HZ (Ritmos: Delta, teta, alfa y beta). Con el fin de eliminar información irrelevante y limitar las frecuencias al ancho de banda deseado, se implementó filtros FIR pasa-bajas y pasa-altas de sexto orden, además de un filtro Notch para atenuar el ruido de línea de tensión.

1.2.2 Supresión de artefactos

Al momento de la adquisición, las señales EEG son contaminadas con ruido y artefactos provenientes de otras fuentes fisiológicas, que con solo la etapa de filtrado no se eliminan. Varios métodos para suprimir artefactos han sido propuestos, pero sin duda el más recomendado en la literatura debido a los resultados entregados ha sido el Análisis de Componentes Independientes (ICA)³⁹. Este método fue aplicado a cada uno de los registros por medio del toolbox para Matlab, EEGLAB⁴⁰ y el plugin para eliminar artefactos MARA^{41 42}. El proceso de detección y eliminación de artefactos es automático, pero se realizó una inspección manual con el fin cerciorarse que las componentes a rechazar no provengan de actividad cerebral. En las figuras 14 y 15 se observan algunos ejemplos de componentes relacionadas a artefactos, las cuales deben ser rechazadas.

Figura 14. Artefacto producido por parpadeo o movimiento ocular.



Fuente: Delorme, A., & Makeig, S. (2004). EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *Journal of neuroscience methods*, 134(1), 9-21.

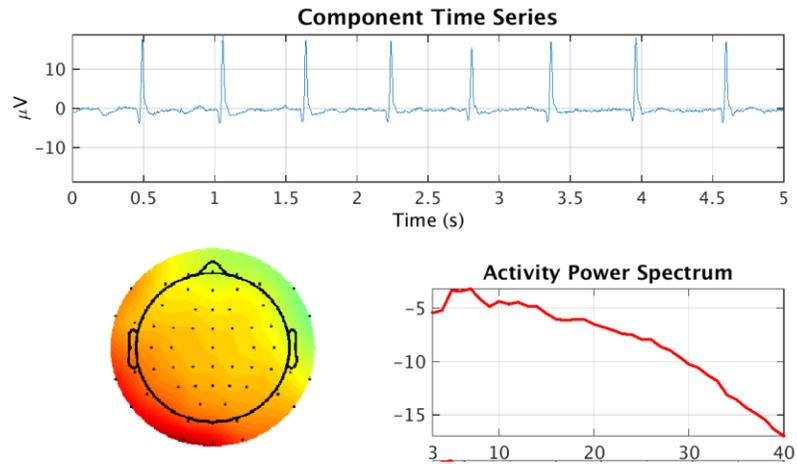
³⁹ Zou, Y., Hart, J., & Jafari, R. (2012, March). Automatic EEG artifact removal based on ICA and Hierarchical Clustering. In *2012 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 649-652). IEEE.

⁴⁰ Delorme, A., & Makeig, S. (2004). EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *Journal of neuroscience methods*, 134(1), 9-21.

⁴¹ Winkler, I., Haufe, S., & Tangermann, M. (2011). Automatic classification of artifactual ICA-components for artifact removal in EEG signals. *Behavioral and Brain Functions*, 7(1), 30.

⁴² Winkler, I., Brandl, S., Horn, F., Waldburger, E., Allefeld, C., & Tangermann, M. (2014). Robust artifactual independent component classification for BCI practitioners. *Journal of neural engineering*, 11(3), 035013.

Figura 15. Artefacto producido por señal ECG



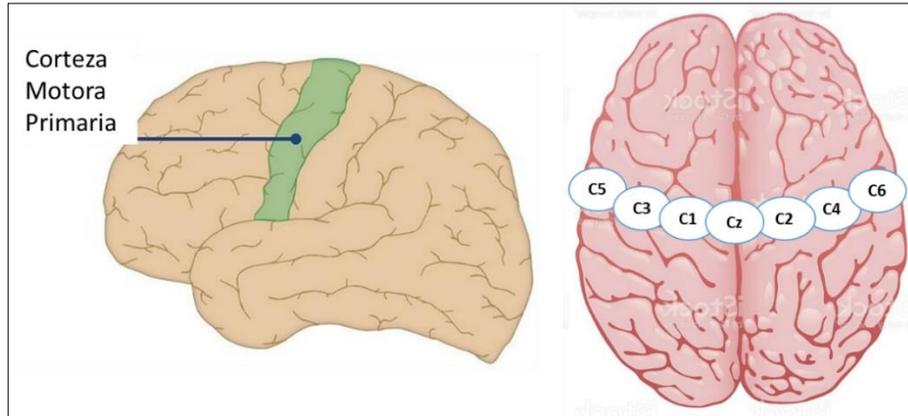
Fuente: Delorme, A., & Makeig, S. (2004). *EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis*. *Journal of neuroscience methods*, 134(1), 9-21.

Al terminar el proceso de eliminación de artefactos, se contó con una nueva base de datos, la cual fue utilizada para continuar con la metodología propuesta.

1.2.3 Selección de canales

Los registros obtenidos de la base de datos cuentan con 64 canales, provenientes de electrodos posicionados de manera estándar sobre toda la cabeza. Como se menciona en el marco teórico, las ondas alfa y beta que contienen la información relacionada a movimientos reales e imaginarios, aparecen en la corteza motora primaria, por tal motivo, en este trabajo se seleccionó los canales **C1, C2, C3, C4, C5, C6** y **Cz**, ya que estos se ubican justo por encima de esta zona como se aprecia en la figura 16, y porque los demás canales ofrecen información redundante o poco relevante.

Figura 16. Selección de canales



Fuente: Elaboración propia.

1.2.4 Normalización

Con el objetivo de quitar niveles de offset y mantener las señales a un rango de amplitud de $[-1,1]$, se aplicó una normalización usando la ecuación 1

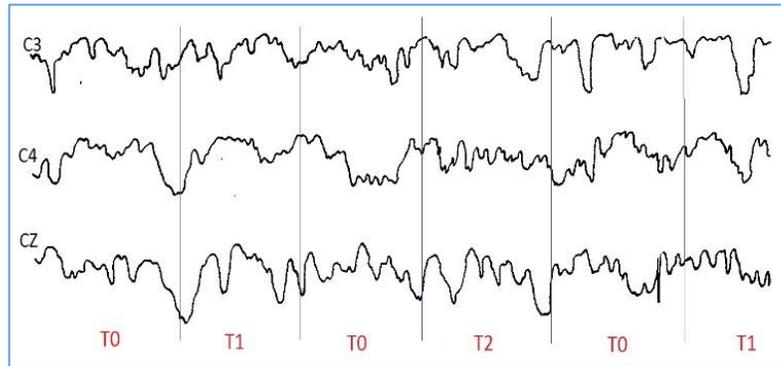
$$s = \frac{s - \underline{s}}{\max |S|} \quad (1)$$

Donde s es la señal, $\max |S|$ es el máximo valor absoluto de la señal y \underline{s} es el valor promedio de la señal.

1.2.5 Segmentación

La duración de la señal es de 2 minutos aproximadamente, cada señal contiene eventos etiquetados con los códigos T0, T1 y T2 como se menciona en el marco teórico. Los eventos T1 y T2 que corresponde a movimientos de manos o pies, tienen cada uno una duración de 4.1 segundos, mientras que el evento T0 correspondiente a descanso tiene una duración de 4.2 segundos. Estos eventos aparecen aleatoriamente durante toda la señal como se muestra en la figura 17.

Figura 17. Distribución de eventos en las señales.



Fuente: Elaboración propia.

Con el objetivo de que el sistema pueda diferenciar eventos relacionados a movimientos imaginarios de manos, se segmentó y se extrajo las partes de la señal que solo contenían las etiquetas T1 y T2. En total 14 eventos fueron extraídos de cada señal, 7 con la etiqueta T1 y 7 con la etiqueta T2. Puesto que las señales fueron muestreadas a 160Hz y cada evento tiene una duración de 4.1 segundos, se obtuvieron 7 vectores correspondientes a los canales **C1**, **C2**, **C3**, **C4**, **C5**, **C6** y **Cz**, cada vector con 14 eventos de 656 muestras cada uno. El proceso se aplicó para toda la base de datos por lo que al final se obtuvo un vector de 6860 muestras en cada una de las rutinas.

$$14 \text{ Eventos} \times 7 \text{ canales} \times 70 \text{ sujetos} = 6860 \text{ muestras}$$

1.3 CARACTERIZACIÓN

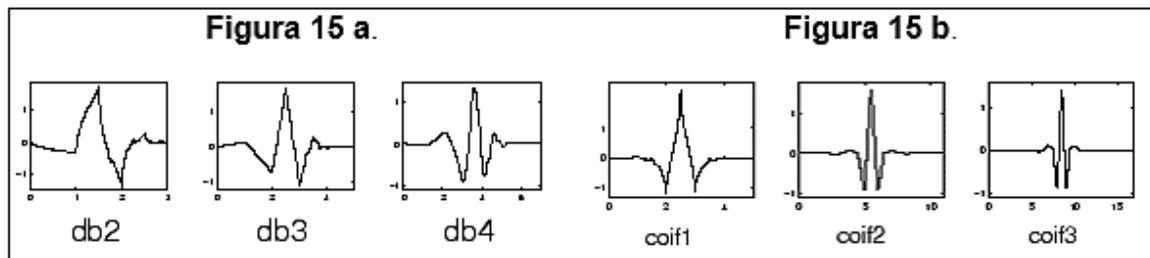
1.3.1 Descomposición en coeficientes wavelet

Los ritmos Alfa y Beta contienen frecuencias que van desde los 8Hz hasta los 25Hz, y se presentan en la corteza motora primaria del cerebro cuando se realizan tareas que involucran movimientos de las extremidades. Las BCI hacen uso de estos ritmos en las señales EEG con el propósito de encontrar patrones característicos que permitan diferenciar los movimientos de cada extremidad. En comparación con la transformada de Fourier que solo permite análisis en el dominio de la frecuencia, La transformada de wavelet permite análisis multiresolución; es decir, permite la observación del espectro en una señal y el instante de tiempo en que este ocurre, por tal motivo, es uno de los mejores métodos para descomponer y caracterizar

señales y se la considera todo un estándar en el análisis de señales fisiológicas según la literatura consultada^{43 44 45}.

El termino wavelet que significa onda pequeña, proviene de su base de análisis, que son funciones ventana de longitud finita que se localizan en el tiempo y la frecuencia lo que permite su traslación y dilatación, wavelet madre se define entonces, como el tipo onda usada para el análisis y descomposición de la señal a tratar. Existen muchas wavelet madre para analizar señales EEG pero las que han mostrado mejores resultados han sido las “Coiflets” y las “Daubechies” debido a su gran similitud morfológica^{46 47}.

Figura 18. a) Wavelets Coiflets. b) Wavelets Daubechies.



Fuente: *Introduction to the mother Wavelet. [imagen]. Mathwork. Disponible en: <https://www.mathworks.com/help/wavelet/gs/introduction-to-the-wavelet-families.html>*

En señales discretas la transformada wavelet funciona como una serie de filtros pasa-bajos y pasa-altos, con diferentes frecuencias de corte, a fin de analizar la señal en diferentes escalas. Teniendo en cuenta el teorema de Nyquist la máxima frecuencia wavelet será la mitad de la frecuencia a la que fue muestreada la señal. La señal será descompuesta en coeficientes de aproximación y detalle. El

⁴³ Ahmed, T., Islam, M., Yusuf, M. S. U., & Ahmad, M. (2013, May). Wavelet based analysis of EEG signal for evaluating mental behavior. In *2013 International Conference on Informatics, Electronics and Vision (ICIEV)* (pp. 1-6). IEEE

⁴⁴ Rafiee, J., Rafiee, M. A., Prause, N., & Schoen, M. P. (2011). Wavelet basis functions in biomedical signal processing. *Expert systems with Applications, 38*(5), 6190-6201.

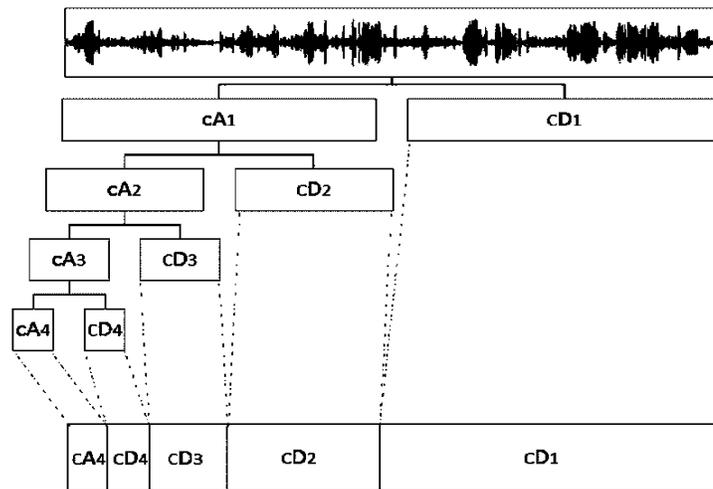
⁴⁵ Übeyli, E. D. (2008). Wavelet/mixture of experts network structure for EEG signals classification. *Expert systems with applications, 34*(3), 1954-1962.

⁴⁶ Alomari, M. H., Awada, E. A., Samaha, A., & Alkamha, K. (2014). Wavelet-based feature extraction for the analysis of EEG signals associated with imagined fists and feet movements. *Computer and Information Science, 7*(2), 17.

⁴⁷ Chavan, A., & Kolte, M. (2013). Optimal Mother Wavelet for EEG Signal Processing. *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering, 2*(12), 5959-5963.

coeficiente de aproximación contiene la información resultante del filtro pasa-bajas, el cual elimina todas las frecuencias que están por encima de la mitad de la máxima frecuencia, y el coeficiente de detalle contiene la información resultante del filtro pasa-altas, el cual elimina todas las frecuencias que están por debajo de la mitad de la máxima frecuencia. El proceso se repite con el coeficiente de aproximación resultante. Según el nivel de descomposición deseado, el proceso se repetirá nuevamente obteniendo nuevamente otros coeficientes de aproximación y detalle como se muestra en la figura 19.

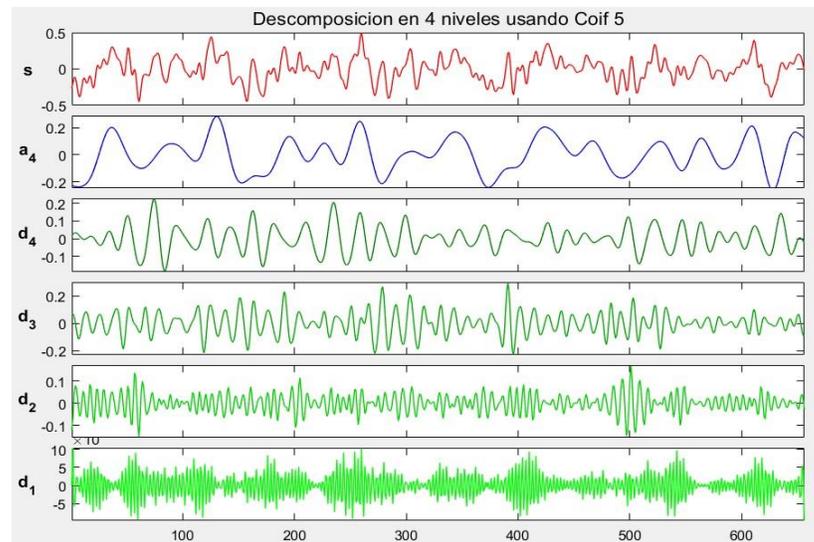
Figura 19 Descomposición en niveles wavelet.



Fuente: 1-D Wavelet Decomposition [Imagen]. Matworks. Disponible en:
<https://www.mathworks.com/help/wavelet/ref/wavedec.html>

A los eventos resultante en la sección 1.2.5, se le aplicó una descomposición de wavelet de 4 niveles, obteniéndose así 4 coeficientes de detalle ($cD1$, $cD2$, $cD3$ y $cD4$) y 1 coeficiente de aproximación ($cA1$) como se ve en la figura 20.

Figura 20. Descomposición wavelet en 4 niveles usando Coif 4, donde S es la señal y a y d son los coeficientes de aproximación y detalle respectivamente.



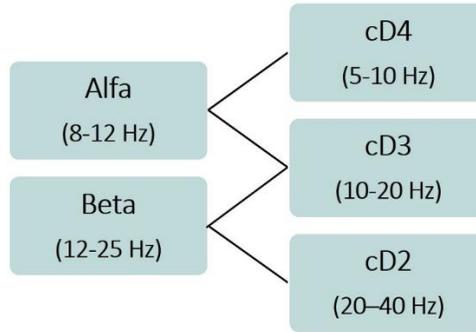
Fuente: Elaboración propia.

Teniendo en cuenta que la frecuencia de muestreo de la señal es de 160Hz, los coeficientes de aproximación y detalle de cada evento están compuestos de los siguientes rangos de frecuencias, como se muestra en la tabla 3. Sin embargo, como se pretende analizar las ondas **alfa** y **beta** por estar directamente relacionadas con actividad sensoria motriz, se escogió únicamente los coeficientes de detalle que contienen frecuencias vinculadas a estas ondas. Figura 21.

Tabla 3. Coeficientes de aproximación y detalle.

Coeficiente de la señal	Rango de frecuencias
cD1	40 – 80 Hz
cD2	20 – 40 Hz
cD3	10 – 20 Hz
cD4	5 – 10 Hz
cA4	0 – 5 Hz

Figura 21. Relación entre ondas Alfa y beta y coeficientes de detalle.



Fuente Elaboración propia.

1.3.2 Extracción de características

Dada la naturaleza eléctrica y dinámica de las señales EEG, ciertos patrones o atributos pueden ser cuantificados. Características como la energía en ciertas bandas de frecuencia, máxima frecuencia, densidad de potencia espectral, se extrajeron de las señales usando la Transformada de Fourier, adicionalmente características estadísticas como la media, la varianza, la desviación estándar, el valor RMS entre otras, fueron extraídas de las medidas espectrales y de los niveles de descomposición wavelet. Para esta investigación se tuvo en cuenta las características que brindaron mejores resultados a otros autores en sus trabajos^{48 49 50}.

Un listado de diferentes estimadores usados para caracterizar las señales de este trabajo se presenta a continuación.

- Raíz Media Cuadrada (**RMS**) $RMS_i = \sqrt{\frac{1}{N} \sum_{n=1}^N D_i^2(n)}$
- Valor Medio Absoluto (**MAV**) $MAV_i = \frac{1}{N} \sum_{n=1}^N |D_i(n)|$
- EEG integrada (**IEEG**) $IEEG_i = \sum_{n=1}^N |D_i(n)|$

⁴⁸ Alomari, M. H., AbuBaker, A., Turani, A., Baniyounes, A. M., & Manasreh, A. (2014). EEG mouse: A machine learning-based brain computer interface. *Int. J. Adv. Comput. Sci. Appl*, 5, 193-198.

⁴⁹ Übeyli, E. D. (2009). Statistics over features: EEG signals analysis. *Computers in Biology and Medicine*, 39(8), 733-741.

⁵⁰ Bajaj, V., & Pachori, R. B. (2012). EEG signal classification using empirical mode decomposition and support vector machine. In *Proceedings of the International Conference on Soft Computing for Problem Solving (SocProS 2011) December 20-22, 2011* (pp. 623-635). Springer, New Delhi.

- Integral Cuadrada Simple (**SSI**) $SSI_i = \sum_{n=1}^N |D_i(n)|^2$
- Varianza de EEG (**VAR**) $MAV_i = \frac{1}{N-1} \sum_{n=1}^N D_i^2(n)$
- Cambio de Amplitud Promedio (**AAC**) $AAC_i = \frac{1}{N} \sum_{n=1}^N |D_i(n+1) - D_i(n)|$
- Media $mean = \mu = \frac{1}{N} \sum_{n=1}^N D_i$
- Kurtosis $kurtosis = k = \frac{E(x-\mu)^4}{\sigma^4}$
- Oblicuidad $skewness = s = \frac{E(x-\mu)^3}{\sigma^3}$
- Desviación estándar $std = \sqrt{\frac{1}{N-1} \sum_{n=1}^N |A_1 - \mu|^2}$
- Shannon entropy $H(X) = -\sum_{i=0}^{N-1} P_i \log_2 P_i$

1.3.3 Selección de características

Debido a la alta dimensionalidad de los datos, la matriz de características puede contener valores redundantes e irrelevantes, provocando lentitud y aciertos erróneos en el modelo al momento de clasificar. Por tal razón fue necesario crear un subconjunto con los atributos que mejor representan los eventos a ser clasificados a fin de reducir tiempo de ejecución y costo computacional. La reducción de dimensión de la matriz y la selección de las características más representativas se realizó por medio del método **Forward Selection**.

Al final de esta etapa se contó con una matriz o subconjunto de datos que representan eventos relacionados a dos clases de movimientos y su respectivo vector de etiquetas como se muestra en la figura 22.

Figura 22. Matriz de características y vector de etiquetas.

$$X = \begin{bmatrix} 1 & x_{1,1} & x_{1,2} & \cdots & x_{1,m} \\ 1 & x_{2,1} & x_{2,2} & \cdots & x_{2,m} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n,1} & x_{n,2} & \cdots & x_{n,m} \end{bmatrix} \quad \mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}$$

Fuente: Elaboración propia.

1.4 CLASIFICACIÓN

Teniendo en cuenta la naturaleza de las señales y el paradigma experimental al momento de adquirir los datos, se necesitaba que el modelo fuese entrenado para diferenciar y predecir intenciones de movimientos, es decir, diferenciar cuando un evento pertenece a cierta clase. Por tal razón se necesitaba de algoritmos de aprendizaje supervisado que permitieran clasificar entre las clases que el modelo ha entrenado. Para esta investigación se utilizó como algoritmos de clasificación las Máquinas de Soporte Vectorial SVM, el clasificador FISHER y el clasificador LOGISTICO.

2. MARCO EXPERIMENTAL

2.1 EVALUACION Y MEDIDAS DE DESEMPEÑO

En esta sección se describe el método de evaluación y las medidas de desempeño usadas para evaluar el clasificador y su comportamiento durante las pruebas realizadas. Como método de evaluación se utilizó la matriz de confusión, debido a que es una herramienta fundamental a la hora de tratar con problemas de clasificación binaria. Usando las etiquetas producidas por el sistema, la matriz de confusión permitió distinguir entre clases verdaderas y clases predichas.

Tabla 4. Matriz de confusión

		Valor estimado	
		A	B
Valor real	A	Vp	Fn
	B	Fp	Vn

Donde:

- **A** y **B**: son las clases o eventos a clasificar (*mano derecha(A)-mano izquierda(B)* o *ambas manos(A)-ambos pies(B)*) según la rutina usada.
- **Vp**: son los verdaderos positivos o eventos clasificados correctamente.
- **Vn**: son los verdaderos negativos o eventos diferentes de la clase de interés clasificados correctamente.
- **Fp**: son los falsos positivos o eventos diferentes de la clase de interés que fueron clasificados como eventos de la clase de interés.
- **Fn**: son los falsos negativos o eventos de la clase de interés clasificados como eventos diferentes de la clase de interés.

De los anteriores casos se pueden extraer las siguientes medidas de desempeño.

- Sensibilidad (**Se**)
$$Se = \frac{Vp}{Vp+Fn}$$
- Especificidad (**Sp**)
$$Sp = \frac{Vn}{Vn+Fp}$$

- Porcentaje de clasificación (**Acc**)

$$Acc = \frac{Vn+Vp}{Vn+Vp+Vp+Fn} \times 100$$

2.2 PRUEBAS APLICADAS AL VECTOR DE CARACTERISTICAS

A los conjuntos de datos obtenidos, se les aplicó pruebas con los clasificadores **SVM**, **Fisher** y **Clasificador Logístico** con el propósito de comprobar su comportamiento y desempeño al momento de clasificar entre dos clases de movimientos imaginarios (mano izquierda-mano derecha, **rutina 1**. Ambas manos-ambos pies, **rutina 2**), la reducción y selección de las características más representativas se la realizó por el método **Forward selection**. Las pruebas realizadas se listan a continuación.

- **Experimento 1:** se clasificó los conjuntos de datos con las 20, 40, 60 y 80 mejores características, usando **SVM** y la wavelet madre **coif2**.
- **Experimento 2:** se clasificó los conjuntos de datos con las 20, 40, 60 y 80 mejores características, usando **SVM** y la wavelet madre **coif4**.
- **Experimento 3:** se clasificó los conjuntos de datos con las 20, 40, 60 y 80 mejores características, usando **SVM** y la wavelet madre **db2**.
- **Experimento 4:** se clasificó los conjuntos de datos con las 20, 40, 60 y 80 mejores características, usando **SVM** y la wavelet madre **db4**.
- **Experimento 5:** se clasificó los conjuntos de datos con las 20, 40, 60 y 80 mejores características, usando **Clasificador Fisher** y la wavelet madre **coif2**.
- **Experimento 6:** se clasificó los conjuntos de datos con las 20, 40, 60 y 80 mejores características, usando **Clasificador Fisher** y la wavelet madre **coif4**.
- **Experimento 7:** se clasificó los conjuntos de datos con las 20, 40, 60 y 80 mejores características, usando **Clasificador Fisher** y la wavelet madre **db2**.
- **Experimento 8:** se clasificó los conjuntos de datos con las 20, 40, 60 y 80 mejores características, usando **Clasificador Fisher** y la wavelet madre **db4**.
- **Experimento 9:** se clasificó los conjuntos de datos con las 20, 40, 60 y 80 mejores características, usando **Clasificador Logístico** y la wavelet madre **coif2**.

- **Experimento 10:** se clasificó los conjuntos de datos con las 20, 40, 60 y 80 mejores características, usando **Clasificador Logístico** y la wavelet madre **coif4**.
- **Experimento 11:** se clasificó los conjuntos de datos con las 20, 40, 60 y 80 mejores características, usando **Clasificador Logístico** y la wavelet madre **db2**.
- **Experimento 12:** se clasificó los conjuntos de datos con las 20, 40, 60 y 80 mejores características, usando **Clasificador Logístico** y la wavelet madre **db4**.

3 RESULTADOS

Los resultados obtenidos de cada una de las pruebas mencionadas anteriormente, se exponen a continuación por medio de tablas, teniendo en cuenta que la **rutina 1** corresponde a la base de datos con movimientos imaginarios de **mano izquierda y mano derecha**, mientras que la **rutina 2** corresponde a la base de datos con movimientos imaginarios de **ambas manos y ambos pies**.

- **Experimento 1:** En la tabla 5 se puede observar que usando la wavelet madre **coif2**, **SVM** obtuvo un acierto **Acc** del 70% al clasificar los eventos de la rutina 1 con un conjunto de datos de 80 características, la sensibilidad (**Se**) fue mayor que la especificidad (**Sp**) con un 0,72 frente a un 0,67, lo que significa que tuvo más acierto clasificando movimientos imaginarios de mano derecha que de mano izquierda. Clasificando los eventos de la rutina 2 su máximo acierto fue del 67% con 40, 60 y 80 características, en este caso la especificidad (**Sp**) fue mayor que la sensibilidad (**Se**) con un 0,73 frente a un 0,61 demostrando que fue mejor clasificando movimientos imaginarios de ambos pies.

Tabla 5. Medidas de desempeño usando coif2 y SVM.

Características usadas	Svm y Coif2					
	Rutina 1			Rutina 2		
	Se	Sp	Acc%	Se	Sp	Acc%
80	0,72	0,67	70	0,64	0,7	67
60	0,71	0,68	69	0,61	0,73	67
40	0,69	0,69	69	0,64	0,7	67
20	0,71	0,61	66	0,6	0,71	65

Fuente: Elaboración propia.

- **Experimento 2:** Usando la wavelet coif4 y con 80 características, el clasificador **SVM** obtuvo un acierto de clasificación (**Acc**) del 73% para los eventos correspondientes a la rutina 1, la sensibilidad (**Se**), fue de 0,75 y la especificidad (**Sp**) de 0,7, lo que se puede interpretar como un mejor desempeño clasificando movimientos de mano derecha que de izquierda. Para los eventos de la rutina 2 el desempeño del clasificador fue inferior, con un 68% de acierto usando 60 características.

Tabla 6. Medidas de desempeño usando coif4 y SVM

Características usadas	Svm y Coif4					
	Rutina 1			Rutina 2		
	Se	Sp	Acc%	Se	Sp	Acc%
80	0,75	0,7	73	0,65	0,67	66
60	0,73	0,69	71	0,65	0,7	68
40	0,73	0,67	70	0,62	0,72	67
20	0,67	0,65	66	0,58	0,74	66

Fuente: Elaboración propia.

- **Experimento 3:** Usando la wavelet **db2**, el desempeño del clasificador **SVM** bajó, obteniendo un acierto de clasificación (**Acc**) del 68% para la rutina 1 con 60 características y del 66% para la rutina 2 con 80 características.

Tabla 7. Medidas de desempeño usando db2 y SVM.

Características usadas	Svm y db2					
	Rutina 1			Rutina 2		
	Se	Sp	ACC%	Se	Sp	ACC%
80	0,63	0,63	63	0,61	0,7	66
60	0,66	0,69	68	0,6	0,67	63
40	0,66	0,66	66	0,62	0,68	65
20	0,63	0,62	63	0,6	0,61	61

Fuente: Elaboración propia.

- **Experimento 4.** En la tabla 8 se puede observar que el desempeño del clasificador **SVM** usando **Db4** fue mejor al aplicarlo a los eventos de la rutina 2, obteniendo un desempeño del 70% con 40 características y del 65% para la rutina 1 con 80 características. La especificidad (**Sp**) fue más alta en la rutina 2 con un valor de 0,73, lo que se traduce a un mejor desempeño clasificando movimientos de ambos pies.

Tabla 8. Medidas de desempeño usando db4 y SVM

Características usadas	Svm y db4					
	Rutina 1			Rutina 2		
	Se	Sp	ACC%	Se	Sp	ACC%
80	0,64	0,67	65	0,67	0,71	69
60	0,64	0,64	64	0,62	0,72	67
40	0,62	0,64	63	0,66	0,73	70
20	0,62	0,64	63	0,64	0,68	66

Fuente: Elaboración propia.

- **Experimento 5.** Usando wavelet **coif2** como método de descomposición de las señales, el mejor desempeño del clasificador **Fisher** para las rutinas 1 y 2 fue del 71% y 69% respectivamente, usando las mejores 80 características para ambos casos. La sensibilidad (**Se**) y especificidad (**Sp**) en la rutina 1 fue del 0,71 para las dos, lo que quiere decir que el clasificador clasifico la misma cantidad de eventos de mano derecha que de mano izquierda.

Tabla 9. Medidas de desempeño usando coif2 y Clasificador Fisher.

Características usadas	Fisher y Coif2					
	Rutina 1			Rutina 2		
	Se	Sp	ACC%	Se	Sp	ACC%
80	0,71	0,71	71	0,67	0,7	69
60	0,7	0,68	69	0,64	0,69	67
40	0,71	0,65	68	0,66	0,7	68
20	0,68	0,63	66	0,63	0,7	66

Fuente: Elaboración propia.

- **Experimento 6.** El desempeño del clasificador **Fisher** con la wavelet **coif4** fue mejor para la rutina 1, con un acierto de clasificación (**Acc**) del 72% y una especificidad (**Sp**) de 0,73 usando 80 características, lo que significa que fue mejor clasificando movimientos de mano izquierda. Para la rutina 2 el acierto fue de 70% y la especificidad de 0,73 siendo mejor clasificando movimientos de ambos pies.

Tabla 10. Medidas de desempeño usando coif4 y Clasificador Fisher.

Características usadas	Fisher y coif4					
	Rutina 1			Rutina 2		
	Se	Sp	ACC%	Se	Sp	ACC%
80	0,71	0,73	72	0,67	0,73	70
60	0,72	0,7	71	0,65	0,72	69
40	0,71	0,68	70	0,66	0,71	68
20	0,63	0,64	64	0,63	0,7	67

Fuente: Elaboración propia.

- **Experimento 7.** El máximo acierto del clasificador **Fisher** con **db2** fue del 68% para la rutina 1 usando 80 características y del 66% para la rutina 2 con 60 y 80 características.

Tabla 11. Medidas de desempeño usando db2 y Clasificador Fisher.

Características usadas	Fisher y db2					
	Rutina 1			Rutina 2		
	Se	Sp	ACC%	Se	Sp	ACC%
80	0,67	0,69	68	0,65	0,67	66
60	0,65	0,7	67	0,65	0,68	66
40	0,65	0,66	65	0,63	0,67	65
20	0,64	0,65	64	0,59	0,61	60

Fuente: Elaboración propia.

- **Experimento 8.** En la tabla 12 se observa que el mejor desempeño del clasificador **Fisher** usando la wavelet **db4**, fue para la rutina 2 con 40 y 60 características, obteniendo un acierto (**Acc**) del 69% para ambos casos. Para la rutina 1 el mejor porcentaje de acierto fue del 67% usando 60 y 80 características.

Tabla 12. Medidas de desempeño usando db4 y Clasificador Fisher.

Características usadas	Fisher y db4					
	Rutina 1			Rutina 2		
	Se	Sp	ACC%	Se	Sp	ACC%
80	0,65	0,68	67	0,68	0,69	68
60	0,66	0,67	67	0,66	0,71	69
40	0,66	0,63	65	0,66	0,71	69
20	0,62	0,64	63	0,61	0,7	66

Fuente: Elaboración propia.

- **Experimento 9.** Usando la wavelet **coif2**, el clasificador **Logístico** obtuvo un acierto de clasificación (**Acc**) del 73% para los eventos de la rutina 1 con 80 características, y para los eventos de la rutina 2 el acierto fue del 69%, con igual número de características que la rutina 1.

Tabla 13. Medidas de desempeño usando coif2 y Clasificador Logístico.

Características usadas	Logistic y Coif2					
	Rutina 1			Rutina 2		
	Se	Sp	ACC%	Se	Sp	ACC%
80	0,73	0,72	73	0,66	0,71	69
60	0,72	0,68	70	0,63	0,69	66
40	0,7	0,66	68	0,68	0,68	68
20	0,67	0,65	66	0,62	0,69	66

Fuente: Elaboración propia.

- **Experimento 10.** En la tabla 14 se puede observar que el mejor porcentaje de clasificación usando la wavelet **coif4** y clasificador **Logístico**, fue para los eventos de la rutina 1 con un 72% y 80 características usadas, la sensibilidad (**Se**) fue de 0,74 clasificando mejores movimientos de mano derecha. Para los eventos de la rutina 2 el porcentaje de clasificación fue del 70% también con 80 características.

Tabla 14. Medidas de desempeño usando coif4 y Clasificador Logístico.

Características usadas	Logistic y Coif4					
	Rutina 1			Rutina 2		
	Se	Sp	ACC%	Se	Sp	ACC%
80	0,74	0,71	72	0,66	0,73	70
60	0,71	0,71	71	0,66	0,69	68
40	0,71	0,7	70	0,68	0,7	69
20	0,63	0,63	63	0,63	0,71	67

Fuente: Elaboración propia.

- **Experimento 11.** El desempeño del clasificador **Logístico** usando wavelet **db2**, fue mejor para la rutina 1 con un acierto (**Acc**) del 69% usando 80 características y del 66% para la rutina 2 con igual número de características que la rutina 1.

Tabla 15. Medidas de desempeño usando db2 y Clasificador Logístico.

Características usadas	Logistic y db2					
	Rutina 1			Rutina 2		
	Se	Sp	ACC%	Se	Sp	ACC%
80	0,69	0,68	69	0,64	0,67	66
60	0,65	0,7	68	0,64	0,66	65
40	0,66	0,67	67	0,63	0,68	66
20	0,65	0,65	65	0,62	0,62	62

Fuente: Elaboración propia.

- **Experimento 12.** El clasificador Logístico usando la wavelet madre db4 y 60 características obtuvo mejor desempeño para la rutina 2 con un acierto de clasificación (**Acc**) del 70% y especificidad (**Sp**) de (0,71) clasificando mejor los movimientos de ambos pies que de ambas manos. Para la rutina 1 el mejor acierto de clasificación fue del 67% con 80 características usadas

Tabla 16. Medidas de desempeño usando db4 y Clasificador Fisher.

Características usadas	Logistic y db4					
	Rutina 1			Rutina 2		
	Se	Sp	ACC%	Se	Sp	ACC%
80	0,65	0,69	67	0,67	0,71	69
60	0,66	0,66	66	0,69	0,71	70
40	0,62	0,67	64	0,65	0,69	67
20	0,62	0,63	63	0,62	0,68	65

Fuente: Elaboración propia.

En la tabla 17 se observa los resultados de las pruebas aplicadas al conjunto de datos de la **rutina 1**. Los dos máximos porcentajes de clasificación se obtuvieron usando **SVM** con wavelet **Coif4** y clasificador **Logístico** con wavelet **Coif2**, ambos con igual número de características. Usando SVM la sensibilidad (**Se**) fue de 0,75 contra un 0,70 de especificidad (**Sp**), lo que nos dice que se tuvieron más aciertos clasificando movimientos de mano derecha que de izquierda.

Tabla 17. Mejores desempeños de los clasificadores para los eventos de la rutina 1.

Rutina 1 (mano derecha / mano izquierda)					
Clasificador	Wavelet	Características	Se	Sp	Acc%
Svm	Coif4	80	0,75	0,7	73
Logistic	coif2	80	0,73	0,72	73
Fisher	coif4	80	0,71	0,73	72
Logistic	coif4	80	0,74	0,71	72
Fisher	coif2	80	0,71	0,71	71
Svm	coif2	80	0,72	0,67	70

Fuente: Elaboración propia.

En la tabla 18 se puede observar los resultados de las pruebas aplicadas al conjunto de datos de la rutina 2. El desempeño fue muy similar para los clasificadores, **SVM**, **Fisher** y **Logístico**. **SVM** usando wavelet **Db4** y las mejores 40 características, obtuvo un acierto de clasificación del 70%. **Fisher** con wavelet **Coif4** y 80 características obtuvo el mismo porcentaje de clasificación que **SVM**. El clasificador **Logístico** no obtuvo aciertos de clasificación diferentes al usar wavelet **Db4** y **Coif4** con 60 y 80 características respectivamente, obteniendo también un acierto máximo de clasificación del 70%.

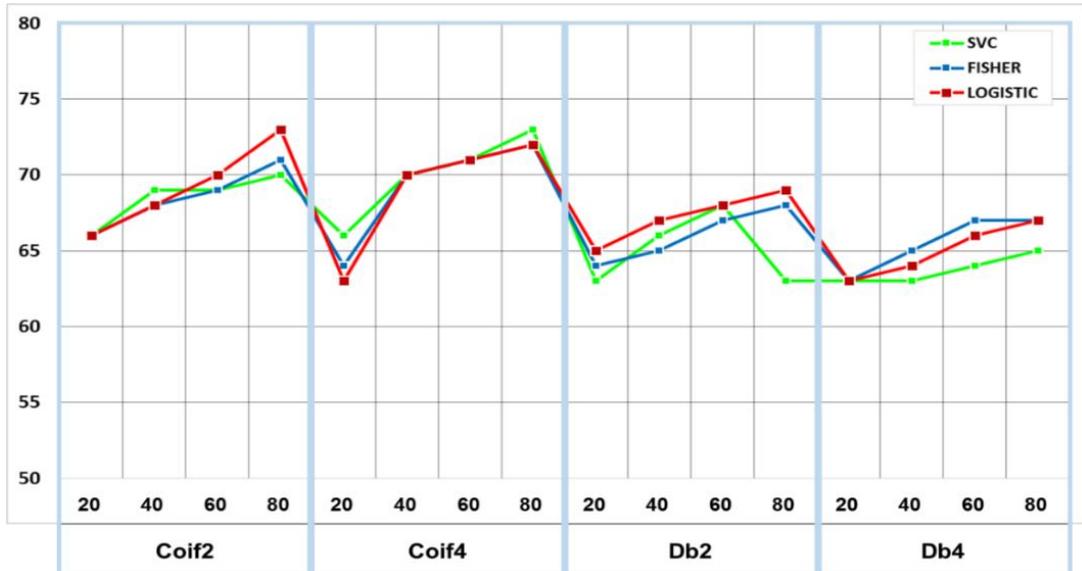
Tabla 18. Mejores desempeños de los clasificadores para los eventos de la rutina 2.

Rutina 2 (ambas manos / ambos pies)					
Clasificador	Wavelet	Características	Se	Sp	Acc%
Svm	db4	40	0,66	0,73	70
Logistic	db4	60	0,69	0,71	70
Fisher	Coif4	80	0,67	0,73	70
Logistic	Coif4	80	0,66	0,73	70
Fisher	db4	40	0,66	0,71	69
Logistic	coif2	80	0,66	0,71	69
Fisher	coif2	80	0,67	0,7	69

Fuente: Elaboración propia.

En la figura 23 se puede observar de mejor manera los resultados obtenidos en las pruebas realizadas para la rutina 1, con cada uno de los clasificadores, wavelet madre y cantidad de características usadas. Se aprecia que el comportamiento del clasificador SVM es mejor con 80 características y el máximo desempeño se obtiene cuando las señales o eventos fueron descompuestos usando la wavelet madre coif4. Por otra parte, el clasificador Logístico obtuvo el mejor porcentaje de clasificación cuando las señales fueron descompuestas con la wavelet coif2 y se usaron igual número de características que el anterior. Se concluye entonces que clasificando movimientos imaginarios de mano derecha y mano izquierda los clasificadores SVM y Logístico obtuvieron el mismo desempeño

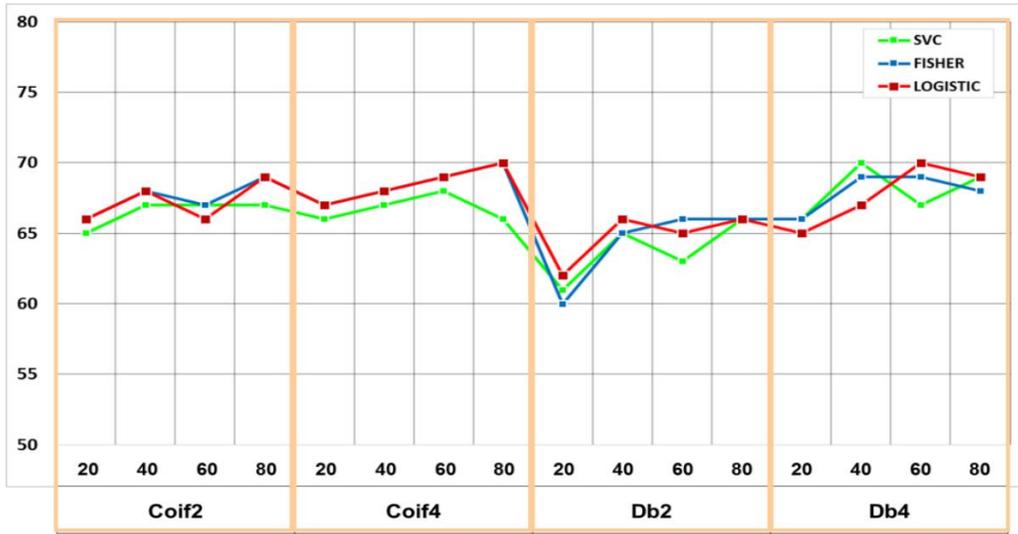
Figura 23. Gráfica de comportamiento de los clasificadores con la rutina 1.



Fuente: Elaboración propia.

En la figura 24 se observa que en comparación con los resultados obtenidos en la rutina 1, en estos experimentos el porcentaje de clasificación fue más bajo, pero los tres clasificadores lograron un acierto del 70% en diferentes configuraciones. Para SVM fue mejor usando 40 características y con wavelet madre db4 como método descomposición de la señal, para el clasificador Fisher usando 80 características y con wavelet madre coif4 y por último el clasificador Logístico fue mejor con la wavelet coif4 y la wavelet db4 usando 80 y 60 características respectivamente.

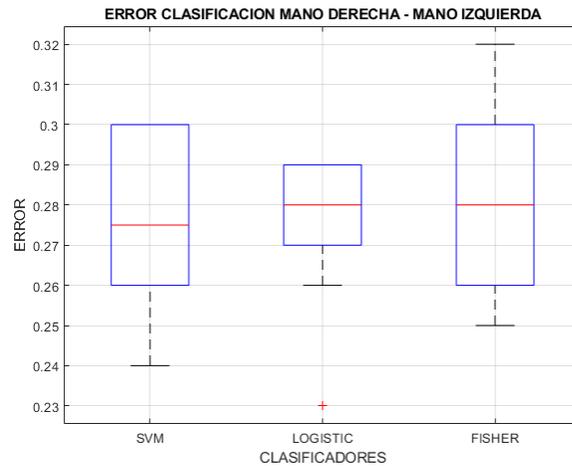
Figura 24. Gráfica de comportamiento de los clasificadores con la rutina 2.



Fuente: Elaboración propia.

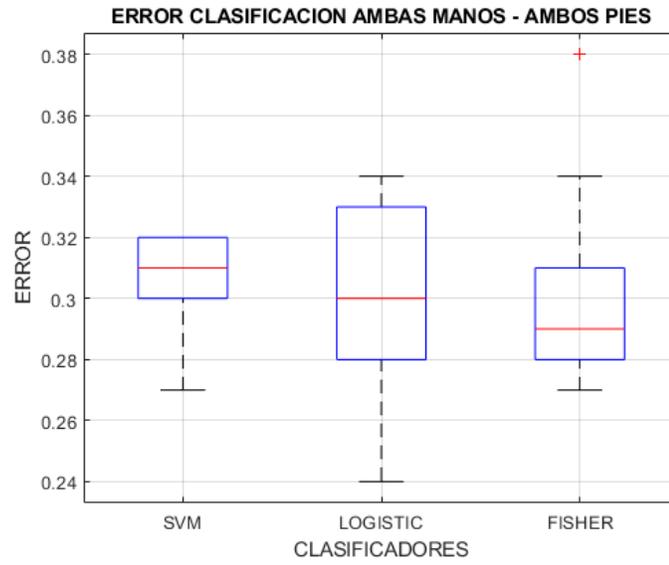
Las figuras 25 y 26 muestran el error de los clasificadores usados para los experimentos de la rutina 1 y la rutina 2 respectivamente. El error se obtiene al promediar 20 iteraciones o ejecuciones del clasificador.

Figura 25 Error de clasificación para la rutina 1.



Fuente: Elaboración propia.

Figura 26 Error de clasificación para la rutina 2.



Fuente: Elaboración propia

4 CONCLUSIONES Y TRABAJO FUTURO

- Una vez finalizadas las pruebas se puede concluir en términos generales que, aunque los resultados no cumplieron con las expectativas que se tenían al momento de iniciar esta investigación, el proceso y la metodología desarrollada brindaron una adquisición de conocimiento y experiencia que motivan a seguir trabajando a fin de mejorar los resultados obtenidos.
- Las señales EEG usadas en esta investigación fueron adquiridas siguiendo cierto protocolo experimental. Al tratarse de movimientos imaginarios nada garantiza que en verdad los voluntarios estaban ejecutando estas tareas; es decir, cuando se trata de señales que contienen potenciales evocados hay certeza de que un estímulo externo provocará cierto nivel de actividad en el cerebro, pero en este caso queda en pie la inquietud, puesto que para provocar actividad cerebral sin estímulo y solo imaginándolo es necesario un entrenamiento previo hasta que el usuario adquiera la habilidad de generar esos potenciales.
- La naturaleza de las señales EEG es compleja y de difícil tratamiento, en este trabajo se utilizó una base de datos que contenía registros EEG, sin antes haber pasado por una etapa de pre-procesado. La cantidad de artefactos que la señal contrajo durante su adquisición pudo haber repercutido directamente en la señal y en la posibilidad de realizar una extracción de características representativas.
- La caracterización es parte fundamental al momento de clasificar señales EEG, aunque se extrajeron características que fueron usadas en trabajos similares y con las cuales se obtuvo buenos desempeños de clasificación, se comprobó que se necesita explorar otras características que permitan una adquisición de patrones más representativos de las señales EEG a clasificar.
- Los clasificadores **SVM** y **Logístico** obtuvieron desempeños similares en términos generales durante todos los experimentos de la rutina 1, sin embargo, los mejores porcentajes de clasificación para ambos fue de 73%, **SVM** con 60 características y clasificador **Logístico** 80 características.
- Se comprobó que los mejores porcentajes de clasificación se obtuvieron en las pruebas realizadas a la rutina 1, con lo que se concluye que el sistema

- es mejor al clasificar movimientos imaginarios de mano derecha o mano izquierda.
- Se recomienda implementar la metodología usada con otras bases de datos y usando diferentes algoritmos clasificadores.

BIBLIOGRAFÍA

1-D Wavelet Decomposition [Imagen]. Matworks. Disponible en: <https://www.mathworks.com/help/wavelet/ref/wavedec.html>

Action potential and how neurons fire. Verywell mind [en línea], [revisado: 13 agosto 2018]. Disponible en: <https://www.verywellmind.com/what-is-an-action-potential-2794811>

Ahmed, T., Islam, M., Yusuf, M. S. U., & Ahmad, M. (2013, May). Wavelet based analysis of EEG signal for evaluating mental behavior. In *2013 International Conference on Informatics, Electronics and Vision (ICIEV)* (pp. 1-6). IEEE.

Alomari, M. H., AbuBaker, A., Turani, A., Baniyounes, A. M., & Manasreh, A. (2014). EEG mouse: A machine learning-based brain computer interface. *Int. J. Adv. Comput. Sci. Appl*, 5, 193-198.

Alomari, M. H., Awada, E. A., Samaha, A., & Alkamha, K. (2014). Wavelet-based feature extraction for the analysis of EEG signals associated with imagined fists and feet movements. *Computer and Information Science*, 7(2), 17.

BAARS, Bernard J., CAGE, Nicole M. Chapter 5 – *Braining Imaging* [En línea]. En: *Fundamentals of Cognitive Neuroscience: A Beginner's Guide*. Academic Press. 2013. P. 109-140. [Consultado: 20 de septiembre de 2018]. Disponible en: <https://www.sciencedirect.com/science/article/pii/B9780124158054000059>. ISBN: 978-0-12-425805-4.

Bajaj, V., & Pachori, R. B. (2012). EEG signal classification using empirical mode decomposition and support vector machine. In *Proceedings of the International Conference on Soft Computing for Problem Solving (SocProS 2011) December 20-22, 2011* (pp. 623-635). Springer, New Delhi/BCI2000, Ncan Schalk Lab. [En línea]. Disponible en internet en: <http://www.schalklab.org/research/bci2000>

BOLY, Melanie, GOSSERIES, Oliva, MASSIMINI, Marcello, ROSANOVA, Mario. Chapter 2 – *Functional Neuroimaging Techniques* [en línea]. En: LAUREYS, Steven, GOSSERIES, Olivia, TONONI, Giulio. *The Neurology of Consciousness: Cognitive neuroscience and neuropathology*. 2da edición. Academy Press. 1 septiembre de 2015. P. 31-47. [Consultado: 20 de septiembre de 2018]. Disponible en: <https://www.sciencedirect.com/science/article/pii/B9780128009482000029> ISBN: 9780128011751

Chan, A. T., Quiroz, J. C., Dascalu, S., & Harris, F. C. (2015). An overview of brain computer interfaces. In *Proc. 30th Int. Conf. on Computers and Their Applications*.

Chavan, A., & Kolte, M. (2013). Optimal Mother Wavelet for EEG Signal Processing. *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, 2(12), 5959-5963.

Clinical Electroencephalography and Nocturnal epilepsy [En línea]. [Consultado septiembre de 2018]. Disponible en internet: <https://neupsykey.com/clinical-electroencephalography-and-nocturnal-epilepsy/>.

Cortés, J. A., Medina, F. A., & Chaves, J. A. (2007). Del análisis de fourier a las wavelets análisis de fourier. *Scientia et technica*, 1(34).

Costa, Á., Asín-Prieto, G., Shimoda, S., Iáñez, E., Moreno, J. C., Pons, J. L., & Azorín, J. M. INTEGRACION DE INTERFAZ CEREBRO-COMPUTADOR Y EXOESQUELETO DE MIEMBRO INFERIOR ORIENTADO A LA REHABILITACION.

Delorme, A., & Makeig, S. (2004). EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *Journal of neuroscience methods*, 134(1), 9-21.

DIEZ, Pablo F., MUT, Vicente, LACIAR, Eric, AVILA, Enrique. A comparison of monopolar and bipolar EEG recordings for SSVEP detection. 2010. PMID: 21096910.

Electroencephalogram (EEG). [En línea]. [Consultado: 26 Jul. 2017]. Disponible en: <http://www.saintlukeshealthsystem.org/health-library/electroencephalogram-eeeg>

Fast Fourier Transform FFT-Basics. [en línea]. Disponible en internet: <https://www.nti-audio.com/en/support/know-how/fast-fourier-transform-fft>

Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PCh, Mark RG, Mietus JE, Moody GB, Peng C-K, Stanley HE. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation* 101(23):e215-e220 [Circulation Electronic Pages; <http://circ.ahajournals.org/cgi/content/full/101/23/e215>]; 2000 (June 13).

GUGER, christoph, KAPPELLER, Christoph, OGAWA, Hiroshi, PRUCKL, Robert, GRUNWALD, Johannes, KAMADA, Kyousuke. Chapter 9 – Electroencephalogram base brain-computer Interfaces [en línea]. En: DIEZ, Pablo. *Smart Wheelchairs and Brain-Computer Interfaces: Mobile Assistive Technologies*. Academic Press. 2018. P. 197-

227. [Consultado 20 de septiembre de 2018]. Disponible en: <https://www.sciencedirect.com/science/article/pii/B9780128128923000091> ISBN: 978-0-12-812892-3.

GUTIERREZ MARTINEZ, Josefina, CANTILLO NEGRETE, Jessica, CARIÑO ESCOBAR, Ruben, ELIAS VIÑAS, David. *Los sistemas de interfaz cerebro-computadora: una herramienta para apoyar la rehabilitación de pacientes con discapacidad motora*. En: *Investigación en discapacidad*. Vol. 2, No 2 (mayo-agosto. 2013); p. 62-69.

HEHE, Joshua. Brain waves [Imagen]. Gamma Brainwaves –The science of Enlightened Minds. Sep. 15, 2018. [Consultado septiembre de 2018]. Disponible en Internet: <https://medium.com/@joshuashawnmichaelhehe/gamma-brainwaves-be319acf6dea>

Hornero, Roberto, Corralejo, Rebeca, Álvarez, Daniel. *Brain-Computer Interface (BCI) aplicado al entrenamiento cognitivo y control domótico para prevenir los efectos del envejecimiento* [en línea]. Lychnos, 3 junio de 2018 [Consultado 3 junio 2017]. Disponible en internet: http://www.fgcsic.es/lychnos/es_es/articulos/Brain-Computer-Interface-aplicado-al-entrenamiento-cognitivo

How neurons communicate. Lumen Boundles Biology [en línea], [revisado septiembre 15 de 2018]. Disponible en: <https://courses.lumenlearning.com/boundless-biology/chapter/how-neurons-communicate/>

Ibáñez Álvaro (2013). BrainAble: un proyecto cerebro-ordenador para personas con discapacidad funcional severa (23.05.2013) <http://www.rtve.es/noticias/20130523/brainable-proyecto-cerebro-ordenador-para-personas-discapacidad-funcional-severa/669780.shtml>

Introduciont to the mother Wavelet. [imagen]. Mathwork. Disponible en: <https://www.mathworks.com/help/wavelet/gs/introduction-to-the-wavelet-families.html>

KLEM, George H., LUDERS, Hans Otto, JASPER, H.H., ELGER, C. The ten-twenty electrode system of the International Federation. 1999.

Kouro, S., & Musalem, R. (2002). Tutorial introductorio a la Teoría de Wavelet. *Artículo presentado como trabajo de la asignatura Técnicas Modernas en Automática*.

KROPOTOV, Juri D. Functional Neuromarkes for psychiatry – Applications for diagnosis and treatment. Academic press. 2016. ISBN: 978-0-12-425805-4.

KULKARNI, Nilesh, BAIRAGI, Vinayak. Chapter Two – Electroencephalogram and Its Use in Clinical Neuroscience [En línea]. En: EEG-Based Diagnosis of Alzheimer Disease. Academic Press. 2018. P. 25-35. ISBN: 978-0-12-815392-5.

KUMAR, Satheesh J., BHUVANESWARI, P. Analysis of electroencephalography (EEG) signals and its categorization-A study. En: Procedia Engineering. 2012. Volume 38. P. 2525-2536. ISSN: 1877-7058

La neurona. Ambientech [imagen]. Disponible en: <https://ambientech.org/blog/la-neurona/>

Martínez, J., & Castro, J. (1995). Análisis de la teoría de ondículas orientada a las aplicaciones en ingeniería eléctrica: Fundamentos. *ETS Industriales Departamento de Ingeniería Eléctrica, Madrid*.

Neuron action potentials: The creation of a brain signal. Khan Academy [en línea], [revisado: 9 agosto 2018]. Disponible en: <https://www.khanacademy.org/test-prep/mcat/organ-systems/neuron-membrane-potentials/a/neuron-action-potentials-the-creation-of-a-brain-signal>

Neurons and their role in the nervous system. Verywell mind [en línea], [Revisado: 13 agosto 2018]. Disponible en: <https://www.verywellmind.com/what-is-a-neuron-2794890>

Rafiee, J., Rafiee, M. A., Prause, N., & Schoen, M. P. (2011). Wavelet basis functions in biomedical signal processing. *Expert systems with Applications*, 38(5), 6190-6201.

RAMOS ARGUELLES, F., MORALES, G., EGOZCUE, S., PABON, R. M., ALONSO, M. T. *Técnicas básicas de electroencefalografía: principios y aplicaciones clínicas*. En: Sist. Sanit. Navar. No 32 (supl. 3. 2009); p. 69-82.

SAAB, Marc. Basic concepts of surface Electroencephalography and Signal Processing as Applied to the Practice of Biofeedback. Special issue. Vol. 36. 2009. P. 128-133.

Sanei, S., & Chambers, J. A. (2013). *EEG signal processing*. John Wiley & Sons.

SANTANA, D., RAMIREZ, M., OSTROSKY SOLIS, F. *Novedades en tecnología de la rehabilitación: una revisión acerca de la interfaz cerebro-computadora*. En: Revista de Neurología. No 39 (5, 2005); p. 447-450.

Schalk, G., McFarland, D.J., Hinterberger, T., Birbaumer, N., Wolpaw, J.R. BCI2000: A General-Purpose Brain-Computer Interface (BCI) System. IEEE Transactions on Biomedical Engineering 51(6):1034-1043, 2004. [In 2008, this paper received the Best Paper Award from IEEE TBME.]

SEECK M., KOESSLER, L., BAST, T., LEIJTEN, F., MICHEL, C., BAUMGARTNER, C., HE, B., BENICZKY, S. The standardized EEG electrode array of the IFCN. Clinical Neurophysiology. Vol. 128. October 2017. P. 2070-2077. ISBN: 1388-2457.

SERRANO, J. Ignacio, DEL CASTILLO, M. Dolores, RAYA, Rafael, BAYÓN, Cristina, ROCON, Eduardo. *BCI basado en la facilitación asociativa de la actividad cortical para el inicio de la marcha en Parálisis Cerebral*. En: Cognitive Area Networks. Vol. 2, No 1 (Junio. 2015); p. 31-34.

SIDELKIVSKA, Valerie. Neuroimaging: *What is it and how can it map the brain?* Cognifit: health, brain & neuroscience [en línea], Agosto 4 de 2017 [Revisado: septiembre de 2018]. Disponible en: <https://blog.cognifit.com/neuroimaging/>

Silva-Sauer, L. D., Valero-Aguayo, L., Velasco-Álvarez, F., Ron-Angevin, R., & Sancha-Ros, S. (2013). Brain-computer interface: Proposal of a shaping-based training. *Revista Brasileira de Engenharia Biomédica*, 29(2), 123-132.

SUTHERLING, William. Magnetoencephalography [en línea]. En: AMINOFF, Michael. *Aminoff's Electrodiagnosis in clinical neurology*. 6ta edición. San Francisco, California: Elsevier Saunders, 2012. P. 219-229. [Consultado: 20 de septiembre de 2018]. Disponible en Internet: <https://www.sciencedirect.com/science/article/pii/B9781455703081000108>. ISBN: 9781455726796.

The international system 10-20 [Imagen]. National Center for Adaptive Neurotechnologies. [consultado septiembre de 2018]. Disponible en internet: https://www.bci2000.org/mediawiki/index.php/User_Tutorial:EEG_Measurement_Setup

The nervous system and nervous tissue. Anatomy and physiology [en línea], [revisado septiembre 15 de 2018]. Disponible en: <https://opentextbc.ca/anatomyandphysiology/chapter/12-4-the-action-potential/>

UBEDA, Andrés, AZORIN, José M., RAYA, Rafael, CERES, Ramón, BRUNETTI, Fernando, NUNES, Margarita, AZEVEDO, Luis. *Plataforma iberada de acceso alternativo al computador para personas con discapacidad*. En: Cognitive Area Networks. Vol. 2, No 1 (Junio. 2015); p. 9-14.

Übeyli, E. D. (2008). Wavelet/mixture of experts network structure for EEG signals classification. *Expert systems with applications*, 34(3), 1954-1962.

Übeyli, E. D. (2009). Statistics over features: EEG signals analysis. *Computers in Biology and Medicine*, 39(8), 733-741.

Winkler, I., Brandl, S., Horn, F., Waldburger, E., Allefeld, C., & Tangermann, M. (2014). Robust artifactual independent component classification for BCI practitioners. *Journal of neural engineering*, 11(3), 035013.

Winkler, I., Haufe, S., & Tangermann, M. (2011). Automatic classification of artifactual ICA-components for artifact removal in EEG signals. *Behavioral and Brain Functions*, 7(1), 30.

Zou, Y., Hart, J., & Jafari, R. (2012, March). Automatic EEG artifact removal based on ICA and Hierarchical Clustering. In *2012 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 649-652). IEEE.

ANEXOS

En esta sección ha sido destinada a los resultados tangibles logrados durante el proceso de esta investigación. Estos anexos contienen una descripción ampliada de los resultados obtenidos en el capítulo 6.

ANEXO 1. Código fuente para la caracterización y clasificación de señales EEG para aplicaciones de interfaz cerebro computador BCI.

1. Algoritmo para la carga de archivos.

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%
% CARGA DE ARCHIVOS, SELECCION DE CANALES%
% Y SEGMENTACIÓN DE LA SEÑAL EN EVENTOS %
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%
clear all
clc;
archivos = dir('* .edf'); %lectura de archivos .edf
header = dir('* .event'); %lectura de los archivos de etiquetas
n=70; %Numero de archivos ó voluntarios a utilizar.
f1=1;
    eventos_C1={zeros};
    eventos_C2={zeros};
    eventos_C3={zeros};
    eventos_C4={zeros};
    eventos_C5={zeros};
    eventos_C6={zeros};
    eventos_Cz={zeros};
    Etiquetas={};

for i=1:n
    F=(header(i).name);
    fid=fopen(F);
    C = textscan(fid, '%s');
    C{1}(1)=[];
    C=C{1,1}(3:2:61,:);
    event=zeros;
    duration=zeros;
    starttime=zeros;
    t1=zeros;
    t2=zeros;
    event(1,1)=str2double(C{1,1}(18));
```

```

for j=2:length(C)
    event(j,1)=str2double(C{j,1}(9));
    t(j,:)=regexp(C{j,1},'\d*', 'Match');
    t1(:,j)=str2double(t{j,1});
    t2(:,j)=str2double(t{j,2});
    duration(j,:)=t1(1,j)+(t2(1,j)./10);
    starttime(j)=sum(duration(1:j,1));
end

```

2. Algoritmo para la selección de los canales.

```

%%%%%%%%%%
% SELECCIÓN DE CANALES %
%%%%%%%%%%

```

```

[v,d]=ReadEDF(archivos(i).name);
C1=v{1,10};
C2=v{1,12};
C3=v{1,9};
C4=v{1,13};
C5=v{1,8};
C6=v{1,14};
Cz=v{1,11};
minvalC1=min(C1);
maxvalC1=max(C1);
C1_norm=(2*(C1-minvalC1)/(maxvalC1-minvalC1))-1;
minvalC2=min(C2);
maxvalC2=max(C2);
C2_norm=(2*(C2-minvalC2)/(maxvalC2-minvalC2))-1;
minvalC3=min(C3);
maxvalC3=max(C3);
C3_norm=(2*(C3-minvalC3)/(maxvalC3-minvalC3))-1;
minvalCz=min(Cz);
maxvalCz=max(Cz);
Cz_norm=(2*(Cz-minvalCz)/(maxvalCz-minvalCz))-1;
minvalC4=min(C4);
maxvalC4=max(C4);
C4_norm=(2*(C4-minvalC4)/(maxvalC4-minvalC4))-1;
minvalC5=min(C5);
maxvalC5=max(C5);
C5_norm=(2*(C5-minvalC5)/(maxvalC5-minvalC5))-1;
minvalC6=min(C6);
maxvalC6=max(C6);

```

```

C6_norm=(2*(C6-minvalC6)/(maxvalC6-minvalC6))-1;
C1=C1_norm;
C2=C2_norm;
C3=C3_norm;
C4=C4_norm;
C5=C5_norm;
C6=C6_norm;
Cz=Cz_norm;

```

3. Algoritmo para la extracción de eventos y creación del vector de etiquetas.

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% EXTRACCIÓN DE EVENTOS %
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

```

for k=2:2:28
    event_label=event(k,1);
    if event_label == 1
        Etiquetas(f1,1)={'Izquierda'};
        eventstart=starttime(1,k)*160;
        eventend=starttime(1,k+1)*160;
        event_C1=(C1(eventstart+1:eventend,1));
        event_C2=(C2(eventstart+1:eventend,1));
        event_C3=(C3(eventstart+1:eventend,1));
        event_C4=(C4(eventstart+1:eventend,1));
        event_C5=(C5(eventstart+1:eventend,1));
        event_C6=(C6(eventstart+1:eventend,1));
        event_Cz=(Cz(eventstart+1:eventend,1));
        eventos_C1{f1,1}=event_C1;
        eventos_C2{f1,1}=event_C2;
        eventos_C3{f1,1}=event_C3;
        eventos_C4{f1,1}=event_C4;
        eventos_C5{f1,1}=event_C5;
        eventos_C6{f1,1}=event_C6;
        eventos_Cz{f1,1}=event_Cz;
        f1=f1+1;
    end
    if event_label == 2
        Etiquetas(f1,1)={'Derecha'};
        eventstart=starttime(1,k)*160;
        eventend=starttime(1,k+1)*160;
        event_C1=(C1(eventstart+1:eventend,1));
        event_C2=(C2(eventstart+1:eventend,1));
        event_C3=(C3(eventstart+1:eventend,1));
    end
end

```

```

event_Cz=(Cz(eventstart+1:eventend,1));
event_C4=(C4(eventstart+1:eventend,1));
event_C5=(C5(eventstart+1:eventend,1));
event_C6=(C6(eventstart+1:eventend,1));
eventos_C1{f1,1}=event_C1;
eventos_C2{f1,1}=event_C2;
eventos_C3{f1,1}=event_C3;
eventos_C4{f1,1}=event_C4;
eventos_C5{f1,1}=event_C5;
eventos_C6{f1,1}=event_C6;
eventos_Cz{f1,1}=event_Cz;
f1=f1+1;
end

end

end
eventos_C1 = cellfun(@transpose,eventos_C1,'UniformOutput',false);
eventos_C2 = cellfun(@transpose,eventos_C2,'UniformOutput',false);
eventos_C3 = cellfun(@transpose,eventos_C3,'UniformOutput',false);
eventos_C4 = cellfun(@transpose,eventos_C4,'UniformOutput',false);
eventos_C5 = cellfun(@transpose,eventos_C5,'UniformOutput',false);
eventos_C6 = cellfun(@transpose,eventos_C6,'UniformOutput',false);
eventos_Cz = cellfun(@transpose,eventos_Cz,'UniformOutput',false);

clearvars -except Etiquetas eventos_C1 eventos_C2 eventos_C3 eventos_C4
eventos_Cz eventos_C5 eventos_C6

```

4. Algoritmo para la descomposición de los eventos en coeficientes wavelet.

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% DESCOMPOSICIÓN EN COEFICIENTES WAVELET%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

M_event=[eventos_C1, eventos_C2, eventos_C3, eventos_C4, eventos_C5,
eventos_C6, eventos_Cz];

[high,width]=size(M_event);
wavelevel=4; %Niveles de descomposición wavelet
motherw='coif4'; %wavelet madre usada coif2, coif4, db2, db4.
for i=1:high
[C,L]=wavedec(M_event{i,1},wavelevel,motherw);
cD2_C1(i,1)={wrcoef('d',C,L,motherw,2)};
cD3_C1(i,1)={wrcoef('d',C,L,motherw,3)};
cD4_C1(i,1)={wrcoef('d',C,L,motherw,4)};

```

```
[C,L]=wavedec(M_event{i,2},wavelevel,motherw);  
cD2_C2(i,1)={wrcoef('d',C,L,motherw,2)};  
cD3_C2(i,1)={wrcoef('d',C,L,motherw,3)};  
cD4_C2(i,1)={wrcoef('d',C,L,motherw,4)};
```

```
[C,L]=wavedec(M_event{i,3},wavelevel,motherw);  
cD2_C3(i,1)={wrcoef('d',C,L,motherw,2)};  
cD3_C3(i,1)={wrcoef('d',C,L,motherw,3)};  
cD4_C3(i,1)={wrcoef('d',C,L,motherw,4)};
```

```
[C,L]=wavedec(M_event{i,4},wavelevel,motherw);  
cD2_C4(i,1)={wrcoef('d',C,L,motherw,2)};  
cD3_C4(i,1)={wrcoef('d',C,L,motherw,3)};  
cD4_C4(i,1)={wrcoef('d',C,L,motherw,4)};
```

```
[C,L]=wavedec(M_event{i,5},wavelevel,motherw);  
cD2_C5(i,1)={wrcoef('d',C,L,motherw,2)};  
cD3_C5(i,1)={wrcoef('d',C,L,motherw,3)};  
cD4_C5(i,1)={wrcoef('d',C,L,motherw,4)};
```

```
[C,L]=wavedec(M_event{i,6},wavelevel,motherw);  
cD2_C6(i,1)={wrcoef('d',C,L,motherw,2)};  
cD3_C6(i,1)={wrcoef('d',C,L,motherw,3)};  
cD4_C6(i,1)={wrcoef('d',C,L,motherw,4)};
```

```
[C,L]=wavedec(M_event{i,7},wavelevel,motherw);  
cD2_Cz(i,1)={wrcoef('d',C,L,motherw,2)};  
cD3_Cz(i,1)={wrcoef('d',C,L,motherw,3)};  
cD4_Cz(i,1)={wrcoef('d',C,L,motherw,4)};
```

end

5. Algoritmo para la extracción de características. Se realiza llamando a la función `tiene_frequency_features` que extrae las características a cada uno de los coeficientes de detalle de los eventos en los 7 canales.

```
[feat01,feat02,feat03,feat04,feat05,feat06,feat07,feat08,feat09,feat10,...  
feat11,feat12,feat13,feat14,feat15,feat16,feat17,feat18,feat19,feat20,...feat21,feat2  
2,feat23,feat24,feat25,feat26,feat27,feat28,feat29,feat30,...  
feat31,feat32,feat33,feat34,feat35,feat36,feat37,feat38,feat39,feat40,...  
feat41,feat42,feat43,feat44,feat45,feat46,feat47,feat48,feat49,feat50,...  
feat51,feat52,feat53,feat54,feat55,feat56,feat57,feat58,feat59,feat60,...  
feat61,feat62,feat63,feat64,feat65,feat66,feat67,feat68,feat69,feat70,...  
feat71,feat72,feat73,feat74,feat75,feat76,feat77,feat78,feat79,feat80,...  
feat81,feat82,feat83] = cellfun(@time_frequency_features_cD2,cD2_C1);
```

```
%%%%%%%%%%%%%%  
% CARACTERISTICAS TEMPORALES %  
% ESPECTRALES Y ESTADISTICAS %  
%%%%%%%%%%%%%%
```

```
[pxx1,f1]=pwelch(x,[],100,500,160,'psd');  
[pxx2,f2]=pburg(x,10,[],160);
```

```
feat01=rms(x);  
feat02=MAV(x);  
feat03=IEEG(x);  
feat04=SSI(x);  
feat05=VAR(x);  
feat06=AAC(x);  
feat07=RSSQ(x);  
feat08=VEEG(x);  
feat09=STD(x);  
feat10=SSI2(x);  
feat11=mean(x);  
feat12=Energy1_3Cor(x);  
feat13=Energy2_3Cor(x);  
feat14=int_ratio(x);  
feat15=KurtoEnv(x);  
feat16=kurtosis(x);  
feat17=MaxFFT(x);  
feat18=MeanFFT(x);  
feat19=MedianFFT(x);  
feat20=VarFFT(x);  
feat21=RappMaxMean(x);  
feat22=RappMaxMedian(x);  
feat23=SkewEnv(x);  
feat24=skewness(x);  
feat25=shannon_entropy(x);
```

```
feat26=rms(pxx1);  
feat27=MAV(pxx1);  
feat28=IEEG(pxx1);  
feat29=SSI(pxx1);  
feat30=VAR(pxx1);  
feat31=AAC(pxx1);  
feat32=RSSQ(pxx1);  
feat33=VEEG(pxx1);  
feat34=STD(pxx1);
```

```

feat35=SSI2(pxx1);
feat36=mean(pxx1);
feat37=Energy1_3Cor(pxx1);
feat38=Energy2_3Cor(pxx1);
feat39=int_ratio(pxx1);
feat40=kurtosis(pxx1);
feat41=RappMaxMean(pxx1);
feat42=RappMaxMedian(pxx1);
feat43=skewness(pxx1);
feat44=wentropy(pxx1,'log energy');

```

```

feat45=rms(pxx2);
feat46=MAV(pxx2);
feat47=IEEG(pxx2);
feat48=SSI(pxx2);
feat49=VAR(pxx2);
feat50=AAC(pxx2);
feat51=RSSQ(pxx2);
feat52=VEEG(pxx2);
feat53=STD(pxx2);
feat54=SSI2(pxx2);
feat55=mean(pxx2);
feat56=Energy1_3Cor(pxx2);
feat57=Energy2_3Cor(pxx2);
feat58=int_ratio(pxx2);
feat59=kurtosis(pxx2);
feat60=RappMaxMean(pxx2);
feat61=RappMaxMedian(pxx2);
feat62=skewness(pxx2);
feat63=wentropy(pxx2,'log energy')

```

```

a=1;
for i=1:length(f1)
    n=f1(i,1);
    if n>=8 && n<=12
%       band8_12w(a,1)=10*log10(pxx1(i,1));
        band8_12w(a,1)=pxx1(i,1);
        a=a+1;
    end
    if n>=12 && n<=20
%       band12_20w(a,1)=10*log10(pxx1(i,1));
        band12_20w(a,1)=pxx1(i,1);
        a=a+1;
    end
end

```

```

end
feat64=max((band8_12w)); %maxband8_12welch
feat65=max((band12_20w)); %maxband12_20welch

a=1;
for i=1:length(f2)
    n=f2(i,1);
    if n>=8 && n<=12
        % band8_12b(a,1)=10*log10(pxx2(i,1));
        band8_12b(a,1)=pxx2(i,1);
        a=a+1;
    end
    if n>=12 && n<=20
        % band12_20b(a,1)=10*log10(pxx2(i,1));
        band12_20b(a,1)=pxx2(i,1);
        a=a+1;
    end
end
end
feat66 = max((band8_12b)); %maxband8_12burg
feat67 = max((band12_20b)); %maxband12_20burg

[P1,L1] = findpeaks(pxx1,f1);
[B1,l1] = sort(P1,'descend');
feat68 = L1(l1(1,:),:); %frecuencia pico uno welch
feat69 = L1(l1(2,:),:); %frecuencia pico dos welch

[P2,L2] = findpeaks(pxx2,f2);
[B2,l2] = sort(P2,'descend');
feat70 = L2(l2(1,:),:); %frecuencia pico uno burg
feat71 = L2(l2(2,:),:); %frecuencia pico dos burg

feat72 = bandpower(pxx1,f1,'psd'); %potencia total welch
feat73 = bandpower(pxx1,f1,[8 12],'psd'); %potencia de banda 8-12 welch
feat74 = 100*(feat73/feat72); %porcentaje de potencia de banda 8-12 welch
feat75 = bandpower(pxx1,f1,[12 20],'psd'); %potencia de banda 12-20 welch
feat76 = 100*(feat75/feat72); %porcentaje de potencia de banda 12-20 welch
feat77 = medfreq(pxx1,f1,[8 12]); %frecuencia media banda 8-12 welch
feat78 = medfreq(pxx1,f1,[12 20]); %frecuencia media banda 12-20 welch
feat79 = meanfreq(pxx1,f1,[8 12]); %frecuencia promedio banda 8-12 welch
feat80 = meanfreq(pxx1,f1,[12 20]); %frecuencia promedio banda 12-20 welch
feat81 = powerbw(pxx1,f1); %ancho de banda de potencia welch
% feat82 = max(10*log10(pxx1)); %frecuencia maxima welch
feat82 = max(pxx1); %frecuencia maxima welch

feat83 = bandpower(pxx2,f2,'psd'); %potencia total burg

```

```

feat84 = bandpower(pxx2,f2,[8 12],'psd'); %potencia de banda 8-12 burg
feat85 = 100*(feat84/feat83); %porcentaje de potencia de banda 8-12 burg
feat86 = bandpower(pxx2,f2,[12 20],'psd'); %potencia de banda 12-20 burg
feat87 = 100*(feat86/feat83); %porcentaje de potencia de banda 12-20 burg
feat88 = medfreq(pxx2,f2,[8 12]); %frecuencia media banda 8-12 burg
feat89 = medfreq(pxx2,f2,[12 20]); %frecuencia media banda 12-20 burg
feat90 = meanfreq(pxx2,f2,[8 12]); %frecuencia promedio banda 8-12 burg
feat91 = meanfreq(pxx2,f2,[12 20]); %frecuencia promedio banda 12-20 burg
feat92 = powerbw(pxx2,f2); %ancho de banda de potencia burg
% feat93 = max(10*log10(pxx2)); %frecuencia maxima burg
feat93 = max(pxx2); %frecuencia maxima burg

```

```
end
```

6. Creación del vector de características, normalización y selección de características.

```
Feat_matrix=[Feature_matrix_cD2,Feature_matrix_cD3,Feature_matrix_cD4];
```

```
[high,width]=size(Feat_matrix);
```

```
for i=1:width
```

```
    Feat_matrix_norm(:,i)=zscore(Feat_matrix(:,i));
```

```
end
```

```
clear i high width
```

```
A=prdataset(Feat_matrix_norm,Etiquetas);
```

```
[W,R]=featsel(A,'maha-s',80);
```

```
featselect=R(1:80,3);
```

```
B=A(:,featselect);
```

7. Algoritmos para la clasificación de la base de datos usando SVM, Fisher y Clasificador Logístico.

```
clc
```

```
tic
```

```
for i=1:10
```

```
    [train,test]=gendat(B,0.80);
```

```
    w1=svc(train);
```

```
    w2=fisherc(train);
```

```
    w3=loglc(train);
```

```
    truelab1=getlab(test);
```

```
    estlab1=test*w1*labeld;
```

```

labs1=[truelab1,estlab1];
U1=confmat(truelab1,estlab1);
d1=test*w1
testd(d1)*100

```

```

truelab2=getlab(test);
estlab2=test*w2*labeld;
labs2=[truelab2,estlab2];
U2=confmat(truelab2,estlab2);
d2=test*w2
testd(d2)*100

```

```

truelab3=getlab(test);
estlab3=test*w3*labeld;
labs3=[truelab3,estlab3];
U3=confmat(truelab3,estlab3);
d3=test*w3
testd(d3)*100

```

```

medidas_svc(1,i)=U1(1,1)/(U1(1,1)+U1(1,2)); %Sensibilidad svc
medidas_svc(2,i)=U1(2,2)/(U1(2,2)+U1(2,1)); %Especificidad svc
medidas_svc(3,i)=(U1(1,2)+U1(2,1))/(U1(1,1)+U1(1,2)+U1(2,2)+U1(2,1));
%Error svc
medidas_svc(4,i)=(U1(1,1)+U1(2,2))/(U1(1,1)+U1(1,2)+U1(2,2)+U1(2,1));
%Acierto svc

```

```

medidas_fisher(1,i)=U2(1,1)/(U2(1,1)+U2(1,2)); %Sensibilidad fisher
medidas_fisher(2,i)=U2(2,2)/(U2(2,2)+U2(2,1)); %Especificidad fisher
medidas_fisher(3,i)=(U2(1,2)+U2(2,1))/(U2(1,1)+U2(1,2)+U2(2,2)+U2(2,1));
%Error fisher
medidas_fisher(4,i)=(U2(1,1)+U2(2,2))/(U2(1,1)+U2(1,2)+U2(2,2)+U2(2,1));
%Acierto fisher

```

```

medidas_loglc(1,i)=U3(1,1)/(U3(1,1)+U3(1,2)); %Sensibilidad loglc
medidas_loglc(2,i)=U3(2,2)/(U3(2,2)+U3(2,1)); %Especificidad loglc
medidas_loglc(3,i)=(U3(1,2)+U3(2,1))/(U3(1,1)+U3(1,2)+U3(2,2)+U3(2,1));
%Error loglc
medidas_loglc(4,i)=(U3(1,1)+U3(2,2))/(U3(1,1)+U3(1,2)+U3(2,2)+U3(2,1));
%Acierto loglc

```

```

end

```

```

medidas2_svc(1,1)=sum(medidas_svc(1,1:end))/10;
medidas2_svc(2,1)=sum(medidas_svc(2,1:end))/10;

```

```
medidas2_svc(3,1)=sum(medidas_svc(3,1:end))/10;  
medidas2_svc(4,1)=sum(medidas_svc(4,1:end))/10;
```

```
medidas2_fisher(1,1)=sum(medidas_fisher(1,1:end))/10;  
medidas2_fisher(2,1)=sum(medidas_fisher(2,1:end))/10;  
medidas2_fisher(3,1)=sum(medidas_fisher(3,1:end))/10;  
medidas2_fisher(4,1)=sum(medidas_fisher(4,1:end))/10;
```

```
medidas2_loglc(1,1)=sum(medidas_loglc(1,1:end))/10;  
medidas2_loglc(2,1)=sum(medidas_loglc(2,1:end))/10;  
medidas2_loglc(3,1)=sum(medidas_loglc(3,1:end))/10;  
medidas2_loglc(4,1)=sum(medidas_loglc(4,1:end))/10;
```

```
toc
```

ANEXO 2. Artículo enviado y aprobado para socialización en las III Jornadas Internacionales de investigación FICA de la Universidad Técnica del Norte en Ibarra-Ecuador

Análisis De Señales EEG Para Detección De Intenciones Motoras Aplicadas A Sistemas BCI

Martin A. Patiño Noguera
Universidad de Nariño
Pasto, Colombia
martinalejo93@hotmail.com

Cristian E. Medina Ortega
Universidad de Nariño
Pasto, Colombia
cristhian.medina.or@hotmail.com

Wilmer Castro
Universidad de Nariño
Pasto, Colombia
wilmercing@gmail.com

Diego H. peluffo Ordoñez
Universidad Técnica del Norte
Ibarra, Ecuador
dhpeluffo@utn.edu.ec

Abstract— The physical limitations that many people have as a result of degenerative neuronal diseases and limb amputations, have resulted in extensive research trying to understand the intentions of the brain through the study of characteristics of EEG signals, with the purpose of use them in output commands and can perform tasks that improve the quality of life of people. Although currently exist BCI systems that somehow allow users to interact with certain devices, these still presenting significant limitations because there is no definitive methodology that allows the correct characterization and classification of EEG signals, this being a research topic still open. The main idea of this work is to present an alternative methodology for feature extraction of EEG signals a view to improving the current systems BCI and achieve a friendly user interface.

Keywords: Brain computer interface (BCI), Discrete Wavelet Transform (WDT), Electroencephalography (EEG), Feature Extraction.

I. INTRODUCCION

DESDE su primera aplicación, la electroencefalografía ha sido una técnica usada principalmente para lograr entender el comportamiento y funcionamiento del cerebro a través de la interpretación de señales eléctricas obtenidas del cuero cabelludo. Para este propósito, las características de las señales electroencefalográficas (EEG) han sido estudiadas con el fin de descifrar las intenciones de las personas quienes podrían controlar ciertos dispositivos solo con imaginarlo. Este concepto es lo que se conoce como interfaz cerebro-computador (BCI), un sistemas cuyo proceso de operación es capaz de interpretar los pensamientos y convertirlos en interacciones con el mundo físico o virtual [1].

Actualmente, los sistemas basados en BCI son de mucha utilidad para personas dependientes, de avanzada edad o con alto grado de discapacidad, dado que este medio representa una nueva forma de comunicación y control.

Como resultado de algunas investigaciones, los sistemas BCI han permitido que personas con parálisis en sus extremidades puedan realizar tareas como: escribir en un monitor, desplazarse en una silla de ruedas o manejar prótesis, etc. En resumen, estos sistemas representan un camino directo entre el cerebro y el dispositivo a ser controlado [2] [3]. Obteniendo las características de las señales EEG se realiza un análisis profundo para distinguir las señales pertinentes, es decir aquellas relacionadas con las intenciones del usuario y que serán usadas para la traducción en comandos de salida. Es aquí donde aún se ve restringida la eficiencia de un sistema BCI, ya que al adquirir las señales por métodos no invasivos, estas se ven afectadas por ruido o los también llamados artefactos que no son más que señales generadas por movimiento ocular, parpadeo, respiración, contracción muscular, latidos del corazón, entre otros. Además de presentar una baja resolución espacial, lo cual limita al sistema realizar una correcta caracterización de los fenómenos fisiológicos y deriva en un bajo acierto de las acciones que el usuario quiera efectuar con el dispositivo final [4][5][6]. Además de tener en cuenta el considerable costo computacional que requiere el procesamiento de señales EEG y debido a la escasa implementación de técnicas que permitan una mejor manipulación de estas señales, aun no existen todavía interfaces amigables con el usuario donde las intenciones estén claramente identificadas y puedan ser aplicadas para trabajar en tiempo real [7].

En este trabajo se propone una metodología genérica para caracterizar y clasificar señales cognitivas de registros EEG de una manera más óptima, usando técnicas de caracterización basadas en información espectral, así como de reconocimiento de patrones. Para tal propósito se trabaja con registros de señales EEG de alta calidad y fiabilidad, presentes en una base de datos gratuita y ampliamente usada por la comunidad científica como los es la PhysioNet, creada por los desarrolladores de la BCI2000 y que está constituida por 1526 registros de 64 señales EEG muestreadas a 160Hz y obtenidas de 109 usuarios, donde cada uno de ellos proporciona 14 registros correspondientes a diferentes tareas motrices e imaginarias. Para la extracción de características se aplican métodos de análisis espectral como: la transformada de Fourier, transformada de wavelet, modelos autoregresivos, filtrado

espacial y métodos no lineales entre otros.

La selección y clasificación de las características se realizan haciendo un estudio de métodos evolutivos y de reconocimiento de patrones.

Una vez procesadas las señales EEG se llevaran a un control basado en lógica difusa que será el encargado de decidir o traducir las intenciones o pensamientos del usuario a salidas directamente aplicables o reconocibles. Tomando medidas estadísticas en términos de exactitud y especificidad en la clasificación de las señales tratadas para dos tareas ejecutadas físicamente y dos imaginarias que corresponden a apertura/cierre de la mano derecha o izquierda, se fija como objetivo un acierto superior al 95% en tareas motrices y superior al 90% en tareas imaginarias.

Este trabajo está organizado de la siguiente manera. Materiales y métodos donde se menciona un breve estado del arte de los sistemas BCI y la caracterización y clasificación de señales EEG, seguido del marco experimental donde se detalla el procedimiento realizado y finalmente se discuten los resultados y las conclusiones.

II. MATERIALES Y METODOS

A continuación se menciona brevemente el funcionamiento de una BCI y el estado del arte de la caracterización y clasificación de señales EEG.

A. BCI

Una interfaz cerebro ordenador BCI por sus siglas en inglés, es un sistema que a partir de las señales EEG obtiene ciertas características, las procesa y las traduce en comandos de salida permitiendo controlar ciertos dispositivos y convirtiéndose en una nueva alternativa de comunicación con amplias posibilidades para las personas discapacitadas[1].

Durante los últimos años ha crecido el interés científico por los sistemas BCI, vaticinando un futuro con usos y aplicaciones limitadas únicamente por la imaginación de quien quiera emplearlos. Actualmente estos sistemas están presentes en áreas de la robótica, la domótica, los videojuegos, la medicina y la rehabilitación. Como resultado de algunas investigaciones se ha logrado que personas con capacidades motoras reducidas mejoren su calidad de vida y puedan realizar tareas como escribir en un monitor, seleccionar objetos de una pantalla, desplazarse en una silla de ruedas, controlar electrodomésticos, manejar prótesis entre otras, las cuales se las considera como todo un record teniendo en cuenta la prematura etapa en la que se encuentra el desarrollo de esta tecnología [2] [3].

Un diagrama de bloques con su funcionamiento básico se muestra en la figura 1.

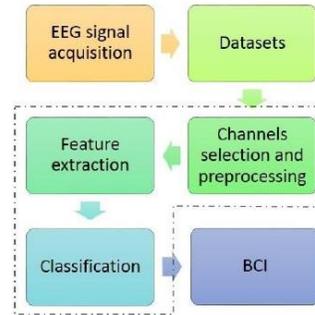


Figura 1. Funcionamiento básico de una interfaz cerebro-computador (BCI).

B. Estado del arte de la caracterización y clasificación de señales EEG

La EEG es la técnica de mayor uso al momento de registrar la actividad eléctrica cerebral dado su bajo costo y fácil implementación, aun así la calidad de los registros no son los mejores debido al ruido y artefactos con los que acarrea, siendo esta su mayor desventaja. Sin embargo en estudios como [8] se propone un modelo basado en la transformada de wavelet discreta (DWT) combinada con la cancelación de ruido adaptativo (ANC) que permiten reducir el impacto de los artefactos y así mejorar la calidad de la señal. En [9] se utiliza el método de agrupamiento automático K-means, el cual logra realizar una reducción de los artefactos oculares sobre las señales EEG, permitiendo que la caracterización y clasificación de tareas motoras imaginarias tenga un acierto del 88%. Otros trabajos como [10] [11] [12] [13] proponen el uso de la transformada de Fourier, la transformada de wavelet discreta (DWT), el análisis de componentes independientes (ICA) y el uso de filtros adaptativos basados en redes neuronales con el fin de minimizar los efectos de los artefactos y mejorar la calidad de las señales EEG a fin de ser usadas en aplicaciones de BCI.

En [14] se propone una metodología que involucra el uso de (DWT) para realizar la caracterización de las señales EEG, la mayoría de las características se extrajeron usando densidad de potencia espectral (PSD) y luego fueron introducidas dentro de algoritmos de aprendizaje automático. El resultado fue más que satisfactorio en cuanto al acierto en tareas motoras imaginarias de una dimensión (derecha/izquierda) para una aplicación BCI que permite la selección de diferentes objetos en un monitor de computador.

III. MARCO EXPERIMENTAL

A. Base de datos EEG

Para este trabajo se usa un conjunto de registros de señales EEG los cuales fueron adquiridos y contribuidos a PhysioNet por los desarrolladores del sistema de instrumentación

Como cada canal (C3, C4, CZ) contiene 15 eventos y las rutinas realizadas por cada uno de los 100 sujetos fueron 2, finalmente se obtiene un subconjunto que incluye 9000 vectores donde están representados los cuatro movimientos que los sujetos imaginan realizar (mano derecha, mano izquierda, ambas manos y ambos pies).

En el campo del procesamiento de señales, la transformada wavelet es una poderosa herramienta matemática que está basada en procesos multi-resolución y sus propiedades permiten determinar con precisión las componentes de una señal, gracias a esto se ha podido llevar a cabo un amplio número de investigaciones relacionadas con este tema. Aquellas propiedades de dilatación y traslación son las que permiten la extracción de todas las componentes para cada posición creando diferentes escalas y funciones desplazadas. Como resultado, la wavelet escalada más fina y larga, permite ver toda la información de la señal, mientras que las pequeñas escalas muestran detalles por acercamiento en las componentes de la señal. Como en el presente trabajo se trata con datos discretos, la transformada de wavelet discreta es la mejor herramienta para su análisis. Existen muchas wavelets madre agrupadas según su utilidad, las Daubechies las más apropiadas para aplicarse en análisis de señales discretas, las Coiflets y las Symmlet, pero según [18], la familia de wavelets coiflet presentan mejor rendimiento al momento de realizar la clasificación. Para este trabajo se calculan las coiflet coif1 hasta coif5 y el nivel de descomposición se estableció para generar cuatro niveles de detalles

Como se muestra en la figura 4, el propósito de la transformada de wavelet discreta DWT, es descomponer la señal EEG en un subconjunto de coeficientes multi-resolución.

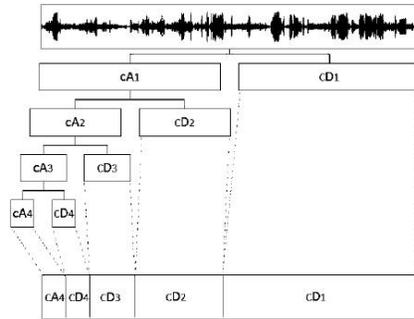


Figura 4. Descomposición multi-resolución de una muestra de señal EEG.

Como las señales EEG del subconjunto utilizado fueron muestreadas a 160 Hz, la transformación wavelet de cada registro en los 4 niveles resulta en cuatro detalles: cD1(40-80Hz), cD2(20-40Hz), cD3(10-20Hz) y cD4(5-10Hz) además de una aproximación sencilla A4(0-5Hz), donde los detalles cD2, cD3 y cD4 contienen información de las ondas alfa, beta y theta y que son de nuestro interés. De cada uno de estos detalles se extrajeron vectores de características y se utilizaron los siguientes estimadores de amplitud.

- Root Mean Square (RMS)

$$RMS_i = \sqrt{\frac{1}{N} \sum_{n=1}^N D_i^2(n)}$$

- Mean Absolute Value (MAV)

$$MAV_i = \frac{1}{N} \sum_{n=1}^N |D_i(n)|$$

- Integrated EEG (IEEG)

$$IEEG_i = \sum_{n=1}^N |D_i(n)|$$

- Simple Square Integral (SSI)

$$SSI_i = \sum_{n=1}^N |D_i(n)|^2$$

- Variance of EEG (VAR)

$$VAR_i = \frac{1}{N-1} \sum_{n=1}^N D_i^2(n)$$

- Average Amplitude Change (AAC)

$$AAC_i = \frac{1}{N} \sum_{n=1}^N |D_i(n+1) - D_i(n)|$$

IV. RESULTADOS Y DISCUSIÓN

Teniendo en cuenta que este es un trabajo en desarrollo, aún se presentan percances en la metodología propuesta y los resultados no son del todo satisfactorios, se propone revisar nuevamente y paso a paso las etapas de filtrado, caracterización y clasificación, remuestrear las señales y verificar el script escrito en MATLAB con el propósito de depurar errores en la programación que sean los causantes de que el sistema aún no realice una caracterización y clasificación adecuada. Posteriormente y debido al poco éxito en la caracterización se procede a trabajar con un subconjunto compuesto por 10 voluntarios y haciendo uso solo de la rutina experimental "Imaginar abrir y cerrar el puño derecho o izquierdo" con el fin de reducir los datos a caracterizar y clasificar y así evitar que el sistema se sature. Los resultados futuros de este trabajo se pueden obtener escribiendo a alguno de los correos de los autores, como se mencionó en la introducción se espera lograr que el sistema realice una caracterización y clasificación de las intenciones con aciertos superiores al 90%.

V. CONCLUSIONES

Debido a que las señales EEG presentan gran cantidad de ruido se hace necesario realizar nuevamente un pre-proceso y un correcto filtrado de las mismas a fin de que el sistema pueda ejecutar una correcta caracterización de los fenómenos fisiológicos presentes en las señales utilizadas en este trabajo, además se necesita impulsar el desarrollo de nuevas tecnologías que conlleven a un mejor método de adquisición de señales EEG libre de ruidos y artefactos, lo cual supondría una mejora relativamente alta en la eficiencia de sistemas BCI. Por último se necesita realizar un estudio comparativo más amplio de las

técnicas de caracterización y clasificación de señales a fin de implementar el que presente mejor rendimiento en cuanto a mayor porcentaje de acierto y costo computacional.

REFERENCIAS

1. Hornero, Roberto, Rebeca Corralejo, and Daniel Álvarez. "Brain-Computer Interface (BCI) aplicado al entrenamiento cognitivo y control doméstico para prevenir los efectos del envejecimiento." *Fundación General CSIC LYCHNOS [en línea]* 8 (2012).
2. Rajangam, Sankaranarayani, et al. "Wireless Cortical Brain-Machine Interface for Whole-Body Navigation in Primates." *Scientific reports* 6 (2016).
3. Gilja, Vikash, et al. "Clinical translation of a high-performance neural prosthesis." *Nature medicine* (2015).
4. Peng, Hong, et al. "Removal of ocular artifacts in EEG—An improved approach combining DWT and ANC for portable applications." *IEEE journal of biomedical and health informatics* 17.3 (2013): 600-607.
5. Ibrahim, Ibrahim Amer, Jayasree Santhosh, and Mahmoud Moghavvemi. "A new approach for an effective eye movement artifact elimination from EEG signal." *2015 IEEE International Conference on Signal and Image Processing Applications (ICSIPA)*. IEEE, 2015.
6. Jafarifarmand, Aysa, and Mohammad Ali Badamchizadeh. "Artifacts removal in EEG signal using a new neural network enhanced adaptive filter." *Neurocomputing* 103 (2013): 222-231.
7. Bai, Ou, et al. "Towards a user-friendly brain-computer interface: initial tests in ALS and PLS patients." *Clinical Neurophysiology* 121.8 (2010): 1293-1303.
8. Santana, Daniel, M. Ramirez, and Feggy Ostrosky-Solis. "Novedades en tecnología de la rehabilitación: una revisión acerca de la interfaz cerebro-computadora." *Revista de neurología* 39.5 (2004): 447-450.
9. Peng, Hong, et al. "Removal of ocular artifacts in EEG—An improved approach combining DWT and ANC for portable applications." *IEEE journal of biomedical and health informatics* 17.3 (2013): 600-607.
10. Assi, Elie Bou, Sandy Rihana, and Mohamad Sawan. "Kmeans-ICA based automatic method for ocular artifacts removal in a motorimagery classification." *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE, 2014.
11. Ibrahim, Ibrahim Amer, Jayasree Santhosh, and Mahmoud Moghavvemi. "A new approach for an effective eye movement artifact elimination from EEG signal." *2015 IEEE International Conference on Signal and Image Processing Applications (ICSIPA)*. IEEE, 2015.
12. Jafarifarmand, Aysa, and Mohammad Ali Badamchizadeh. "Artifacts removal in EEG signal using a new neural network enhanced adaptive filter." *Neurocomputing* 103 (2013): 222-231.
13. Jadhav, P. N., et al. "Automated detection and correction of eye blink and muscular artefacts in EEG signal for analysis of Autism Spectrum Disorder." *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE, 2014.
14. Zodape, Nilesh. "BRAIN COMPUTER INTERFACE FOR HANDS-FREE COMPUTER ACCESSIBILITY." *International Journal of Engineering Sciences & Research Technology* 1.4: 556-561.
15. Sleight, Jason, Preeti Pillai, and Shiwali Mohan. "Classification of executed and imagined motor movement EEG signals." *Ann Arbor: University of Michigan* (2009): 1-10.
16. Deecke, L., H. Weinberg, and P. Brickett. "Magnetic fields of the human brain accompanying voluntary movement: Bereitschaftsmagnetfeld." *Experimental Brain Research* 48.1 (1982): 144-148.
17. Romo-Vazquez, Rebeca, et al. "EEG ocular artefacts and noise removal." *2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE, 2007.
18. Alomari, Mohammad H., et al. "EEG Mouse: A Machine Learning-Based Brain Computer Interface." *LIACSA International Journal of Advanced Computer Science and Applications* 5.4 (2014): 193-198.

ANEXO 3. Certificado de participación como ponente en las III jornadas internacionales FICA en la UTN



ANEXO 4. Certificado de participación como ponente en el evento Datavis Day de la Universidad Autónoma de Nariño.



OTORGA EL PRESENTE
CERTIFICADO A:

Wilmer Castro

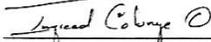
Con documento de identidad No.

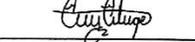
PARTICIPO COMO PONENTE CON:

Procesamiento de señales EEG para aplicaciones BCI, trascendencia como alternativa de comunicación y rehabilitación

EN AUNAR DATAVIS DAY

Realizado en las instalaciones de AUNAR, del 25 al 27 de Agosto
Se firma en San Juan de Pasto a los 27 días del mes de Agosto de 2016


Dra. Ingrid Colunge
Rectora


Mg. Constanza Colunge
Vicerrectora Académica


Ing. Milton Cabreja Alvarez
Coordinador Programa
Ingeniería Informática