



Universidad Autónoma de Querétaro

Facultad de Ingeniería
Maestría en ciencias línea terminal mecatrónica

“Clasificación automática de la imaginación motora empleando indicadores estadísticos y señales electroencefalográficas”

Opción de titulación

Tesis

Que como parte de los requisitos para obtener el Grado de
Maestría en Mecatrónica

Presenta:

Ing. Emmanuel Zárate de Vicente

Dirigido por:

Dr. Juan Pablo Amézquita Sánchez

Dr. Juan Pablo Amézquita Sánchez

Presidente

Dr. Martín Valtierra Rodríguez

Secretario

Dr. Roque Alfredo Osornio Ríos

Vocal

Dr. Luis Alberto Morales Hernández

Suplente

Dr. J. Jesús de Santiago Pérez

Suplente

Centro Universitario, Querétaro, Qro.

Mayo, 2023

México



Dirección General de Bibliotecas y Servicios Digitales
de Información



Clasificación automática de la imaginación motora
empleando indicadores estadísticos y señales
electroencefalográficas

por

Emmanuel Zárate de Vicente

se distribuye bajo una [Licencia Creative Commons
Atribución-NoComercial-SinDerivadas 4.0
Internacional](#).

Clave RI: IGMAC-302334



Universidad Autónoma de Querétaro

Facultad de Ingeniería
Maestría en ciencias línea terminal mecatrónica

“Clasificación automática de la imaginación motora empleando indicadores estadísticos y señales electroencefalográficas”

Opción de titulación

Tesis

Que como parte de los requisitos para obtener el Grado de
Maestría en Mecatrónica

Presenta:

Ing. Emmanuel Zárate de Vicente

Dirigido por:

Dr. Juan Pablo Amézquita Sánchez

Sinodales

Dr. Juan Pablo Amézquita Sánchez

Presidente

Firma

Dr. Martín Valtierra Rodríguez

Secretario

Firma

Dr. Roque Alfredo Osornio Ríos

Vocal

Firma

Dr. Luis Alberto Morales Hernández

Suplente

Firma

Dr. J. Jesús de Santiago Pérez

Suplente

Firma

Centro Universitario, Querétaro, Qro.

Mayo, 2023

México

Resumen

La imaginación motora (IM) es responsable de los movimientos corporales, por lo que la imaginación motora tiene un inmenso potencial para su aplicabilidad en aplicaciones médicas, aplicaciones industriales, juegos, entre otros. Esta se basa principalmente en el monitoreo de señales electroencefalográficas (EEG), las cuales se caracterizan por ser señales embebidas en una gran cantidad de ruido, además de presentar propiedades no estacionarias. Por lo tanto, la identificación de las características más adecuadas dentro de las señales EEG con el fin asociarlas con el IM es un desafío debido a las propiedades de las señales. En este sentido, en este trabajo de tesis se presenta un método basado en la integración de la transformada wavelet de paquetes, índices estadísticos y una red neuronal artificial para clasificar automáticamente tres movimientos imaginados tales como: reposo, arriba y abajo utilizando señales EEG. En particular, se investigan 17 indicadores estadísticos, ocho niveles de la transformada wavelet por paquetes. Las mejores características son evaluados e identificadas por medio del método de Kruskal-Wallis, las cuales son utilizados para entrenar y validar una red neuronal del tipo perceptrón multicapa. Una vez validada la propuesta metodológica, se genera una interfaz de usuario para hacer la implementación del método con un brazo robótico. El método propuesto demuestra una exactitud del 80% para distinguir entre los tres pensamientos propuestos, además de permitir la apertura y cerrado del efector final del brazo robótico en base a la distinción de los diferentes pensamientos.

Palabras clave: Señales de ECG, Imaginación motora, Transformada wavelet, Índice estadístico, Redes neuronales.

Summary

Motor imagery (MI) is responsible for body movements, which has immense potential for its applicability in medical purposes, industrial applications, gaming, among others. It is based mainly on monitoring of electroencephalographic (EEG) signals, which are noisy signals with nonstationary properties. Hence, identifying suitable features associated with MI using EEG signals is a challenge due to their properties. In this sense, this thesis introduces a new method based on the integration of wavelet packet transform, statistical indices, and an artificial neural network for classifying to automatically three fancied movements (e.g., rest, up, and down) using EEG signals. For this reason, 17 statistical indicators are analyzed, eight levels of the packet wavelet transform and the best results obtained by the Kruskal-Wallis method are used to train a multilayer perceptron neural network. A user interface was also generated to implement the method with a robotic arm. The proposed method demonstrates an accuracy of 80%, suggesting that the use of statistical indices at frequency bands related to brain activity that can be suitable for motor imagery classification.

Keywords: ECG signals, Motor Imagery, Wavelet transform, Statistical Index, Neural networks.

Agradecimientos

A mi padre el cual durante todo mi proceso de aprendizaje me brindo las herramientas necesarias para poder terminar un logro más en mi lista de objetivos, el cual nunca quito el dedo del renglón para poder darme todo e incluso más de lo que necesitaba para este proceso.

A mi madre la cual con su amor y paciencia me dedico su tiempo para inculcar en mi esfuerzo y valentía, la cual del mismo modo estuvo detrás de mí para no dejarme llevar por las distracciones.

A mis hermanos los cuales, con cariño y apoyo incondicional estuvieron durante este recorrido, por estar conmigo gracias. A toda mi familia por sus consejos, oraciones y palabras de aliento hicieron una mejor persona y de algún modo estuvieron siempre acompañándome en esta y otras metas.

A mis compañeros de doctorado Roberto y Viviana por su gran apoyo en cada tema y duda que tenía en cuanto a todo este proceso.

A mis asesores, Dr. Amézquita, por creer en mi capacidad y por la valiosa orientación a través de la investigación para culminar este trabajo, al Dr. Valtierra, Dr. Morales, Dr. Osornio y al Dr. J. Jesús, por apoyarme en el proceso y por sus comentarios que hacen que el trabajo sea mejor y culminar mi posgrado con una mejor visión de la investigación en México.

A la Universidad Autónoma de Querétaro y al Consejo Nacional de Ciencia y Tecnología (CONACyT) por bríndame la oportunidad de estudiar el posgrado mediante la beca otorgada 793285.

Contenido

Resumen.....	3
Summary.....	4
Agradecimientos	5
Índice de figuras.....	8
Índice de Tablas	9
1 Introducción	11
1.1 Antecedentes	13
1.2 Descripción del problema.....	17
1.3 Justificación.....	18
1.4 Hipótesis.....	20
1.5 Objetivo General	20
1.5.1 Objetivos particulares	20
2 Revisión de la literatura	22
2.1 Señales EEG.....	23
2.1.1 Tipo de sensores para el monitoreo de señales EEG	24
2.1.2 Imaginación motora.....	26
2.2 Procesamiento digital de señales.....	26
2.2.1 Python.....	27
2.2.2 MATLAB	28
2.2.3 Indicadores Estadísticos	29
2.2.4 Transformada Wavelet por paquetes	30
2.2.5 Kruskal Wallis	32
2.2.6 Clasificador basado en redes neuronales	33
2.3. Interfaz hombre-maquina	35
2.4. Microprocesador Arduino.....	36
2.5. Actuador	37

3 Metodología	39
3.1. Metodología propuesta.....	40
3.2. Material	41
3.3 Casco EMOTIV.....	43
3.3.1 Interfaz de adquisición de señales EEG	45
3.4 Control de brazo robótico.....	46
4 Resultados	52
4.1 Puesta de experimento.....	53
4.2 Resultados: Identificación del método (procesamiento de la señal)	54
4.3 Resultados: Validación (método-actuador).....	63
4.4 Discusión de los resultados	65
5 Conclusiones y perspectivas	67
5.1 Conclusiones	68
5.2 Prospectivas.....	68
Referencias.....	70
Anexos	75

Índice de figuras

Figura 1. Ilustración de la adquisición EEG	24
Figura 2. Sensores de superficie, a) de aguja, b) adheridos, c) contacto y (d) casco de malla.	25
Figura 3. Interfaz de PYTHON.....	27
Figura 4. Ventana de trabajo MATLAB	28
Figura 5. Diagrama de niveles para transformada wavelet por paquetes	31
Figura 6. Valores estimados por análisis estadístico	33
Figura 7. Red Neuronal Multicapa	34
Figura 8. Componentes de sistema HMI	36
Figura 9. Arduino Mega.....	37
Figura 10. Ilustración de actuadores lineales y rotativos.....	38
Figura 11. Metodología propuesta	41
Figura 12. Protocolo visual.....	42
Figura 13. Lugar de adquisición de señales EEG.	43
Figura 14. (a) Diadema EMOTIV EPOC+ y (b) localización de los sensores.	43
Figura 15. Sistema Internacional 10-20 para la colocación de los electrodos extra craneales.	44
Figura 16. Interfaz creada para la adquisición de las señales EEG.	46
Figura 17. Brazo Robótico STEREN 680-K	47
Figura 18. Módulo L298N.....	48
Figura 19. Diagrama de conexión Arduino y brazo.....	49
Figura 20. Script ejemplo de la conexión serial del Arduino programada desde Matlab mediante Arduino IO.	51
Figura 21. Toma de señales EEG.....	53
Figura 22. Señales EEG obtenidas con Interfaz de usuario.....	55
Figura 23. Señal EEG segmentada.	55
Figura 24. Bandas de frecuencia obtenidas al usar WPT.	57
Figura 25. Distribución de los datos obtenidos con el método KWT.....	59
Figura 26. Red neuronal para validación de datos.....	60
Figura 27. Materiales para validación de actuador.	63
Figura 28. Prueba de sistema.	64
Figura 29. Reconocimiento Congreso CONIIN	77
Figura 30. Artículo de investigación.....	78

Índice de Tablas

Tabla 1 Indicadores estadísticos	29
Tabla 2. Características de la Arduino modelo Mega.....	37
Tabla 3 Movimientos de actuador k-680	47
Tabla 4. Características más relevantes seleccionadas por medio de KWT.....	58
Tabla 5. Matriz de confusión obtenida para la validación del clasificador.....	61
Tabla 6 Matriz de observación.....	62
Tabla 7. Resultados de matriz de confusión.	62
Tabla 8. Clasificación de los pensamientos en la etapa de validación (método-actuador).....	64

Anexos

A1. Carta de consentimiento informado.	75
A2. Carta de confidencialidad.....	64

1 Introducción

Las enfermedades neuromusculares (ENMs) tales como la esclerosis lateral amiotrófica (ELA), parálisis cerebral (PC), accidente cerebrovascular (AC) o lesión de la médula espinal (LME) se caracterizan por alterar el funcionamiento de la conexión neuronal con el músculo, lo que puede llegar a afectar a uno o varios componentes de la unidad motora, las terminaciones nerviosas y los nervios periféricos del cuerpo humano (Solorzano, 2016). A causa de estas afecciones, existe una falta de comunicación entre nervios y músculo, lo que produce una debilidad en la estructura y funcionalidad de estos. Además, las ENMs pueden desarrollar diferentes dificultades en actividades cotidianas que realiza una persona; por ejemplo, caminar, subir o bajar escaleras, oír, hablar o comunicarse, entre otras (Agoaga, 2006). En particular, en México hay más de seis millones de personas que presentan algún tipo de discapacidad, las cuales la mayoría son causadas por una ENM (Medical, 2020). Esto representa cerca del 5% de la población mexicana que podría tener alguna discapacidad en su vida diaria a causa de una ENM.

No todas las ENMs tienen una cura, por lo que los tratamientos son indispensables para mejorar la calidad de vida de los pacientes (Luna et al., 2016) En este sentido, algunos tipos de ENMs tales como distrofias musculares de Duchenne (DMD), distrofias musculares de Becker (DMB) y distrofias musculares de cintura (LGMB) pueden ser tratados mediante medicamentos, cirugías y educación y asesoramiento familiar (Kokontis & Gutmann, 2016). Otra forma de mejorar las condiciones de vida de los pacientes con ENMs es por medio de aparatos ortopédicos como lo son muletas, andaderas, sillas de ruedas, entre otros (Agoaga, 2006). Recientemente, una nueva alternativa que se está estudiando/probando para mejorar las condiciones de pacientes con una ENM son las interfaces cerebro-computadora (ICC) con el fin de ayudar al paciente a controlar diferentes tipos de sistemas que los rodean como lo son sillas de ruedas, puertas, instrumentos, dispositivos de comunicación, entre otros (Shih et al., 2012). Estas interfaces requieren de la imaginación motora (IM) para realizar la disposición de los movimientos.

La IM se conoce como una representación mental de los movimientos (p. ej., los movimientos de la mano) realizados por individuos, donde está involucrada la planificación motora y la simulación interna de la actividad motora sin un movimiento físico (Jeannerod & Frak, 1999), (Zhou et al., 2008). Esta se caracteriza por activar e involucrar las mismas áreas

cerebrales que se activan durante un movimiento real (Rodríguez et al., 2009), (Übeyli, 2009). En este sentido, se ha empleado en el tratamiento de pacientes con ictus, enfermedad provocada por la interrupción brusca de la circulación cerebral tras una lesión de los vasos sanguíneos de esta zona, limitando sus habilidades motoras (Altenmüller & E. James, 2020), (Kevric & Subasi, 2017). Este tratamiento se basa en la evocación, por persona, de un movimiento y el seguimiento de señales EEG con el fin de identificar patrones en las señales EEG para asociarlos con el movimiento imaginado (Monteiro et al., 2021). En consecuencia, es crucial proponer un método para identificar patrones adecuados en las señales EEG.

1.1 Antecedentes

La imaginación de movimiento o imaginación motora (IM) es la representación mental de movimientos que involucran la planeación motora y una simulación interna de una actividad motora sin realizar movimientos reales (Jeannerod & Frak, 1999). Se ha reportado que la IM tiene los mismos componentes e involucra las mismas áreas cerebrales, que cuando se realiza un movimiento real (Rodríguez et al., 2009).

En los últimos años, se han utilizado distintos métodos tanto a nivel internacional como nacional para el procesamiento de señales electroencefalográficas (EEG), con el fin de ser aplicadas en un interfaz humano-máquina. Lo anterior con ayuda de la imaginación motora ya que hoy en día tiene bastante popularidad debido a su potencial para recrear sistemas de movimiento en articulaciones que el usuario puede generar con el pensamiento. Aplicando estos dos elementos se da pauta para usar la imaginación motora en la asistencia de personas con discapacidad e incluso, para poder aplicarlos en otros ámbitos sociales e industriales.

En lo referente a trabajos reportados a nivel internacional para la clasificación de la imaginación motora se encuentra el de (Neuper et al., 2005) quienes utilizaron el filtrado de señales EEG para clasificar la imaginación motora de apertura y cerradura de la mano. El filtro del tipo pasa banda se emplea para la filtración de la banda beta (15-19 Hz) donde un umbral de la señal fue establecido en base a las pruebas. Cuando la señal filtrada excede el umbral predefinido, se generó un disparador de una secuencia de agarre. Con esto lograron la restauración no invasiva de la función de agarre manual del paciente, logrando la sujeción de

un vaso con la mano inmóvil completamente solo, esto con una precisión del 82.5%. (Casallas et al., 2015) presentaron una metodología basada en la amplitud máxima de señal electromiográfica (EMG), logrando diferenciar tres movimientos: giro de muñeca, cerradura de mano y apertura de mano, esto utilizando tres conjuntos de personas (mayores a 40 años, adultos de 18 a 39 años y niños de 8 a 15 años). Sus resultados fueron el nivel de error que obtuvieron al utilizar distintos individuos, electrodos desechables, agentes externos y otros, siendo este del 75%. Por otro lado, (Larger, 2018) presentaron una metodología basada en la amplitud de una señal EMG para controlar una prótesis de un grado de libertad, siendo reportada una eficiencia del 96% en el control de esta misma. (Rayal et al., 2019), (Khan et al., 2019) en otros estudios más recientes encontraron la extracción de características de las señales EEG de otras maneras entre ellas por medio de los patrones espaciales comunes, aunado la utilización de un análisis discriminatorio lineal que investigadores de Pakistán pusieron a prueba. El objetivo de esta metodología es la detección de movimientos de la mano obteniendo una exactitud del 60.61%.

De forma más reciente, (Terrasa Navarro, 2020) investigó los efectos del envejecimiento y la neuro modulación sobre la corteza somatosensorial, esto utilizando señales EEG para diseñar un protocolo y explorar los cambios en la corteza motora. Esto se aplicó en pacientes con fibromialgia para analizar su comportamiento. En los resultados obtenidos de este estudio se observa como el deterioro afecta en el envío de señales, porque disminuye su eficiencia en las lecturas, por lo cual es importante tomar en cuenta para este tipo de trabajos el buscar un grupo de personas con las mismas características motoras, sensoriales e incluso rango de edad, ya que generará un grupo con altas similitudes.

A pesar de los resultados obtenidos en los trabajos previamente discutidos, no se alcanza un nivel adecuado en la clasificación de los pensamientos, además de tener una carga computacional alta, lo que limita un resultado en tiempo real o en línea. Por lo tanto, de acuerdo a lo antes mencionado aún se cuenta con la oportunidad de aplicar distintas técnicas para explorar el comportamiento ante la clasificación de imaginación motora, además que puede buscar la obtención de un resultado en línea. Otra de las limitantes en los trabajos son las bases de datos previamente realizadas, no son propias y relativamente muy viejas lo que limita el

trabajo y abre la oportunidad de las mejoras que se pueden realizar empleando bases propias y con distintos pensamientos, ya que los elementos para entrenar hoy en día la imaginación motora son distintos a los de hace cinco años.

Con respecto a los trabajos realizados a nivel nacional se tiene el de (D’Croz-Baron et al., 2012), investigadores de Puebla, México, quienes realizaron una investigación basándose en el análisis autorregresivo y en la extracción de características por el método de Fisher. Sin embargo, a pesar de obtener buena exactitud del 80.8%, reportan que tienen una alta carga computacional, evitando un resultado en tiempo real. Por otro lado, (Cantillo Negrete et al., 2014) caracterizaron la actividad eléctrica cerebral relacionada con la imaginación del movimiento de la mano, de manera particular el movimiento de la mano derecha e izquierda. El registro de EEG se inició con una evaluación de la actividad cerebral basal del sujeto, seguido por una serie de pruebas de movimiento por cada una de las extremidades e imaginación de movimiento respectivamente. Las señales EEG adquiridas fueron caracterizadas utilizando la transformada de Fourier. En este proyecto se reportó una eficiencia del 73% y 76% para el movimiento izquierdo y derecho respectivamente a partir de un grupo de sujetos sanos con un intervalo de 21 y 30 años, siendo mitad mujeres y todos diestros. Debido a este porcentaje de eficiencia es preciso el continuar con las investigaciones de este tipo y validar una lectura de mayor precisión, ya que trabajos anteriores cuentan con una eficiencia mayor al obtenido.

A nivel local dentro de la Universidad Autónoma de Querétaro (UAQ) existen trabajos

realizados a procesamiento de señales del cuerpo humano. Por ejemplo, (Vargas Lopez, 2022) investigó una metodología basada en entropías, fractales y neuronales para predecir un infarto hasta una hora antes del evento. De manera reciente, (Aviles, 2020)

evaluó la transformada wavelet, indicadores estadísticos y redes neuronales para la clasificación de los movimientos del brazo a partir de señales EMG. (Barcenas, 2020) corroboró la eficiencia de la dimensión fractal combinando redes neuronales para la identificación de pacientes con déficit cognitivo leve (DCL) utilizando señales magnetoencefalográficas (MEG). Esta investigación entregó como resultado una eficiencia del

73% para distinguir los pacientes sanos de los pacientes con DCL. Por último, (Vargas Parra Raymundo, 2020) combinó la transformada wavelet e indicadores de Hjorth con una red neuronal para identificar pacientes con DCL empleando señales MEG, alcanzado una eficacia del 75%.

En este tipo de proyectos se utilizan diferentes tipos de sensores biomédicos, desde los musculares hasta los craneales. Debido a la naturalidad de las señales que se ven durante el presente proyecto se optara por una banda de adquisición de datos de la marca EMOTIV, específicamente el modelo EPOC + el cual es un hardware capaz de adquirir señales del tipo EEG, el cual se vende al público desde el 2008 con un pequeño kit de desarrollo de software para conectarse al equipo y adquirir los parámetros leídos por el sensor. Este equipo cuenta con 14 electrodos de tipo húmedo, lo cual indica que tienen un recubierto de gel electrolítico como conductor entre la piel y el electrodo, estos electrodos están posicionados de acuerdo a un sistema estandarizado 10-20.

Es importante destacar que recientemente las investigaciones realizadas en la Universidad se enfocan en la predicción de infartos para dar tiempo de previsión del evento, también en la clasificación de personas con DCL. Sin embargo, a pesar de los avances realizados es importante continuar realizando evaluaciones o propuestas para ampliar las metodologías utilizadas y así permitir incrementar la eficiencia de la clasificación y reducir la cantidad de carga computacional con el propósito de aplicarlo en un actuador final en tiempo real. En este sentido, (Cruz Ramírez, 2018) desarrolló una metodología basada en la descomposición empírica de modos, fractales y redes neuronales para la clasificación automática de la imaginación motora utilizando señales de EEG. (Ruiz, 2019) integró los indicadores de Hjorth con la transformada wavelet y redes neuronales para clasificar la imaginación motora, (Montes Martínez, 2019) utilizó una metodología basada en la transformada wavelet y fractales para la clasificación de la imaginación motora. Estos tres trabajos de tesis desarrollados en la UAQ han sentado las bases para el análisis de señales EEG para la clasificación de la imaginación motora; sin embargo, es importante seguir investigando nuevos métodos/metodologías con la capacidad de clasificar el pensamiento humano con una mayor precisión; así mismo, es importante el genera una interfaz que le permita al usuario adquirir las señales sin ningún límite, así como el aplicar distintos procesamiento, lo cual no

fue realizado por las tesis anterior, las cuales dependen de un software comercial (está limitado en la cantidad de señales a adquirir, además el procesamiento está cerrado a las técnicas en el software) para la adquisición y procesamiento de las señales EEG.

1.2 Descripción del problema

El cerebro se encarga de controlar el cuerpo, una máquina que está activa sin descanso, por lo cual se puede inferir que durante día y noche se encuentra mandando distintas señales eléctricas. Existen diversas técnicas que permiten visualizar e interpretar dichas señales en características que puedan ser entendibles y manipulables. En este caso en particular se analizan las señales EEG, ya que debido a su forma, amplitud, frecuencia, rango y ubicación es posible determinar un estado mental asociado a actividades motoras, sensoriales, estados de sueño o algunas enfermedades (Bermúdez G et al., 2013). A medida que las características extraídas por la técnica de procesamiento se encuentren estadísticamente más separadas menor será el error (Renfrew, 2009). Debido a la misma naturaleza de las señales EEG es complicada la elección de alguna técnica o proceso, ya que son altamente no lineales, inmersa en ruido y no son estacionarias, por esto se debe seleccionar una metodología que se adapte mejor a las características antes mencionadas, ya que solo así se obtendrá una eficiencia en la clasificación de estos pensamientos motores. Esto da la pauta de mencionar que no son tan eficientes y no pueden ser implementadas en línea, debido a la alta carga computacional de los diversos métodos que se emplean actualmente para la caracterización de las señales EEG (Renfrew, 2009).

Además, otro problema presente en este tipo de proyectos es la limitación por parte del software que se emplea, ya que, si bien tiene un uso de licencia comercial, obligando al usuario a pagar una renta mensual o bien limita la lectura de los pensamientos a una fracción de la capacidad real debido a razones propias de ellos creadores. Debido a estas limitaciones es de gran utilidad el desarrollar una interfaz propia, permitiendo utilizar más áreas del sensor y quitando las limitantes de dependencia que los desarrolladores crean.

Dado estas consideraciones se tiene la necesidad de explorar los algoritmos o métodos para verificar el rendimiento obtenido en las características señales EEG, que permitan obtener una baja carga computacional con los métodos estadísticos utilizados, sin comprometer los

resultados en la distinción de los diferentes estados mentales y así implementar estos en un actuador de tipo brazo robot.

1.3 Justificación

En base a los problemas detectados en la revisión de la literatura, la justificación en el desarrollo de este trabajo se basa en los siguientes argumentos.

- Mejorar el tiempo de respuesta utilizando indicadores estadísticos, ya que son de baja carga computacional, siendo capaz de proporcionar un resultado en línea.
- Realizar una interfaz de usuario no comercial para aprovechar más de los posibles resultados del sensor EMOTIV EPOC+, ya que actualmente los programas con los que se utilizan este tipo de lecturas, están limitados a cierto número de pensamientos o movimientos.
- Mejorar el nivel de exactitud en la clasificación de los pensamientos por medio de los indicadores estadísticos.

Los movimientos faltantes por alguna discapacidad neuromotriz o física son de gran importancia restablecerlos, ya que al ser carentes en la persona disminuye nuestras actividades y de igual forma nuestra autoestima. Debido a lo antes mencionado el hombre estudio distintas formas de encontrar un remplazo a una falta de movilidad o perdida de extremidad con la finalidad de mejorar la calidad de vida en curso, esto ha dado como resultado diversas tecnologías, siendo la lectura de señales EEG una de estas y con ello hacer funcionar algún actuador como una prótesis o silla de ruedas. Hoy en día se presenta como una alternativa el uso de señales EEG a partir de un sensor que pueda captarlas y un controlador que pueda procesarla, esto genero diversas e innovadoras tecnologías que facilitan la reintegración de algunas actividades. Con una correcta implementación se permite al usuario evitarse problemas tales como enfrentarse a un músculo o extremidad que ya no reciba una señal mioeléctrica a través del sistema nervioso, ya que con estas lecturas se puede lograr que una persona utilice algún dispositivo externo con un control más eficiente y seguir con su vida de forma óptima.

Es por esto que la justificación del trabajo presente es lograr una metodología basada en señales EEG que permita caracterizar entre distintos movimientos de nuestra imaginación,

implementando una metodología ligera a diferencia de las ya propuestas en cuestión a carga computacional, los movimientos serán arriba, abajo y reposo para aplicarlos en un actuador final, tal como una silla de ruedas o una prótesis. Siendo el caso de este proyecto se utilizará como actuador el efector final de un pequeño brazo robótico. Este actuador se controlará con la clasificación de los estados mentales presentados obtenidos y diferenciados gracias al aplicado de señales EEG.

Impacto tecnológico

Este proyecto de tesis permitirá el desarrollo de una interfaz que en conjunto con el casco EMOTIV EPOC+ permitirá el monitoreo, adquisición y procesamiento de señales EEG de maneja libre, lo que generaría que no se dependiera de software comercial que es de arquitectura cerrada (por ejemplo, este tipo de softwares están limitados en la cantidad de pruebas y están limitados en las técnicas de procesamiento).

Impacto social

El impacto social se basa en el desarrollo de un prototipo para la clasificación del pensamiento humano, que en particular a las personas cuadripléjicas les permitiría recuperen algo de su independencia a través del pensamiento humano y un actuador que les permita por ejemplo el movimiento de una silla de ruedas. Para esto se impartirá una presentación a manera de platica sobre la utilidad del prototipo generado en este trabajo de tesis, permitiendo dar a conocer a los asistentes sobre sus alcances y así ellos puedan observar/visualizar el impacto del proyecto en algún caso en particular.

El uso de una interfaz propia permitirá explorar más los pensamientos de forma detallada, sin tener que sacrificar la carga computacional de los procesos para que la clasificación no dependa de algún tercero en nuestro proyecto, por esto y las razones previamente vistas, la metodología de este trabajo será disminuir los tiempos de procesamiento aligerando la carga computacional, que permita a un actuador moverse de acuerdo a lo que se piensa.

1.4 Hipótesis

Mediante el monitoreo de señales EEG por medio del casco EMOTIV EPOC+, la integración de indicadores no estadísticos, tales como varianza, curtosis, media y redes neuronales se desarrollará una metodología que permita la clasificación automática de la imaginación motora, en particular pensamientos que simulen movimientos hacia la arriba, abajo, y reposo.

1.5 Objetivo General

Proponer y desarrollar una metodología basada en indicadores estadísticos y redes neuronales para la clasificación automática de las señales EEG de imaginación motora (pensamientos que simulen movimientos hacia la arriba, abajo, y reposo) utilizando las señales adquiridas del cerebro a través del casco EMOTIV EPOC+.

1.5.1 Objetivos particulares

1. Desarrollar una interfaz que permita la lectura/adquisición de señales EEG del casco EMOTIV EPOC+ mediante el uso de lenguaje/software tal como MATLAB, Python, etc.
2. Programar los indicadores estadísticos (5to y 6to momento, varianza, desviación estándar, curtosis, factor latitud, oblicuidad, entre otros) con ayuda del software MATLAB con el fin de estimar características en la señal EEG.
3. Analizar las señales EEG adquiridas mediante los indicadores estadísticos con el fin de distinguir entre los diferentes pensamientos.
4. Realizar un análisis estadístico a las características estimadas de las señales obtenidas empleando el análisis de Kruskal Wallis para determinar cuáles son las más útiles para distinguir entre los diferentes pensamientos.
5. Diseñar una red neuronal de tipo PM haciendo uso del software MATLAB o Python para interpretar las características más discriminantes obtenidas, para clasificar los diferentes pensamientos de forma automática.

6. Realizar un análisis estadístico de las diferentes pruebas con el fin de validar la metodología propuesta para realizar la distinción entre los diferentes pensamientos de manera eficiente y confiable (pensamientos arriba, abajo y reposo).
7. Aplicar la metodología propuesta a través de la fusión MATLAB o Python-Arduino para mover el efector final de un robot comercial de la marca Steren k-680.

2 Revisión de la literatura

Como se presentó en el capítulo anterior, este trabajo de tesis se basa en el desarrollo de una metodología basado en indicadores estadísticos y redes neuronales con el fin de diferenciar de manera automática los diferentes pensamientos, imaginación motora, empleando señales EEG. Por lo tanto, en este capítulo se presentan los fundamentos de las señales EEG, así como la matemática que involucra los indicadores estadísticos y redes neuronales. Finalmente, se describen los softwares empleados en este trabajo de tesis tal como el software Python, MATLAB y el microcontrolador para el procesamiento de los análisis.

2.1 Señales EEG

Las señales electroencefalográficas son encargadas de registrar la actividad eléctrica del cerebro en condiciones de reposo, sueño o durante actividades (Morales et al., 2009) . Estas señales eléctricas se originan en la unidad base del sistema nervioso, siendo la neurona, la cual se encarga de captar, transmitir y procesar las señales internas y externas que viajan entre las neuronas a través de impulsos eléctricos que se transmiten de una a otra neurona. Dicha actividad se propaga a través del tejido circundante, de este se puede registrar la actividad producida utilizando sensores que cumplen la función de transductores, convirtiendo la corriente iónica y extra neuronales en corrientes eléctricas (De la Torre, 2012).

En circunstancias normales hay cuatro tipos de patrones en las señales EEG:

- Las ondas α , las cuales se registran mejor en las regiones parietal y occipital mientras una persona está despierta y relajada, pero con los ojos cerrados. Estas ondas son oscilaciones rítmicas de 8Hz a 12 Hz

- Las ondas β son más intensas en los lóbulos frontales, especialmente en el área cerca de la circunvolución pre-central. Estas ondas se producen por estímulos visuales y actividad mental. Dado que muestran respuesta a estímulos provenientes de receptores y están superpuestas sobre los patrones de actividad continuos, constituyen actividad evocada. Las ondas β ocurren a una frecuencia de 13 a 25 Hz.

- Las ondas θ provienen de los lóbulos temporal y occipital. Tienen una frecuencia de 5 a 8 Hz, y son comunes en recién nacidos y en adultos que están durmiendo. El registro de las ondas θ en adultos despiertos por lo general indica estrés emocional intenso, y puede ser un precursor de una crisis nerviosa.

•Las ondas δ al parecer se emiten en un patrón general a partir de la corteza cerebral. Estas ondas tienen una frecuencia de 1 a 5 Hz, y son comunes durante el sueño y en un lactante despierto.

Durante un estudio de EEG, diversos electrodos son colocados en distintas posiciones en la superficie del cuero cabelludo empleando un pegamento temporal como se muestra en la Figura 1. En este sentido, cada electrodo está conectado a un amplificador y una máquina de grabación de EEG con el fin de que las señales eléctricas del cerebro sean convertidas en líneas onduladas para grabar los resultados (Siuly et al., 2017).

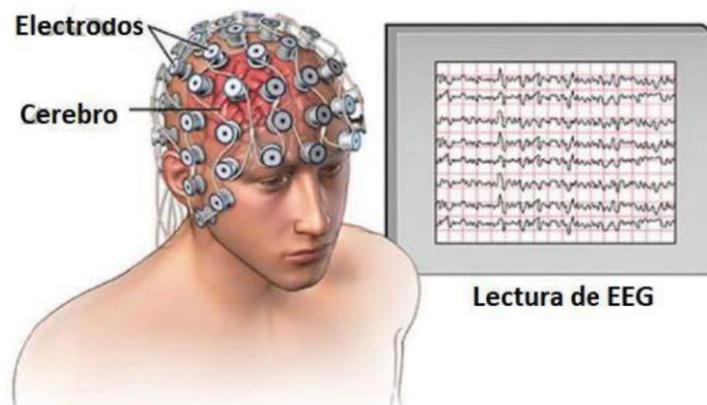


Figura 1. Ilustración de la adquisición EEG

2.1.1 Tipo de sensores para el monitoreo de señales EEG

Las señales EEG han permitido el desarrollo de estudios en distintas aplicaciones mediante la ampliación de la diferencia de potencial entre los electrodos receptores de la señal, los cuales pueden estar situados en el cuero cabelludo (sensores basales y de superficie) o subdurales. En particular, la captación de las señales se realiza de diferentes maneras, desde la toma de datos en el cuero cabelludo, en la base craneal, con el cerebro expuesto o en localizaciones cerebrales profundas. Los neurólogos creen que el origen de las tensiones que describe el EEG está en las células piramidales de la corteza cerebral (Bermudez G., et al, 2013). Cada célula constituye un diminuto dipolo eléctrico, cuya polaridad depende de que la entrada en la red a la célula sea una inhibición o una excitación. En este sentido, es importante mencionar que se obtiene una mejor resolución y disminución de ruido en la señal al estar más

cerca del cerebro (Guevara et al., 2010); por lo tanto, se pueden dividir los sensores en dos grandes ramos:

Sensores de superficie. Estos sensores son colocados en el cuero cabelludo, los cuales se caracterizan por su fácil colocación, indoloros y pueden permanecer por un tiempo prolongado en la misma posición sin ningún problema. En esta categoría existen diferentes modelos los cuales son descritos a continuación (ver Figura 2):

- a) **Electrodos de aguja.** Se caracterizan por ser agujas con un diámetro de 0.5 mm, por lo general son elaboradas con aleación de acero inoxidable o platino. Siendo estos insertados bajo el cuero cabelludo
- b) **Adheridos.** Son pequeños discos metálicos de 5 mm de diámetro. Se adhieren con pasta conductora y se fijan con colodión que es un aislante. Aplicados correctamente dan resistencias de contacto muy bajas.
- c) **De contacto.** Son tubos pequeños de plata clorurada enroscados a un soporte de plástico. En el extremo de contacto se pone una almohadilla húmeda con solución conductora. Son sujetados al cráneo con unas bandas elásticas y conectados con pinzas de cocodrilo. Se colocan fácilmente, pero pueden ser incómodos para los pacientes. Por lo cual no son utilizados en registros de amplia duración.
- d) **Casco de malla.** Es un sensor en forma de casco elástico donde se introducen varios electrodos, dando comodidad en la colocación y el registro. Este cambia de tamaño de acuerdo al paciente.

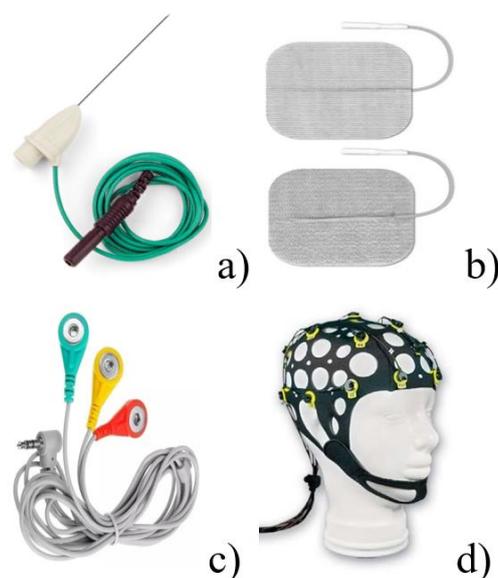


Figura 2. Sensores de superficie, (a) de aguja, b) adheridos, c) contacto y (d) casco de malla.

Sensores subdurales. Son sensores que se utilizan para registrar la actividad eléctrica directamente del cerebro. Este tipo de sensor se implantan en cirugía bajo anestesia general. Estos permiten tener una mejor captación de la estimulación eléctrica de las neuronas para activar y estudiar ciertas zonas del cerebro (De la torre, 2012).

2.1.2 Imaginación motora

La imaginación de movimiento o imaginación motora (IM), es la representación mental de movimientos que involucran la planeación motora y una simulación interna de una actividad motora, sin realizar movimientos reales (Jeannerod & Frak, 1999). Se ha reportado que la IM tiene los mismos componentes, e involucra las mismas áreas cerebrales, que cuando se realiza un movimiento real (Rodríguez et al., 2009). Por lo tanto, los patrones de activación cerebral consisten en cambios de los patrones en los electroencefalogramas o señales EEG, requiriendo de un método capaz de identificar estos patrones de manera adecuada con el fin de asociarlos al pensamiento realizado.

El entrenamiento con imaginación motora es una técnica muy utilizada en el ámbito deportivo para mejorar el desempeño motor de los deportistas y de personas con alguna pérdida de extremidad. Dado que la imaginación motora supone un trabajo off-line sobre ciertos esquemas de movimiento (sin ejecutar movimientos, ni recibir información feedback del entorno ni del propio cuerpo), ha de suponerse que si un entrenamiento de este tipo es eficaz existen procesos comunes entre la ejecución y la imaginación de los movimientos involucrados. Por lo tanto, esos procesos pudieran explicarse computacionalmente a modelos de procesamiento predictivo de la cognición (Clark, 2015).

2.2 Procesamiento digital de señales

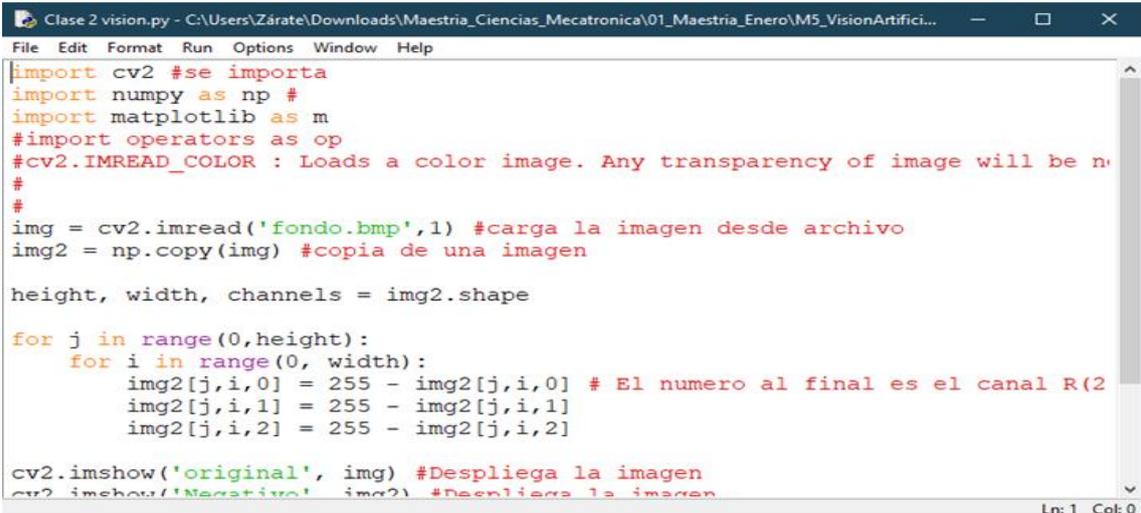
El procesamiento digital de señales (PDS) es un área de la ingeniería electrónica que se encarga en la representación, transformación y manipulación de la información contenida tanto

en señales en tiempo como en imágenes. Con base en ello, el procesamiento se encarga del manejo o identificación de las características que contienen las señales analizadas.

2.2.1 Python

Python es un lenguaje de scripting independiente de plataforma y orientado a objetos, preparado para realizar cualquier tipo de programa, desde aplicaciones Windows a servidores de red o incluso, páginas web. Es un lenguaje interpretado, lo que significa que no se necesita compilar el código fuente para poder ejecutarlo, lo que ofrece ventajas como la rapidez de desarrollo e inconvenientes como una menor velocidad (Alvarez, 2003) .

Python se basa en una ventana principal tipo bloc de notas, se divide en una sola sección que es el área de trabajo, ya que corre directo sobre el portal, no ocupando un compilador propio, el editor de archivo permite crear la descripción del código que se requiere para el procesamiento de las señales, en este mismo programa se puede realizar mediante código un espacio de trabajo que permite visualizar las variables y su entrada de las señales procesadas. En la Figura 3 se añade una ventana de bloc de notas, la cual cuenta con una barra de opciones para guardar, editar, correr y dar opciones del programa, el resto es un espacio de un programa con sus respectivas librerías y código. Al generar un nuevo programa esta ventana aparecerá en blanco permitiéndonos añadir los elementos que requiramos y simplemente ejecutar sin un compilador.



```
Clase 2 vision.py - C:\Users\Zárate\Downloads\Maestria_Ciencias_Mecatronica\01_Maestria_Enero\M5_VisionArtifici...
File Edit Format Run Options Window Help
import cv2 #se importa
import numpy as np #
import matplotlib as m
#import operators as op
#cv2.IMREAD_COLOR : Loads a color image. Any transparency of image will be n
#
#
img = cv2.imread('fondo.bmp',1) #carga la imagen desde archivo
img2 = np.copy(img) #copia de una imagen

height, width, channels = img2.shape

for j in range(0,height):
    for i in range(0, width):
        img2[j,i,0] = 255 - img2[j,i,0] # El numero al final es el canal R(2
        img2[j,i,1] = 255 - img2[j,i,1]
        img2[j,i,2] = 255 - img2[j,i,2]

cv2.imshow('original', img) #Despliega la imagen
cv2.imshow('Negativo' img2) #Despliega la imagen
Ln: 1 Col: 0
```

Figura 3. Interfaz de PYTHON

2.2.2 MATLAB

MATLAB es un software comercial de alto nivel, el cual permite la manipulación de vectores o matrices (señales digitales), con el fin de visualizar, modelar, analizar y procesar información (Leis, 2011). En particular, MATLAB se basa en una ventana principal, la cual está subdividida en cuatro ventanas (ver Figura 4):

- **Ventana de comandos.** ventana usada para el análisis de señales y entrada de datos actuales
- **Ventana de espacio de trabajo.** Es utilizada para visualizar las variables utilizadas en el momento que se trabaja y el valor actual
- **Ventana de detalles.** Esta ventana se utiliza para revisar el historial de las operaciones realizadas.
- **Ventana de carpeta actual.** Es utilizada para ver los archivos dentro de la carpeta de trabajo.

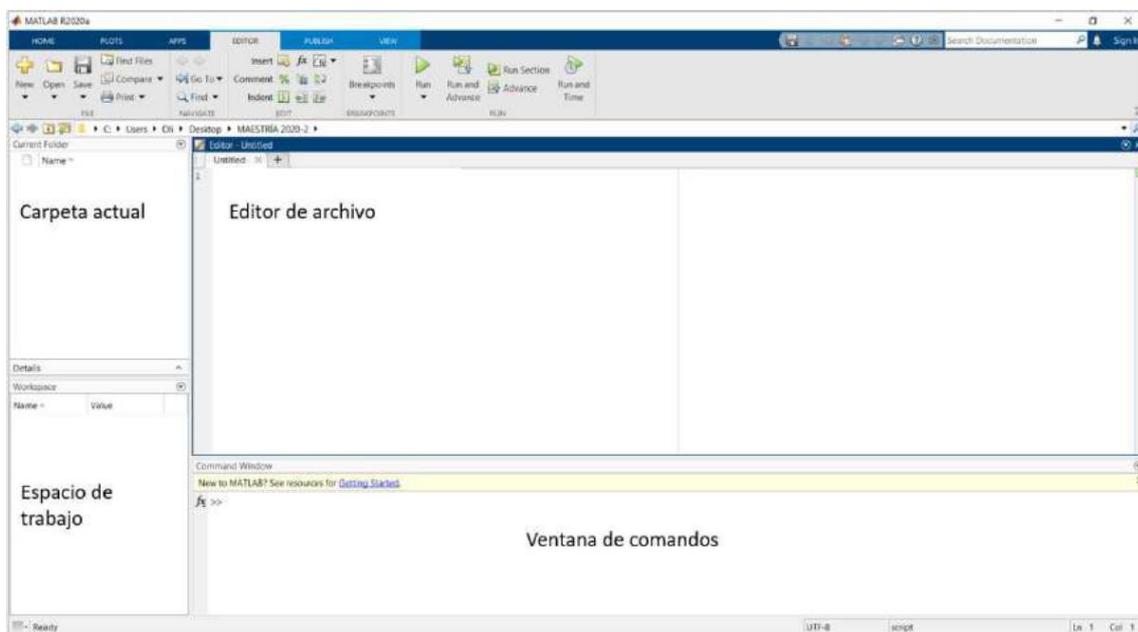


Figura 4. Ventana de trabajo MATLAB

2.2.3 Indicadores Estadísticos

El procesamiento de señales es un área centrada principalmente en la estimación de modelos o propiedades con el potencial de ser correlacionado con un fenómeno examinado. En la última década, propiedades como la dimensión fractal, la entropía, la distancia de Mahalanobis (Bradley, 1997; Bai et al., 2012; Kittler, 2014; Rayal et al., 2019), entre otros, se han introducido en la literatura para estimar diversas propiedades en las señales estudiadas, pero su cálculo presenta una alta carga computacional, limitando su aplicación en fenómenos donde se requiere un resultado en tiempo real. En particular, los indicadores estadísticos han demostrado ser eficientes para estimar las propiedades o modelos de señales no estacionarias o variantes en el tiempo, por ejemplo, electroencefalogramas, vibraciones, electrocardiogramas, además de identificar enfermedades en humanos, entre otros. En consecuencia, los indicadores estadísticos se caracterizan por requerir una baja carga computacional (no se emplea ninguna transformación) ya que, menos operaciones matemáticas que las otras propiedades antes mencionadas son requeridas (Hassan & Hassan Bhuiyan, 2016), lo que permite obtener resultados en tiempo real o casi instantáneamente (Bradley, 1997) (Rayal et al., 2019). Por esta razón, las capacidades de 17 indicadores estadísticos (Ecuaciones (1)–(17)), resumidas en la Tabla 1, (X representa la señal de tiempo con N muestras), son investigadas en este trabajo de tesis con el fin de asociar las más útiles a la distinción de los diferentes pensamientos.

Tabla 1 Indicadores estadísticos

Indicador estadístico	Descripción	Ecuación	
MODA	Valor que más se repite en un conjunto de datos.	$X_{mo} = moda(x_i)$	(1)
MEDIANA	Valor central de un conjunto de datos.	$X_{me} = magnitud\left(\frac{N+1}{2}\right)$	(2)
VALOR CUADRÁTICO MEDIO (RMS)	Energía de la señal.	$X_{rms} = \left(\frac{1}{N} \sum_{i=1}^N x_i^2\right)^{\frac{1}{2}}$	(3)

VALOR MEDIO CUADRÁTICO (SMR)	Mide la energía de la señal de forma similar al RMS, pero este es más sensible al tamaño de la señal.	$X_{smr} = \left(\frac{1}{N} \sum_{i=1}^N x_i ^2 \right)^2$	(4)
RANGO	Dispersión de los datos	$X_{rg} = \max(x_i) - \min(x_i)$	(5)
MEDIA	Valor promedio de la señal.	$X_{\mu} = \frac{1}{n} \sum_{i=1}^n x_i$	(6)
VARIANZA	Promedio de los valores cuadrados de la desviación de esa variable.	$X_{\sigma^2} = \frac{1}{N-1} \sum_{i=1}^N x_i^2$	(7)
DESVIACIÓN ESTÁNDAR	Dispersión de los datos en base su media.	$X_{\sigma} = \sqrt{X_{\sigma^2}}$	(8)
SKEWNESS	Medida de la asimetría de la probabilidad de distribución de los datos.	$X_{sk} = \frac{\sum_{i=1}^N (x_i - x_{\mu})^3}{(N-1)x_{\sigma}^3}$	(9)
KURTOSIS	Indicador del grado de nitidez de la distribución de probabilidad.	$X_{ku} = \frac{\sum_{i=1}^N (x_i - x_{\mu})^4}{(N-1)x_{\sigma}^4}$	(10)
QUINTO MOMENTO	Medida de la elongación de una distribución probabilística del conjunto de datos.	$X_{5^{th}m} = \frac{\sum_{i=1}^N (x_i - x_{\mu})^5}{(N-1)x_{\sigma}^5}$	(11)
SEXTO MOMENTO		$X_{6^{th}m} = \frac{\sum_{i=1}^N (x_i - x_{\mu})^6}{(N-1)x_{\sigma}^6}$	(12)
FACTOR DE FORMA CON RMS	Relación de la magnitud de la forma de onda continua y el promedio de la señal.	$X_{sfrms} = \frac{X_{rms}}{\frac{1}{N} \sum_{i=1}^N x_i }$	(13)
FACTOR DE FORMA CON SMR		$X_{sfsmr} = \frac{X_{smr}}{\frac{1}{N} \sum_{i=1}^N x_i }$	(14)
FACTOR CRESTA	Diferencia entre valores mínimos y máximos relativos al tamaño medio de la señal.	$X_{cf} = \frac{\max(x_i)}{X_{rms}}$	(15)
FACTOR IMPULSO	Indicador de la magnitud del mayor impulso de la señal.	$X_{if} = \frac{\max(x_i)}{\frac{1}{N} \sum_{i=1}^N x_i }$	(16)
FACTOR LATITUD	Relación del valor máximo de la señal y el valor SMR.	$X_{lf} = \frac{\max(x_i)}{X_{smr}}$	(17)

2.2.4 Transformada Wavelet por paquetes

La transformada wavelet (WT por sus siglas en inglés Wavelet Transform) es un algoritmo eficiente para el análisis tiempo-frecuencia de señales no-estacionarias (señales que varían sus características a lo largo del tiempo), encontrando una gran aceptación en el análisis

de señales provenientes del cuerpo humano, las cuales tienen un gran impacto en la ingeniería biomédica (Cortes et al., 2007).

La Transformada de Wavelet por paquetes (WPT por sus siglas en inglés, Wavelet Packet Transform) es una variante de la transformada discreta wavelet, con el fin de descomponer una señal en diferentes bandas de frecuencia, pero esta descompone iterativamente no solo la aproximación, filtro pasa-bajas, estimada obtenidos de la etapa o nivel anterior, sino también los de detalle (filtro pasa altas), dando lugar a una estructura en árbol doble como se puede observar en la Figura 5. En otras palabras, la WPT se caracteriza por ofrecer un análisis más detallado que la tradicional transformada wavelet discreta ya que en el WPT las aproximaciones y los detalles se descomponen en un nuevo grupo de la misma (Abbasi et al., 2017) creando un árbol tiempo-frecuencia más minucioso. Estas bandas de frecuencia, llamadas nodos, permiten una representación y estudio más detallado de la señal (Perez-Sanchez et al., 2020).

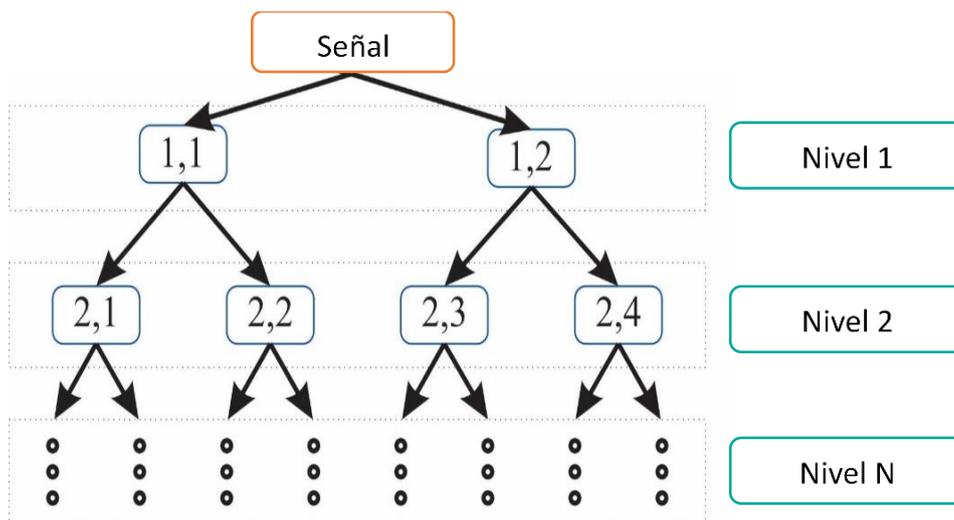


Figura 5. Diagrama de niveles para transformada wavelet por paquetes

WPT se define de la siguiente manera:

$$W_{j,k}^n(t) = 2^{j/2} W^n(2^j t - k) \quad (18)$$

donde j es el parámetro de escala (localización de frecuencia), k representa el parámetro de traslación (localización temporal), n es un parámetro de oscilación y W representa la ondoleta madre. En este sentido, la Ecuación (18) es resuelta a través de las siguientes ecuaciones con el fin de obtener/estimar los nodos o bandas de frecuencia de cada nivel:

$$W^{2n}(t) = \sqrt{2} \sum_{k=-\infty}^{\infty} h(k)W^n(2t - k) \quad (19)$$

$$W^{2n+1}(t) = \sqrt{2} \sum_{k=-\infty}^{\infty} g(k)W^n(2t - k) \quad (20)$$

donde h representa los coeficientes de filtro pasa bajas y g son los coeficientes de filtro pasa altas.

A lo largo de los años, se han empleado diversas ondoletas madre (p. ej., Daubechies, biortogonal, Morlet, entre otras) para realizar el método WPT, lo que ha dado como resultado que Daubechies presente resultados confiables para analizar o procesar señales biomédicas (Rafiee et al., 2011).

2.2.5 Kruskal Wallis

Esta prueba no paramétrica es análoga a la prueba paramétrica ANOVA de una vía. Este es un método no paramétrico para probar si un grupo de datos proviene de la misma población. Ya que es una prueba no paramétrica no asume normalidad en los datos, en oposición a la tradicional ANOVA, la cual si asume bajo la hipótesis nula que los datos vienen de la misma distribución. A diferencia del ANOVA en el que se comparan medias, el test de Kruskal Wallis (por sus siglas en inglés Kruskal Wallis Test KWT) contrasta si las diferentes muestras están equidistribuidas y que por lo tanto pertenecen a una misma distribución (población). Bajo ciertas simplificaciones puede considerarse que el test de Kruskal Wallis compara las medianas (Bashar & Bhuiyan, 2016)

H0: todas las muestras provienen de la misma población (distribución).

HA: Al menos una muestra proviene de una población con una distribución distinta.

Para determinar si cualquiera de las diferencias entre las medianas es estadísticamente significativa, se compara el valor p con el nivel de significancia para evaluar la hipótesis nula. La hipótesis nula indica que las medias de población son todas iguales. Por lo general, un nivel

de significancia (denotado como α o alfa) de 0.05 funciona adecuadamente. Un nivel de significancia de 0.05 indica un riesgo de 5% de concluir que existe una diferencia cuando no hay una diferencia real (Bashar & Bhuiyan, 2016) Esto será de utilidad para evaluar las lecturas tomadas, ya que se verificará de acuerdo a los indicadores estadísticos la diferencia entre un pensamiento y otro. Como se muestra en la Figura 6 se tienen dos conjuntos en el cual uno de ellos (a) se encuentra con datos diferentes, lo cual indica que son diferente pensamiento, mientras que en (b) se observa que los datos comparados son similares, dando por entendido que los pensamientos son el mismo y pueden ser validados como independiente y diferente. En consecuencia, el KWT y su valor p se utilizan en este trabajo de tesis para determinar los indicadores estadísticos con la información más útil para clasificar tres IM (arriba, abajo y descanso).

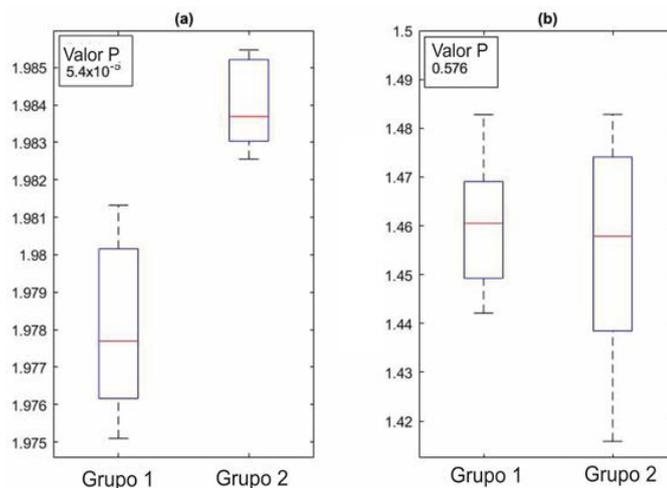


Figura 6. Valores estimados por análisis estadístico

2.2.6 Clasificador basado en redes neuronales

La neuro-computación es una aportación al conocimiento humano con el objetivo de crear sistemas inteligentes, considerando como tales máquinas o sistemas capaces de llevar a cabo tareas que exhiben alguna de las características asociadas a la inteligencia humana. En las dos últimas décadas, los avances en este campo han sido espectaculares; en particular el

desarrollo de las redes neuronales artificiales (RNA), las cuales se asemejará a la fisiología del cerebro humano, permitiendo el reconocimiento de patrones, predicción, optimización, entre otras aplicaciones. Existen muchas topologías de RNA, pero el perceptrón multicapa es una de las redes más utilizadas y eficiente para la clasificación de patrones (Bala & Kumar, 2017) En particular, este tipo de estructura, las conexiones entre neuronas siempre se alimentan hacia adelante, es decir, las conexiones se alimentan en las neuronas en una cierta capa hacia las neuronas en la siguiente capa.

El perceptrón multicapa se compone principalmente de tres capas: (1) una capa de entrada, una capa oculta (esta capa puede contener una, dos o las capas necesarias de neuronas) y una capa final de neuronas de salida como se muestra en la Figura 7 La MLP se basan en las conexiones de las neuronas a través de ponderaciones que ocurren dentro de la red. Dentro de esta red se establecen pesos mediante un proceso de entrenamiento debido a los valores de entrada y de salida, los cuales son enviados repetidamente para su formación. Los pesos son ajustados repetidamente en cada repetición con el propósito de acercar los valores de la salida de la red a los valores deseados. Cada neurona tiene como propósito específico dedicarse a la función de entrada o salida, además que algunas otras capas ocultas se hacen internas a la red creando la configuración/arquitectura mencionada para el procesamiento de la información más específica (Moghaddasi & Noorian-Bidgoli, 2018)

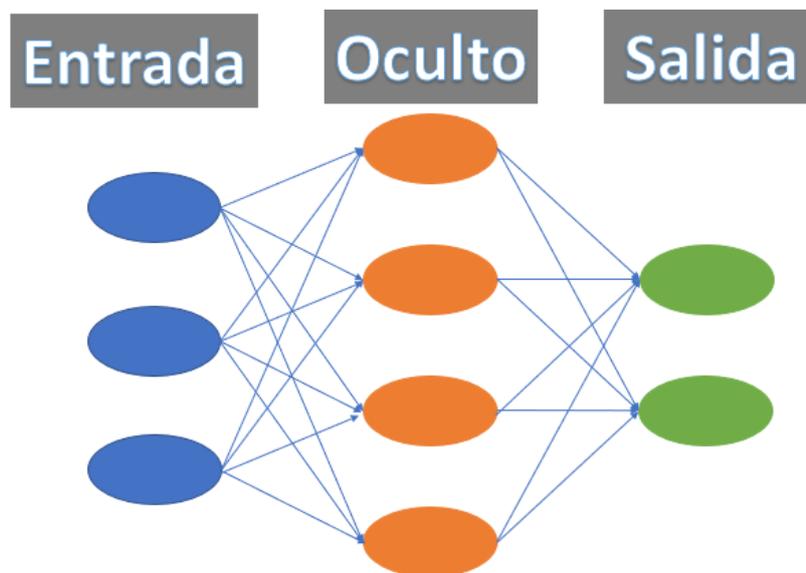


Figura 7. Red Neuronal Multicapa

Es importante mencionar que para realizar un perceptrón multicapa, la capa oculta debe contener como mínimo el doble de neuronas de acuerdo a las entradas, sin embargo, siempre dependerá del objetivo que se busca para realizar un ajuste fino y obtener mejores resultados (Wang, 2003).

2.3. Interfaz hombre-maquina

Hoy día distintos marcos de interacción se emplean para la captura de diferentes señales provenientes del cuerpo humano, como los movimientos musculares, gestos corporales, faciales y movimientos. En este sentido, HMI (human-machine interface por sus siglas en inglés) permite a un usuario comunicarse con una máquina, software o sistema. Técnicamente, se refiere a cualquier pantalla que se usa para interactuar con un equipo, pero es empleado normalmente para las de entornos industriales. Las HMI permite mostrar datos en tiempo real y permite al usuario controlar las máquinas con una interfaz gráfica de usuario.

La HMI se caracteriza por monitorear directamente la actividad cerebral y asociar esta con el pensamiento del usuario o ser humano, traduciendo o procesando la señal monitoreada en actividades relacionadas con diversas aplicaciones tales como el movimiento de una silla de ruedas, el movimiento de in brazo, entre otras aplicaciones (Shih et al. 2012):

Un sistema HMI consta de 4 componentes secuenciales: (1) adquisición de la señal dada por el usuario (en particular para esta tesis, este punto se refiere a la toma de las señales EEG), (2) extracción de características (esta sección se enfoca al procesamiento de las señales, p. ej., la transformada wavelet e indicadores estadísticos), (3) interpretación de las características (clasificación de las características con el fin particular de la tesis de asignarlas a un pensamiento) y (4) dispositivo de salida (los pensamientos asociarlos al movimiento de un actuador tal como un brazo robótico) como se muestra en la Figura 8. Estos 4 componentes son controlados mediante un protocolo de operación que define el inicio y tiempo de operación, los detalles del procesamiento de la señal, la naturaleza de los comandos del dispositivo y la supervisión del rendimiento.

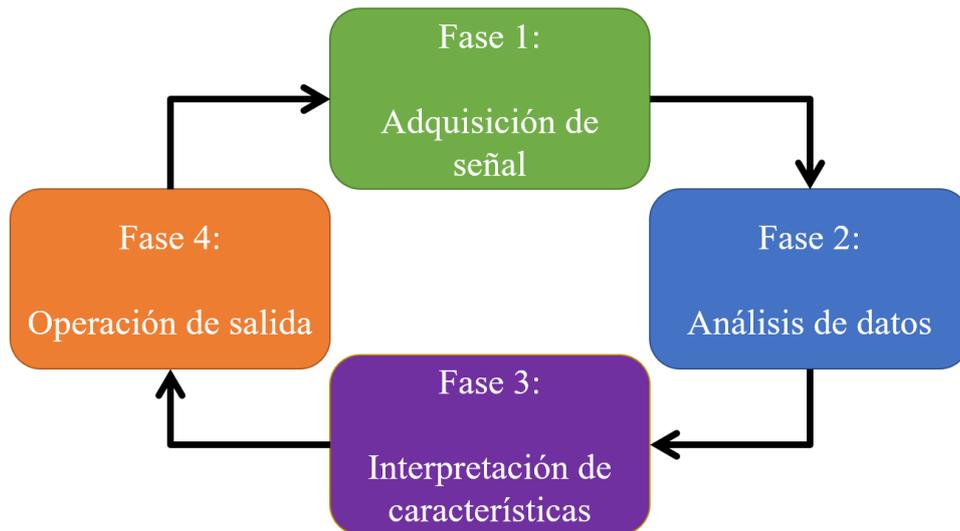


Figura 8. Componentes de sistema HMI

2.4. Microprocesador Arduino

Arduino (ver Figura 9) es una plataforma de electrónica/software de código abierto para la creación de prototipos de hardware flexible y fácil uso, ya que esta integra un microcontrolador reprogramable y una serie de pines que le permiten establecer conexiones entre los distintos actuadores y sensores. La placa electrónica es diseñada por el proveedor, por lo tanto, el usuario final no debe preocuparse por las conexiones eléctricas necesarias que necesita el microcontrolador para funcionar y puede empezar directamente a desarrollar diferentes aplicaciones electrónicas.

Para el desarrollo de este trabajo de tesis se optó por trabajar con la placa de Arduino mega, ya se adapta al trabajo de tesis, dado que tiene mayor capacidad de memoria y velocidad de procesamiento. Los microcontroladores utilizados en las placas de Arduino cuentan con una arquitectura del tipo AVR (Automatic Voltage Regulator), arquitectura desarrollada por Atmel. La programación es apta para distintos ecosistemas como Windows, Mas OS y Linux, siendo su lenguaje base C++ (Arduino, 2019).

La Tabla 2 presenta las características más importantes de la Arduino seleccionada para este trabajo de tesis.

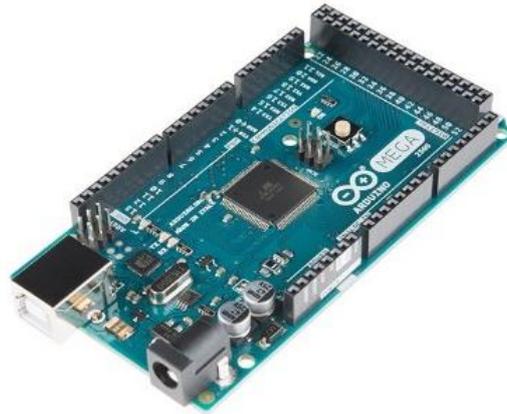


Figura 9. Arduino Mega

Tabla 2. Características de la Arduino modelo Mega

Arduino Mega	
Dimensiones (in)	4 in x 2.1 in
Procesador	ATmega2560
Velocidad e reloj	16MHz
Memoria flash(kB)	256
SRAM (kB)	8
Voltaje de trabajo	5v
Entradas y salidas digitales	54
Entradas y salidas con PWM	15
Pines analógicos	16
Conectividad USB	Estándar A/B USB

2.5. Actuador

Un actuador es un dispositivo que convierte la energía eléctrica en movimiento mecánico. El dispositivo toma energía de una determinada fuente (que puede ser energía creada por aire, líquido o electricidad) y la convierte en el movimiento deseado. Los dos tipos de movimiento básicos deseados son lineal y rotativo, pero también es común el movimiento oscilatorio (Corona, 2014). En este sentido, el actuador giratorio a (ver Figura 10) genera

movimiento giratorio a través del eje, como controlar la válvula de bola/válvula de mariposa para girar 90 grados para abrir o cerrar la válvula. Los actuadores rotativos pueden seleccionar el ángulo de rotación según las necesidades de la industria para adaptarse perfectamente a las necesidades de la industria. Por otro lado, el actuador lineal b (ver Figura 10) se mueve en una dirección de línea recta. Es como un brazo robótico, que se puede extender o acortar y se puede usar para mover objetos repetidamente.

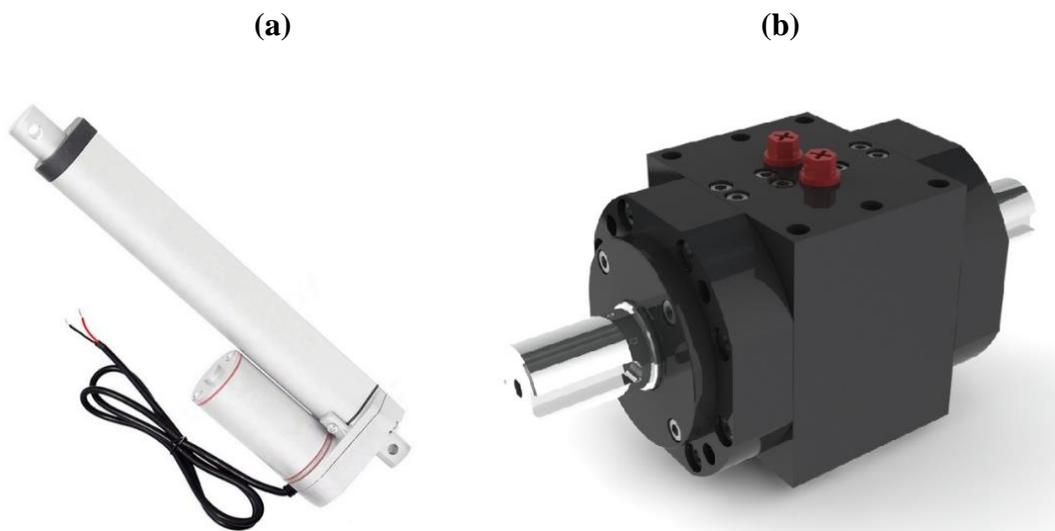


Figura 10. Actuadores (a) lineales y (b) rotativos.

3 Metodología

Este capítulo se centra en la descripción de la metodología propuesta para el procesamiento de las señales EEG con el fin de poder clasificar automáticamente el pensamiento humano. Del mismo modo se describe la base de datos y el análisis hecho con las señales monitoreadas.

3.1. Metodología propuesta

La Figura 11 presenta gráficamente los pasos de la metodología propuesta basada en la integración de WPT, Indicadores estadísticos y una MLP para clasificar automáticamente tres movimientos imaginados (reposo, arriba y abajo) y que estos muevan el efector final de un brazo robótico. Para poder realizar la tarea antes mencionada, la propuesta metodológica se divide en dos etapas: (1) procesamiento, Figura 11(a) donde las señales EEG son adquiridas mediante una diadema EMOTIV+ configurada para trabajar con una frecuencia de muestreo de 256 Hz para 14 canales, cada movimiento imaginado de cada participante es tomado a partir de una muestra de cinco segundos, estas señales adquiridas son procesadas por WPT para descomponer las señales EEG en diversas bandas de frecuencia con el fin de obtener un análisis más detallado de señales EEG (Chu, 2015), el cual se realiza sobre ocho niveles para observar cual es el que permite obtener las mejores características. Posteriormente, las bandas de frecuencia estimadas por WPT son analizadas a través de 17 indicadores estadísticos para estimar patrones o características con capacidad de diferenciar entre los movimientos imaginados. Una vez que se calculan los valores de indicadores estadísticos a cada banda de frecuencia y para cada movimiento imaginado de cada canal, estos son evaluados utilizando KWT para determinar los patrones más útiles para reconocer los tres pensamientos (reposo, arriba y abajo). Ya identificadas las características más relevantes, seleccionadas de acuerdo con el KWT, estas son empleadas para entrenar y validar una MLP-ANN para identificar automáticamente el movimiento imaginado.

Ya con el procesamiento identificado, como paso 2 de la metodología propuesta, ver Figura 11(b) se procede a validar este procesamiento con señales que se adquieren en tiempo real y estas son procesadas por la etapa de procesamiento con el fin de decir en línea a que pensamiento se refiere la señal monitoreada y en base a ello poder asociarla al movimiento del efector final de un brazo robótico.

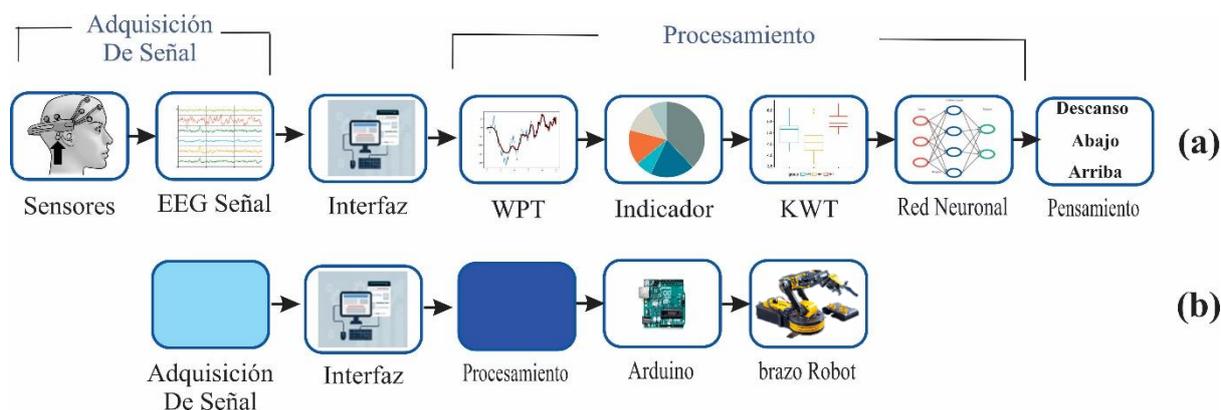


Figura 11. Metodología propuesta

3.2. Material

Con el fin de evaluar la efectividad del método propuesto para distinguir tres pensamientos (reposo, arriba y abajo), las señales EEG de diez participantes, cinco hombres y cinco mujeres, con edades comprendidas entre veinte y veintiséis años son analizadas. Con el fin de no generar alteraciones en la señal EEG, los participantes deben satisfacer los siguientes requisitos:

- No tomar café durante una semana antes de las pruebas
- No consumir alcohol durante una semana antes de las pruebas
- Dormir bien antes de la prueba (al menos siete horas)
- No usar productos para el cabello

Es importante resaltar que los participantes no presentan condiciones psiquiátricas o médicas que limiten el monitoreo de sus señales de EEG. Con el fin de adquirir las señales de EEG de cada participante, estos fueron expuestos a una secuencia de imágenes (Lin et al., 2019) (Montes Martínez, 2019) durante cinco segundos (esta tamaño de ventana de tiempo permite capturar información relevante asociada con la actividad cerebral (Batres-Mendoza et al., 2016) para generar diversos patrones de IM tales como: reposo arriba y abajo. En este sentido, a cada participante se le muestra una flecha hacia arriba, una flecha hacia abajo y símbolo de parada (stop), lo que indica que deben imaginar que se mueven hacia arriba, hacia abajo y reposo (ningún pensamiento), respectivamente.

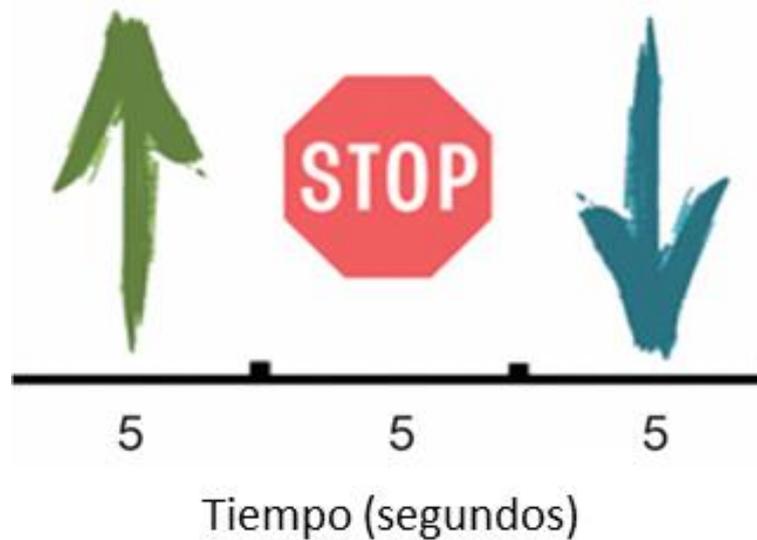


Figura 12. Protocolo visual

Para monitorear y adquirir las señales de EEG de cada participante durante la secuencia de imágenes, se emplea la diadema EMOTIV modelo EPOC+ con catorce electrodos y dos referencias colocadas según la referencia internacional 10-20, (Lin et al., 2019). La referencia internacional 10-20 indica el porcentaje de distancia entre los electrodos, donde las letras AF, F, T, C, P y O representan las secciones cerebrales: a través del frontal, frontal, temporal, central, parietal y occipital, respectivamente. Por otro lado, la palabra CMS y DRL son los puntos de referencia (Pérez-Vidal et al., 2018).

Durante cada adquisición de las señales EEG, se emplea una frecuencia de muestreo de 256Hz para adquirir las señales de EEG, lo que resulta en 3.840 muestras para cada prueba de acuerdo con la Figura 12. Un total de 300 pruebas (30 pruebas para cada participante) fueron realizadas con el fin de tener una muestra representativa. Cada prueba se realizó en una habitación sin distractores (por ejemplo, sonidos, luces u objetos) para evitar alteraciones en la actividad eléctrica del cerebro como se muestra en la Figura 13 (Pérez-Vidal et al., 2018) (Lin et al., 2019).



Figura 13. Lugar de adquisición de señales EEG.

3.3 Casco EMOTIV

El casco EMOTIV EPOC+, Figura 14(a), es un sistema de monitoreo no invasivo de señales EEG, el cual cuenta con catorce electrodos y dos más como referencia. Los electrodos se distribuidos a lo largo de diversas zonas del cerebro humano (ver Figura 14 (b)); en particular, en la parte occipital, parietal y frontal de la cabeza. donde las letras AF, F, T, C, P y O representan las secciones cerebrales: a través del frontal, frontal, temporal, central, parietal y occipital, respectivamente. Por otro lado, la palabra CMS y DRL indican los puntos de referencia (Pérez-Vidal et al., 2018).

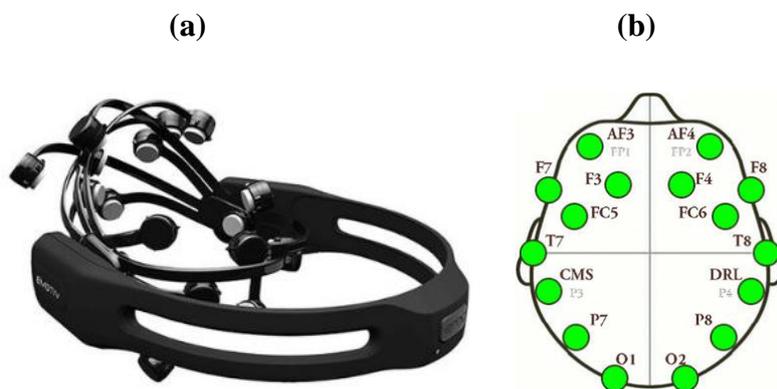


Figura 14. (a) Diadema EMOTIV EPOC+ y (b) localización de los sensores.

La diadema EPOC+ tiene entre sus principales características permite una frecuencia de muestreo de 256 Hz por canal, envío de la información a través de comunicación inalámbrica, 9 horas de batería. Adicionalmente, este casco basa su diseño y características en las siguientes normas:

- EU directive 93/42/EEC Normativa de nivel medico
- 2ADIH-EPOC02 Normativa de Dispositivo externo
- 2014/53/EU Normativa de dispositivo electrónico

Este dispositivo se basa en el estándar de colocación de electrodos extra craneales conocido como el sistema internacional 10-20 (ver Figura 15), donde 10 y 20 representan distancias reales entre los electrodos vecinos; de esta forma se entiende que hay entre 10% o 20% del total de la parte frontal o posterior, distancia derecha-izquierda del cráneo. Las letras señalan el área (Fp, prefrontal; F, frontal; C, central; P, parietal; T, temporal y O, occipital), mientras que los números designan el hemisferio (pares del derecho, nones del izquierdo) y los electrodos de la línea media se señalan con una “z”; por lo que Fz se encuentra frontalmente en la línea media.

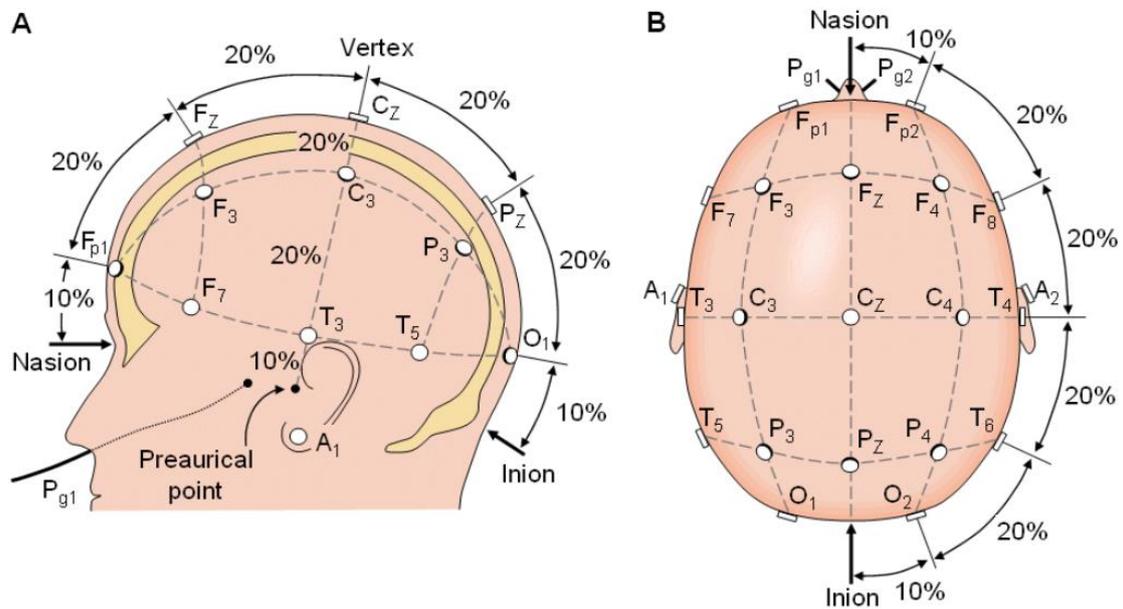


Figura 15. Sistema Internacional 10-20 para la colocación de los electrodos extra craneales.

3.3.1 Interfaz de adquisición de señales EEG

Como se muestra en la figura de la metodología propuesta, se requiere de una interfaz con el fin de adquirir las señales EEG para que en un inicio esta sirva solamente como un adquisidor (Figura 15(a)) y posteriormente como un sistema que adquiere y procesa (Figura 15(b)) la información para que un actuador realice una tarea. La Figura 16 muestra la interfaz propuesta, la cual cuenta con diversos espacios de trabajo, los cuales son descritos a continuación:

1. Ver sensor: Esta casilla permite seleccionar todos los sensores o uno en específico para su visualización en la ventana de visualización, permitiendo una rápida revisión de la adquisición.
2. Tiempo de muestreo: El cuadro de texto se habilita para introducir el tiempo de muestreo que se desea adquirir de las señales EEG, se bloquea para solo mostrar el tiempo de adquisición de alguna muestra previamente realizada.
3. Frecuencia de muestreo: Indica la frecuencia de muestreo del sistema en caso de adquisición o de visualización de una señal, la cual esta predefinida por el fabricante del casco a 256Hz.
4. Adquirir: Este pushbutton se encarga de indicar cuando adquirir la señal con el tiempo de muestreo previamente ajustado por el usuario, la señal obtenida se guarda en un archivo tipo Excel con el nombre que establezca el usuario.
5. Imaginación motora: Este pushbutton este encargado de permitir la interacción entre el usuario y un actuador con el fin de realizar los movimientos de arriba y abajo del brazo robótico.
6. Ventana de visualización: Esta ventana cuenta con dos funciones: (1) visualización de la señal adquirida por los sensores y (2) mostrar al usuario el pensamiento obtenido con la función imaginación motora.
7. Barra de herramientas: La barra de herramientas cuenta con tres opciones: (1) (inicio) cuenta con un menú desplegable con las siguientes opciones: abrir un archivo ya guardado previamente para visualizar la frecuencia de muestreo, el tiempo de muestreo y la señal obtenida por los sensores, (2) nueva adquisición habilitará los botones 4 y 5 para adquirir una nueva señal o comenzar la imaginación motora y (3) guardar el documento visualizado en alguna ruta de preferencia por el usuario. Finalmente, se

encuentra la opción de limpiar con el fin de dejar en blanco la ventana de visualización y un botón para salir de la aplicación.

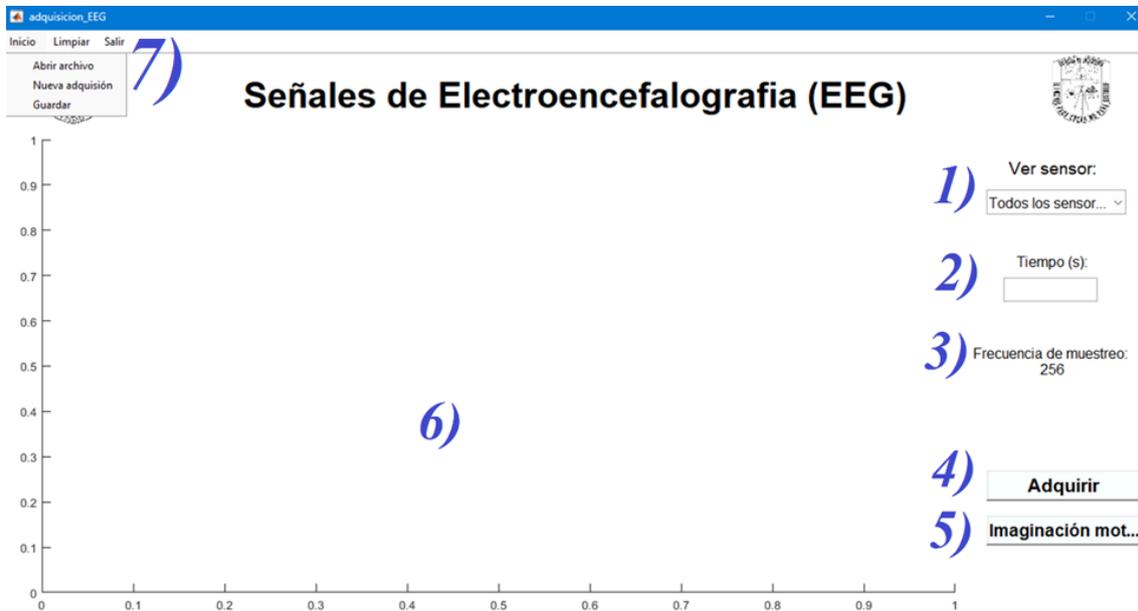


Figura 16. Interfaz creada para la adquisición de las señales EEG.

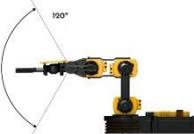
3.4 Control de brazo robótico

Dado el propósito de la tesis, se emplea un actuador que permite simular la movilidad de un brazo humano. En este sentido, se emplea el brazo robótico de la marca STEREN modelo k-680 mostrado en la Figura 17, el cual cuenta con cinco motores, uno para girar el brazo sobre su eje de izquierda a derecha, tres más para posicionar el brazo en diferentes ángulos y el último para abrir la pinza. La Tabla 3 resume los movimientos, así como los grados y distancia que puede realizar cada uno de los grados de libertad del robot.



Figura 17. Brazo Robótico STEREN 680-K

Tabla 3 Movimientos de actuador k-680

Motor	Movimiento
1 Motor horizontal, rango de 0° a 270°	
2 Motor vertical, rango 0° a 180°	
3 Motor vertical, rango 0° a 300°	
4 Motor vertical, rango 0° a 120°	

5 Motor pinza, rango 0cm - 4.5 cm



Para el control eléctrico de subida y bajada del brazo robótico se empleó el módulo L298N (ver Figura 18), el cual cuenta con dos puentes H que permiten controlar el sentido y velocidad de giro de dos motores DC. El rango de tensiones en el que trabaja este módulo es de 3V hasta 35V, y una intensidad máxima de 2A.

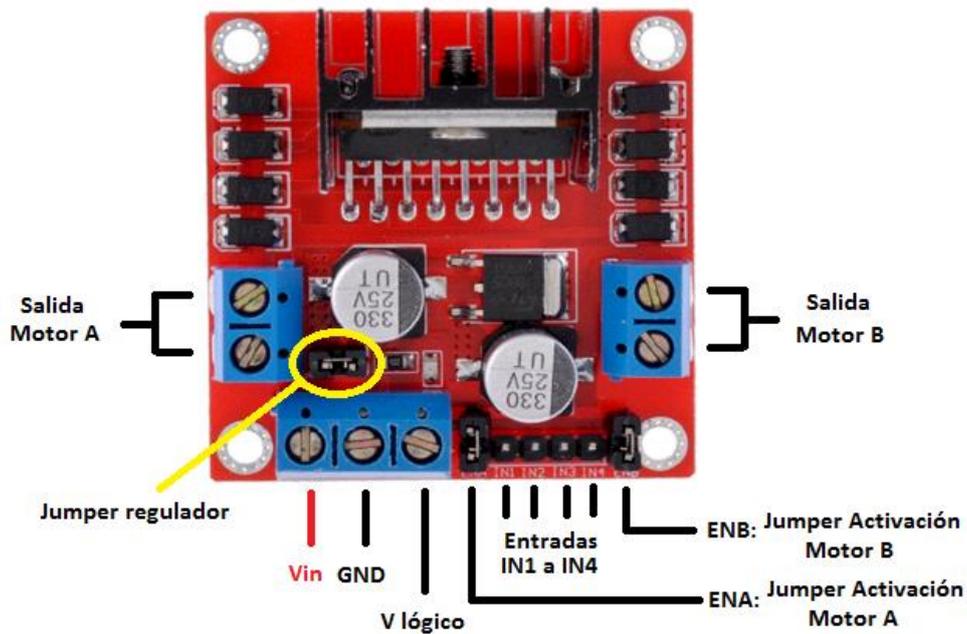


Figura 18. Módulo L298N.

Los pines mostrados en la Figura 18 se describen a continuación:

Las salidas para los motores A y B proporcionan el voltaje para el funcionamiento de motores de corriente continua. Los pines IN1 e IN2 permiten el control del sentido de giro del motor A. Por otro lado, los pines IN3 e IN4 permiten el control del sentido de giro del motor B. Estos funcionan de forma que, por ejemplo, si IN1 está en HIGH (5V) e IN2 en LOW (0V), el motor A gira en cierto sentido, por el contrario, si IN1 está en LOW e IN2 en HIGH el motor girara en sentido contrario. Esto descrito, aplica también para los pines que controlan el sentido de giro del motor B. Para controlar la velocidad de giro de los motores se deben retirar los

jumpers que se encuentran en los pines ENA y ENB y conectar dichas terminales a las salidas PWM de Arduino pero si se tiene los jumpers colocados, los motores girarán a una misma velocidad.

Es de suma importancia mencionar que para el trabajo presente solo se utilizó el efector 3 para asociarla a los tres distintos pensamientos: reposos (Evita movimiento), arriba (subida del brazo), abajo (movimiento abajo del brazo), los cuales fueron controlados a través del puente H y este a su vez controlado por una Arduino Mega, la cual se encarga de enviar las instrucciones giro hacia el puente H. En otras palabras, para la parte del Hardware se utiliza la computadora como maestro y el Arduino como esclavo (ver Figura 19). El Arduino se encarga de indicar la salida a través de los pines digitales al controlador de motores L298N y este accionara a su vez al motor que tiene la función de subir o bajar de acuerdo al procesamiento de la señal EEG (ver Figura 19).

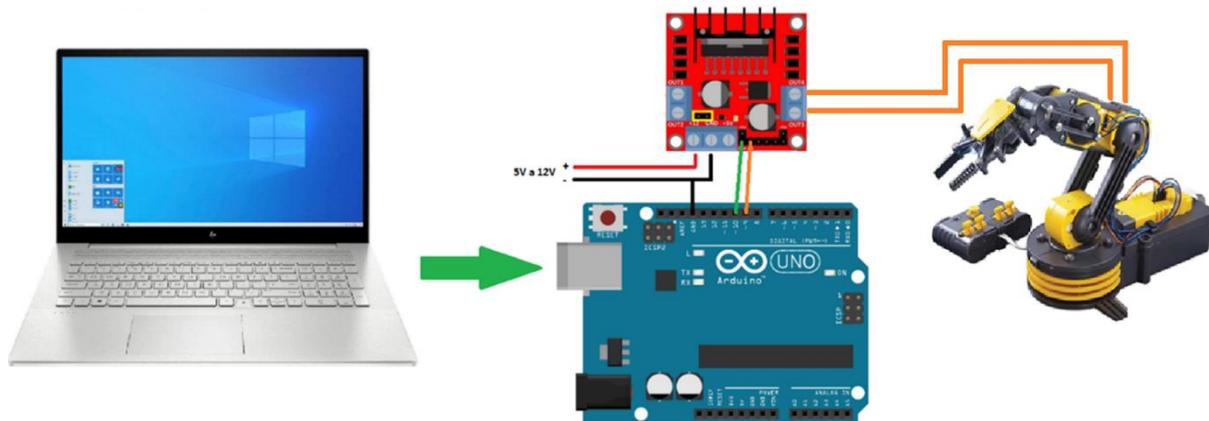


Figura 19. Diagrama de conexión Arduino y brazo.

Con el fin de controlar el brazo robótico, la interacción MATLAB-Arduino-Brazo se realiza a través de una comunicación serial descrita en MATLAB, la cual es descrita en la Figura 20. Esta comienza con la declaración de las variables que relacionaremos a los puertos que se controlaran del Arduino, después la señal obtenida llegara a una estructura case donde de acuerdo al valor entregado por la red neuronal realizara una operación. La operación del case 1 muestra la imagen del pensamiento obtenido, después procederá a comparar una variable que funciona como seguro evitando utilizar más del rango de movimiento permitido por el actuador. Sí cumple el haber sido un pensamiento diferente al previo, realizará la acción, en

este caso subirá, de lo contrario no hace nada y solo se muestra la imagen. Los dos casos extras cuentan con la misma configuración, siendo el movimiento del brazo el único cambio.

```
%% declaracion de variables
a=arduino();%Para usar arduino
%Puertos de arduino
P3 = 'D3';    %%Salida para motor A
P2 = 'D2';    %%Salida para motor A
rule = 1;    %%Condicion de inicio
xs = 1;    %%Tiempo de espera
while (stop~=1)

    %% -----Decision
    il=il+1;
    if (il==3)
        % c1=4000000
        switch Signal
        case 1
            cla (handles.grafica,'reset');
            [x4,map4]=imread('abre.png'); %%Arriba
            image(x4);
            colormap(map4);
            axis off
            hold on
            if (rule ~= 10)
                writeDigitalPin(a,P3,0);
                writeDigitalPin(a,P2,1);
                pause(0.3);
                writeDigitalPin(a,P3,1);

            else
                rule = rule;
            end
            rule =10;
        case 2
            cla (handles.grafica,'reset');
            [x5,map5]=imread('cierra.png'); %% abajo
            image(x5);
            colormap(map5);
            axis off
            hold on
            if (rule ~= 20)
                writeDigitalPin(a,P3,1);
                writeDigitalPin(a,P2,0);
                pause(0.3);
                writeDigitalPin(a,P2,1);
            else
                rule = rule;
            end
            rule =20;
        case 3
            cla (handles.grafica,'reset')
            [x6,map6]=imread('reposeo.png'); %% Reposo
            image(x6);
            colormap(map3);
            axis off
            hold on
            if (rule ~= 30)
                writeDigitalPin(a,P3,1);
                writeDigitalPin(a,P2,0);
                pause(0.1);
                writeDigitalPin(a,P3,0);
                writeDigitalPin(a,P2,1);
                pause(0.1);
                writeDigitalPin(a,P3,1);
            else
                rule = rule;
            end
        end
    end
end
```

```
        rule =rule;
    end
    pause(1);%El mns se va a mantener 1 segundo
    xs = xs+1;
end
tEnd=toc(tStart)
```

Figura 20. Script ejemplo de la conexión serial del Arduino programada desde Matlab mediante Arduino IO.

4 Resultados

En este capítulo se muestran los resultados obtenidos de acuerdo a la metodología propuesta, así como la discusión de estos.

4.1 Puesta de experimento

Con el fin de adquirir las señales EEG de los diversos participantes, esto siguen los siguientes pasos:

1. Los participantes no deben usar ningún producto capilar el día de la prueba (por ejemplo, gel, cera, fijador, etc.). por lo tanto, es importante que acudan con el cabello limpio con el fin de que los sensores capten de mejor manera las señales EEG.
2. Los participantes son colocados en un asiento cómodo, dentro de una habitación con buena iluminación con el fin de evitar la fatiga por la pantalla (ver Figura 21).
3. Se les indica a los pacientes que se deben relajar y procurar no realizar ningún movimiento mientras se registran las señales EEG.
4. Se coloca el sistema de adquisición EMOTIV EPOC+ a los participantes. Durante la colocación de los electrodos se adiciona una solución salina a los sensores con la finalidad de reducir la resistencia entre cuero cabelludo y electrodo, logrando reducir el ruido mecánico que se puede generar por la conexión electrodo-piel.
5. Una vez colocados los electrodos, el participante será expuesto a una presentación de quince segundos, la cual contiene los cinco segundos de cada pensamiento (abajo, reposo y arriba) para poder guardar los pensamientos que se relacionan a la imagen puesta.



Figura 21. Toma de señales EEG

Es muy importante mencionar que la puesta de experimento se aplicó a 10 participantes (5 hombres y 5 mujeres) con un rango de edad de 20 años. Adicionalmente, la prueba se repitió 30 veces por participantes, resultando en un total de 300 pruebas, resultando en 300 señales EEG correspondientes a arriba, 300 señales EEG correspondiente a abajo y 300 señales EEG correspondientes a reposo. Cada una de las pruebas se realizó con una frecuencia de muestreo de 256 (frecuencia de muestreo fijada por el fabricante del casco EMOTIV+), resultando en 1,875 muestras por prueba. Finalmente, es muy importante también mencionar que todas estas lecturas realizadas están aprobadas bajo el consentimiento de comité de ética con el registro CEAIFI-215-2021-TP.

4.2 Resultados: Identificación del método (procesamiento de la señal)

Siguiendo la metodología propuesta en este trabajo de tesis, las señales EEG para diferentes MI (reposo, arriba y abajo) se adquieren mediante EMOTIV banda EPOC+, la cual es colocada al usuario después de su protocolo de preparación. La Figura 22 muestra las señales obtenidas de cada sensor del uno al catorce para después seleccionar cada señal de manera individual y realizar su procesamiento. Con el objeto de ejemplificar, la Figura 23 ilustra un ejemplo de las señales de EEG medidas para los tres MI y el sensor AF3. De acuerdo con esta figura, no es posible observar cambios significativos que puedan estar asociados a los pensamientos realizados. Por lo tanto, es requerido de un método con la capacidad de estimar o encontrar características relevantes en estas señales EEG. En este sentido, las señales de EEG adquiridas para los tres MI, reposo, arriba y abajo se analizan por medio de WPT para descomponer las señales de EEG en diversas bandas de frecuencia (FB) con el fin de tratar de identificar características relevantes en las señales analizadas. Es importante mencionar que las señales de EEG se descomponen con la WPT desde el nivel 1 hasta el nivel 8, resultando que el nivel 5 de la WPT (en este nivel se estiman 32 FB con un rango de 4Hz debido a los 256Hz de frecuencia de muestreo) con una ondoleta o wavalet madre Daubechies 1 y 2 presentan los mejores resultados. Solo a modo de ejemplo, la Figura 24 muestra las FB estimadas con la WPT para el nivel 5 de los tres pensamientos. Es muy importante mencionar que esta figura, solo presenta las primeras y últimas 8 FBs para los tres pensamientos MI y sensor AF3. De acuerdo a esta figura es posible observar más características que la señal original; sin embargo, estas características u oscilaciones se presentan en los tres MI; por lo tanto, se requiere un

procesamiento adicional con la capacidad de identificar características adecuadas con el objetivo de diferenciar entre los tres MI.

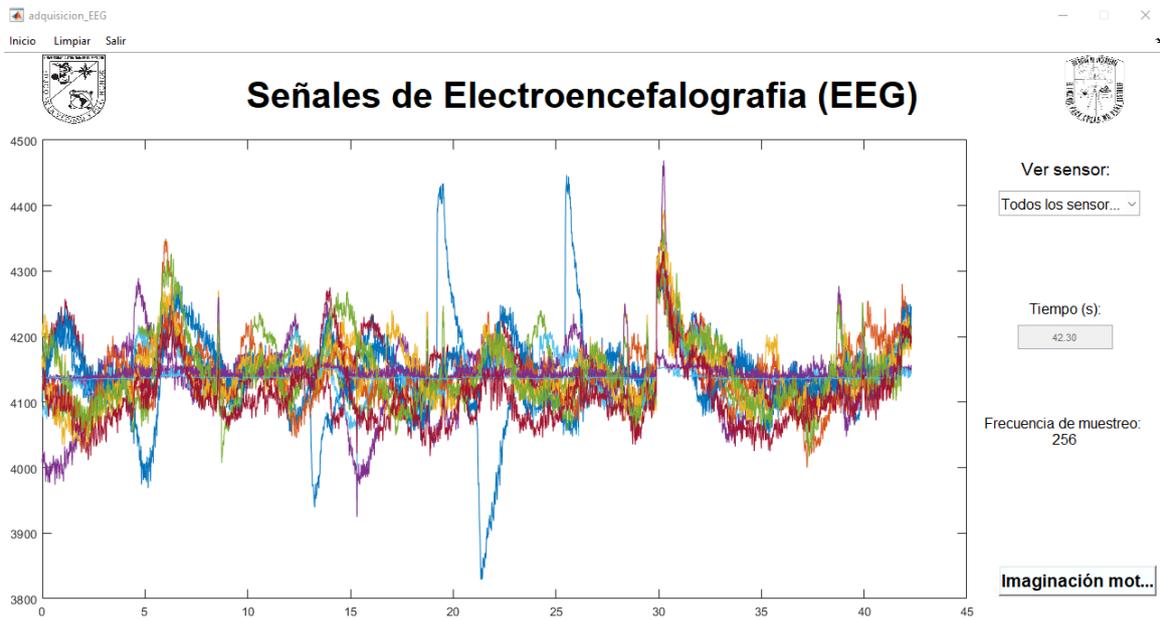


Figura 22. Señales EEG obtenidas empleando la interfaz de usuario.

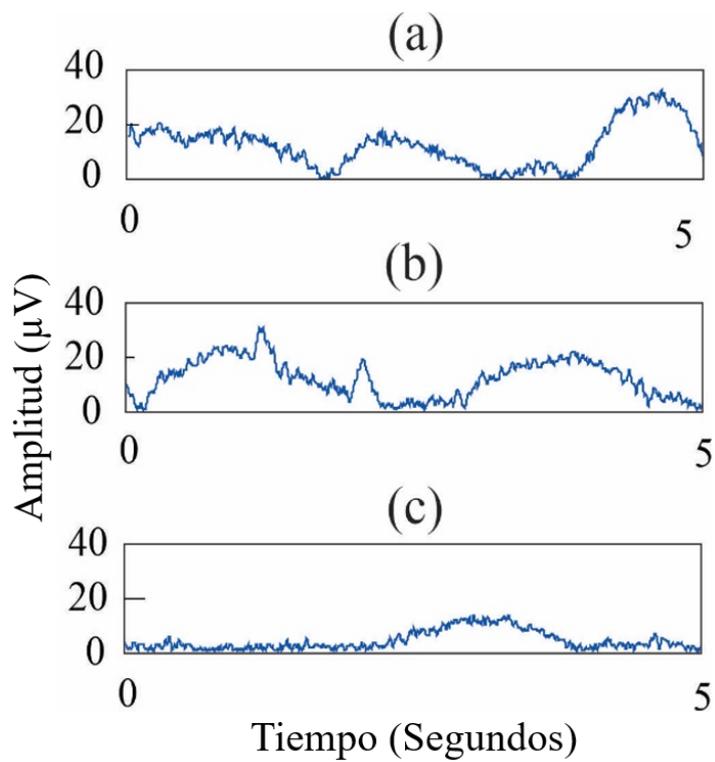


Figura 23. Señal EEG monitoreada para el pensamiento de (a) arriba, (b) reposo y (c) abajo.

Una vez descompuestas las señales EEG por medio de la WPT (de acuerdo al nivel seleccionado se obtienen 32 FBs como se observa en la Figura 24), las FBs son evaluados por los 17 indicadores estadísticos con el fin de descubrir patrones con la capacidad de distinguir entre los tres MI. Con el fin de determinar las bandas de frecuencia en conjunto con los indicadores estadísticos se emplea el método KWT. Después de realizar un análisis exhaustivo de la información, se encontró que 18 características, resumidas en la Tabla 4, son útiles para distinguir entre los tres MI, ya que presentan el valor p más bajo y la mayor separabilidad entre los tres MI. En particular, la Tabla 4 presenta el sensor, el no. de FB y el no. de indicador estadístico con la información más útil para diferencias entre los 3 pensamientos. La Figura 25 muestra la distribución de las características seleccionadas de acuerdo al método de KWT entre los diferentes movimientos imaginados. Finalmente, ya con las características seleccionadas, estas son empleadas para entrenar y validar un clasificador basado en inteligencia artificial conocido como perceptrón multicapa (MLP por sus siglas en inglés) con el fin de distinguir entre los 3 pensamientos de manera automática.

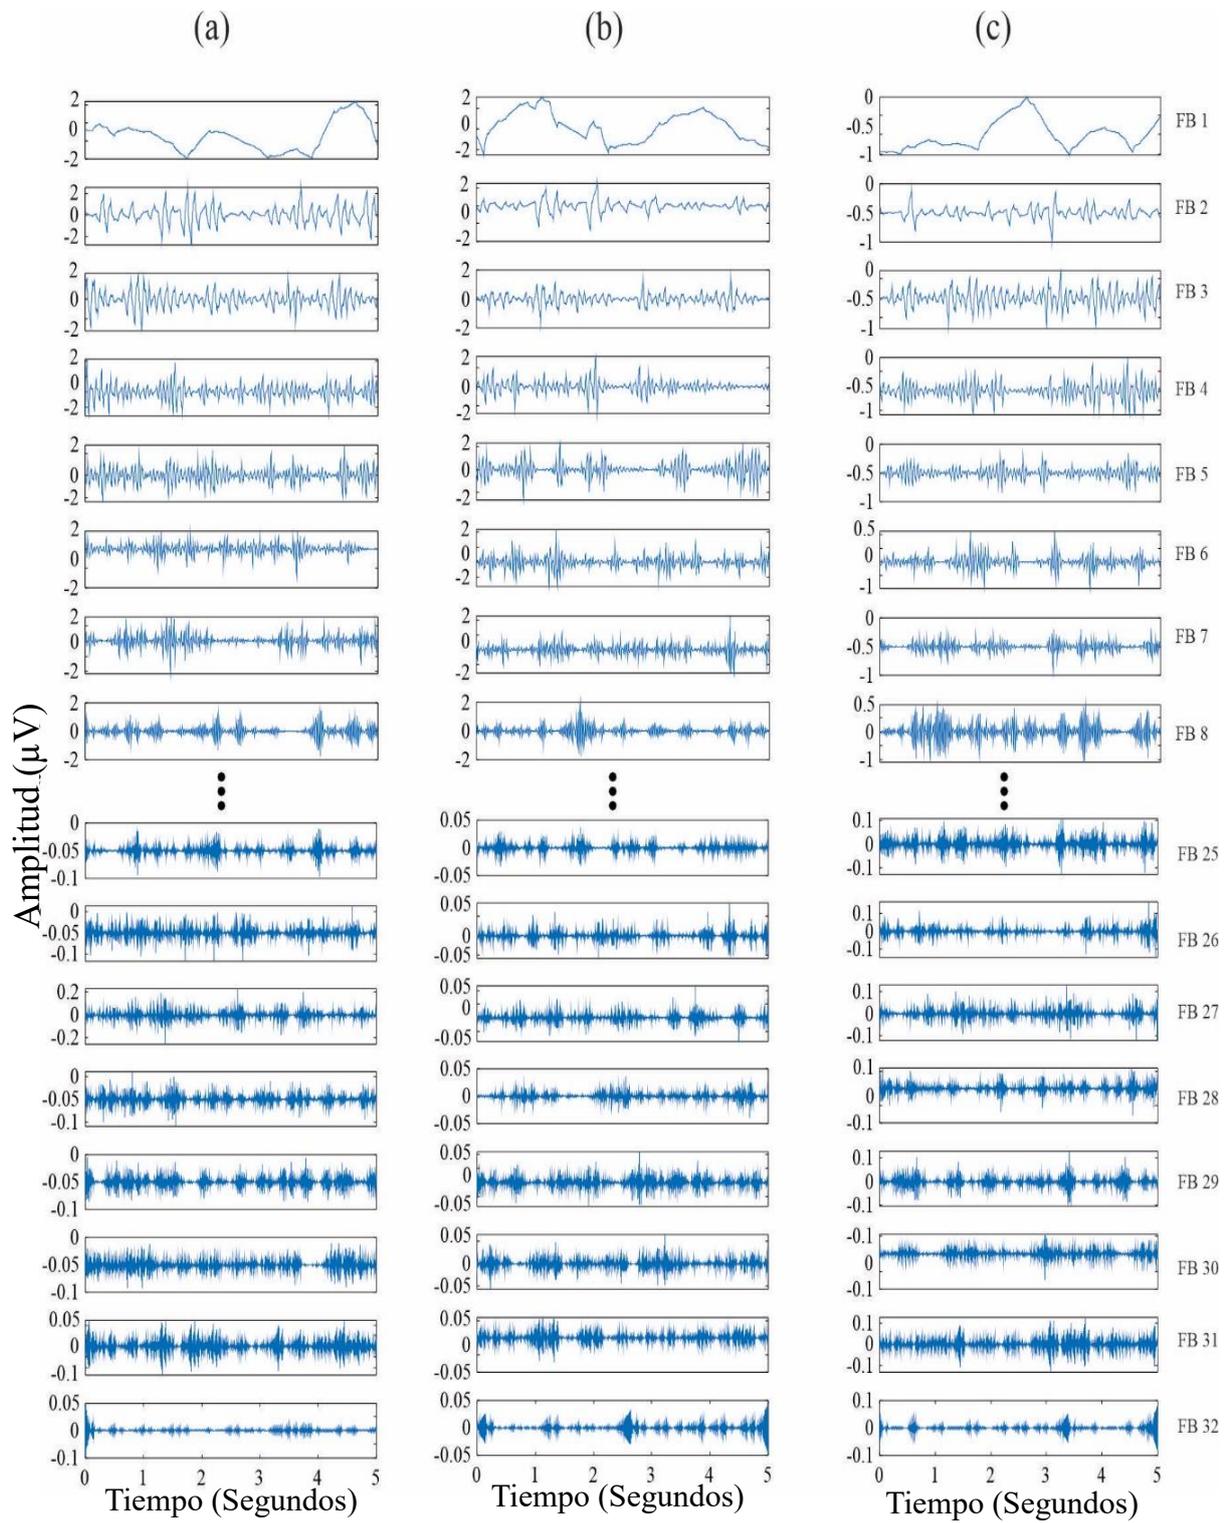


Figura 24. Bandas de frecuencia obtenidas al usar WPT donde (a) corresponde arriba, (b) reposo y (c) abajo.

Tabla 4. Características más relevantes seleccionadas por medio de KWT.

<i>Característica</i>	<i>Daubechies</i>	<i>Sensor</i>	<i>No. FB</i>	<i>No. IE</i>	<i>Valor P</i>
A	1	F3	10	4	7.7 e-6
B	1	F3	32	11	1.4 e-5
C	1	AF3	10	11	1.3 e-6
D	1	F7	1	16	1.4 e-5
E	1	F7	1	17	8.4 e-6
F	1	O1	24	10	1.1 e-7
G	1	F8	12	4	5.6 e-6
H	2	AF3	32	13	3.5 e-5
I	2	FC5	32	18	1.1 e-5
J	2	AF3	23	6	1.9 e-6
K	2	AF3	23	8	2.8 e-6
L	2	O1	8	11	6.4 e-8
M	2	O2	22	11	3.7 e-6
N	2	O2	23	4	2.4 e-5
O	2	F8	23	11	1.9 e-5
P	2	F8	32	18	6.7 e-9
Q	2	F4	32	4	2.2 e-6
R	2	F4	32	15	1.2 e-6

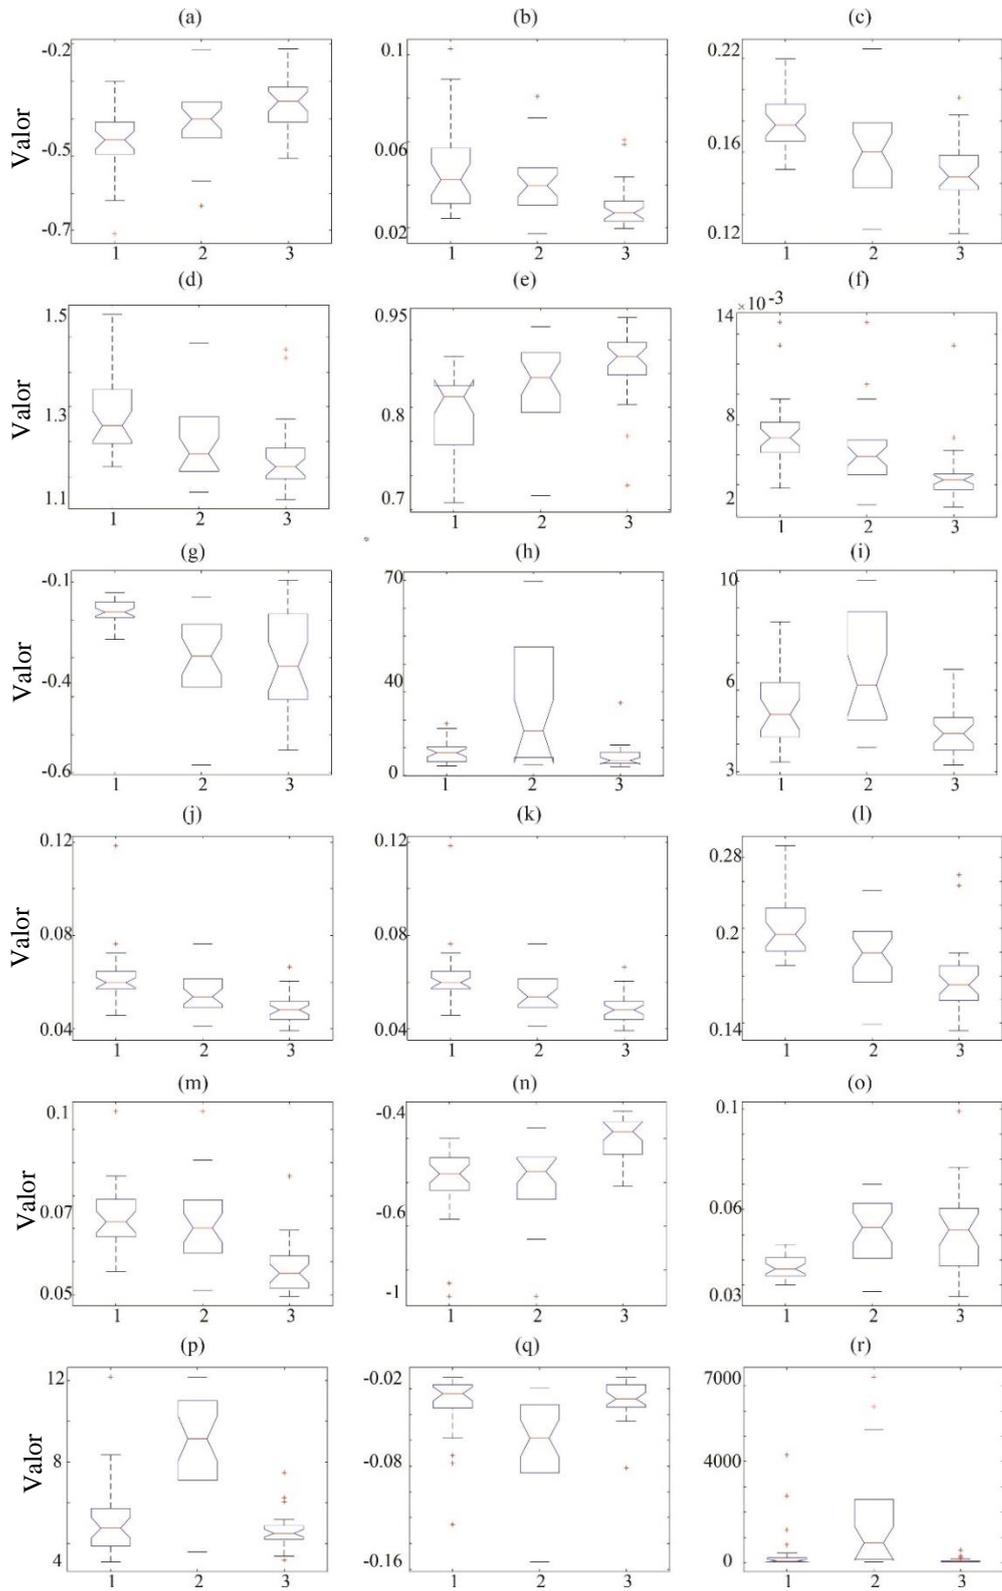


Figura 25. Distribución de los datos obtenidos con el método KWT de acuerdo a las características de la Tabla 4. Los valores horizontales corresponden con la distribución de datos de: 1 arriba, 2 reposo y 3 abajo,

Es importante mencionar que durante el entrenamiento de la red neuronal se utiliza el 70% (210 pruebas) de los datos, mientras que el restante, 30% (90 pruebas), se emplea para validación. Un análisis exhaustivo a prueba y error es llevado a cabo para definir la configuración de MLP que permita obtener resultados adecuados. En este sentido, se obtuvo que una MLP con dos capas ocultas de 36 y 16 neuronas, respectivamente, con una función logsig es la que permite diferenciar de mejor manera entre los 3 pensamientos de acuerdo a las características de entrenamiento. Adicionalmente, la MLP presenta 18 entradas (correspondientes al número de funciones seleccionadas) y 3 salidas (correspondientes al número de movimientos imaginados) (ver Figura 26).

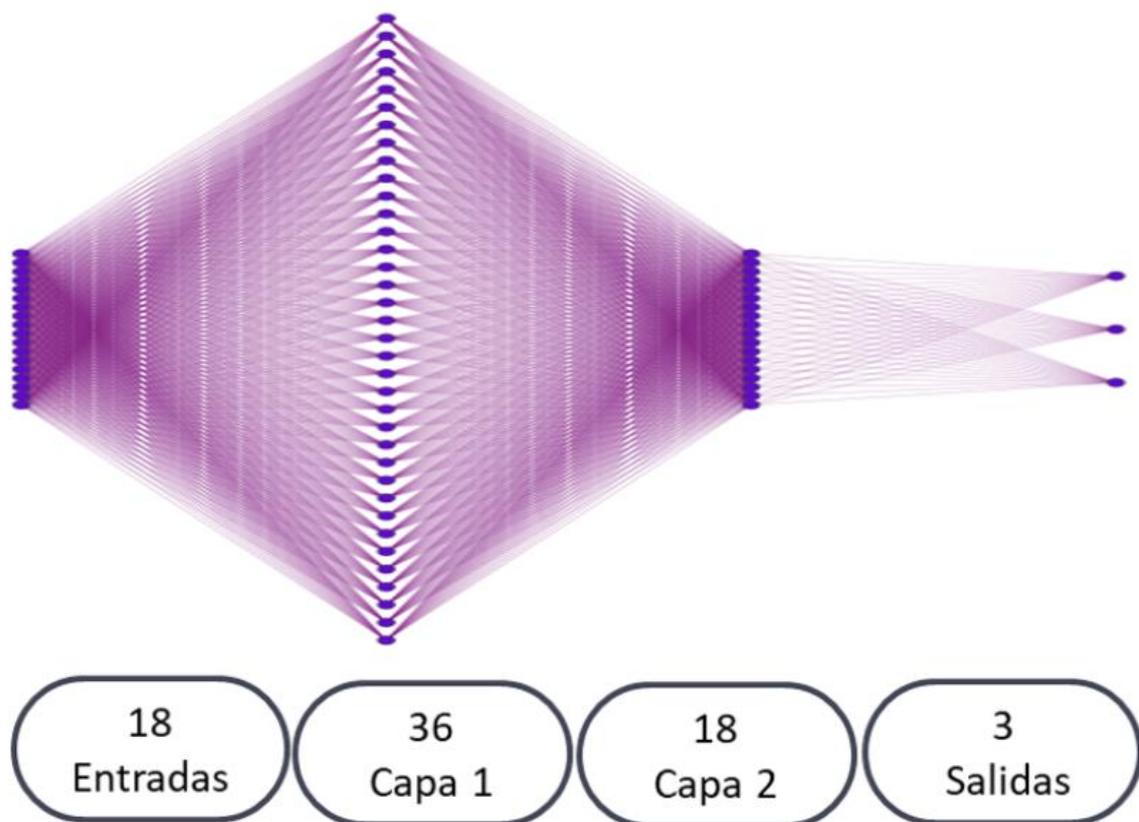


Figura 26. Red neuronal para validación de datos.

De acuerdo a la Tabla 5, matiz de confusión, y la Ecuación (25) se identifica que la estrategia de lenguaje de maquina propuesto presenta una exactitud del 80%, etapa de validación (30% de las pruebas analizadas), para distinguir entre tres movimientos imaginados. De acuerdo los resultados obtenidos, la metodología propuesta otorga una mayor exactitud,

80%, que otras metodologías propuestas presentadas en la literatura, donde obtienen una exactitud máxima de 74.5% para clasificar tres movimientos imaginados (Cruz Ramírez, 2018, Cantillo Negrete et al., 2014, Hernández González, 2017) Adicionalmente, es importante mencionar que la metodología propuesta utiliza algoritmos de baja complejidad computacional en comparación con otras metodologías, lo que permite una futura implementación en sistema hardware de bajo costo. En este sentido, el uso de WPT se puede cambiar por un filtro digital; por ejemplo, un filtro FIR, en vez de dividir la señal en diferentes bandas y los indicadores estadísticos son operadores simples.

Tabla 5. Matriz de confusión obtenida para la validación del clasificador.

	Descanso	Arriba	Abajo
Descanso	69	21	0
Arriba	6	72	12
Abajo	15	0	75

Adicionalmente, para cada estado, se calculan sus diferentes parámetros de acuerdo a las siguientes ecuaciones:

$$Exactitud = \left(\frac{TP+TN}{TP+TN'+FP+FN} \right) \cdot 100\% \quad (21)$$

donde TP es el verdadero positivo, resultado en el que el modelo predice correctamente la clase positiva. FN: Falso negativo, también llamado error de tipo 2, un resultado en el que el modelo predice incorrectamente la clase negativa cuando en realidad es positiva. TN: Verdadero Negativo, resultado donde el modelo predice correctamente la clase negativa. FP: Falso positivo, también llamado error de tipo 1, resultado donde el modelo predice incorrectamente la clase positiva cuando en realidad es negativa. En resumen, la exactitud indica la proporción de predicciones que el modelo clasificó correctamente.

Otro indicador estimado de la matriz de confusión es la precisión, la cual también se conoce como valor predictivo positivo y este indica la proporción de instancias relevantes entre las instancias recuperadas.

$$Precisión = \left(\frac{TP}{TP+FP} \right) \cdot 100\% \quad (22)$$

Adicionalmente, dos indicadores de clasificación conocidos como especificidad y sensibilidad son estimados de la siguiente manera:

$$\text{Sensibilidad} = \left(\frac{TP}{TP+FN} \right) \cdot 100\% \quad (23)$$

La sensibilidad, tasa de aciertos o tasa positiva real (TPR), es la proporción de la cantidad total de instancias pertinentes que se recuperaron realmente.

$$\text{Especificidad} = \left(\frac{TN}{TN+FP} \right) \cdot 100\% \quad (24)$$

La especificidad, también conocida como tasa negativa real (TNR), mide la proporción de negativos reales que se identifican correctamente como tales. Es lo opuesto a la sensibilidad. La Tabla 6 presenta los valores verdaderos y falsos para los tres pensamientos estimados de acuerdo a la matriz de confusión mostrada en la Tabla 5.

Tabla 6 Matriz de observación

Matriz de Observación				
Pensamientos	Medidas			
	TP	TN	FP	FN
Reposo	69	159	21	21
Arriba	72	159	21	18
Abajo	75	168	12	15

Una vez realizada la matriz de observación, se calculados los valores de las ecuaciones 21 a 24 para cada caso de pensamiento imaginario como se puede observar en la Tabla 7.

Tabla 7. Resultados de matriz de confusión.

Resultados de matriz de confusión				
	Reposo	Arriba	Abajo	Promedio
Exactitud	84.4%	85.6%	90.0%	86.6%
Precisión	76.7%	77.4%	86.2%	80.1%
Sensibilidad	76.7%	80.0%	83.3%	80%
Especificad	88.3%	88.3%	93.3%	89.8%

Finalmente, se obtiene una exactitud general de la metodología propuesta de acuerdo con la siguiente ecuación:

$$Exactitud\ general = \left(\frac{\Sigma TP}{Numero\ de\ muestras} \right) \cdot 100\% \quad (25)$$

Por lo tanto, se tiene una exactitud del 80% para la metodología propuesta, lo que indica que esta presenta una buena identificación de manera correcta de los pensamientos realizados.

$$Exactitud\ general = \left(\frac{69 + 72 + 75}{270} \right) \cdot 100\% = 80\%$$

4.3 Resultados: Validación (método-actuador)

Una vez que identificado el método (procesamiento de la señal) es identificado y validado, se procede a la etapa final que se llama validación, donde la metodología descrita en la sección anterior es conjuntada con un actuador con el fin de observar su viabilidad en conjunto. En este sentido, las pruebas de validación con el actuador fueron realizadas en el mismo entorno tranquilo y sin distracciones con los siguientes materiales: brazo robótico, sistema Arduino y control de motores, computadora y casco EMOTIV EPOC+ como se muestra en la Figura 27.



Figura 27. Materiales para validación de actuador.

Con la finalidad de validar la metodología propuesta y los resultados obtenidos en el presente trabajo se analizan los pensamientos imaginados con la interfaz descrita en la sección de imaginación motora. Esta prueba se realizó solamente en el Tesista (ver Figura 28) debido a los problemas de COVID que todavía se viven en la actualidad, donde 30 pensamientos son

analizados (10 arriba, 10 abajo y 10 de reposo), donde los resultados obtenidos, clasificación de los pensamientos, son resumidos en la Tabla 8. Durante el experimento se recrearon las mismas circunstancias o misma puesta de experimento como se describió en la sección 4.1, con el objeto de asemejar las señales analizadas en la sección 4.2.



Figura 28. Prueba de sistema de validación (método-actuador).

Para cada estado de la Tabla 8, la tasa de exactitud de clasificación se calcula de acuerdo con la Ecuación (22)

Tabla 8. Clasificación de los pensamientos en la etapa de validación (método-actuador)

	Descanso	Arriba	Abajo	Exactitud
Descanso	8	2	0	80%
Arriba	2	8	0	80%
Abajo	0	1	9	90%
			Exactitud General	83.3%

4.4 Discusión de los resultados

Para esta parte analizaremos la tabla número 9 que presenta los resultados de la metodología propuesta y las diferentes metodologías que se emplean en los distintos trabajos que utilizaron señales EEG. En esta se muestra una breve descripción de la metodología empleada, el tiempo de predicción logrado, la precisión y movimientos analizados. Donde se aprecia que la propuesta realizada obtiene una exactitud del 80% en diferencia de los trabajos anteriores.

Tabla 9 Comparación de la metodología propuesta contra los trabajos anteriores.

Autor	Movimientos registrados	Técnica	Exactitud
D’Croz-Baron et al., 2012	Pensamiento de mano izquierda y derecha (2)	Extracción de parámetros Criterio de fisher	80%
Meisheri et al., 2018	Movimiento de mano izquierda, mano derecha, pies y lengua (4)	Patrón espacial común multiclase y Takagi-Sugeno-Kang	74.65%
Khan et al., 2019	Pensamiento izquierda, derecha y reposo.(3)	Patrón espacial común y Análisis discriminatorio lineal	60.61
Montes Martínez, 2019	Pensamiento izquierda, derecha y reposo.(3)	Transformada wavelet y fractales	74.51
Cantillo Negrete et al., 2020	Pensamiento izquierda, derecha y reposo.(3)	Transformada de Fourier	73%
Trabajo presentado	Pensamiento arriba, abajo y reposo.(3)	Transformada Wavelet por paquetes e indicadores estadísticos.	80%

A partir de esta tabla se puede observar que la mayoría de trabajos previos reportados de la literatura requieren distintas características de alta carga computacional para medir los cambios entre un pensamiento a otro, por lo cual impide una asignación continua, limitando el funcionamiento en tiempo real, lo cual es importante para las aplicaciones en respuesta rápida y poder ejecutar la acción imaginada dando una ejecución requerida. La propuesta cuenta con ciertas ventajas en perspectiva de sus predecesores como: Se cuenta con una interfaz de entrenamiento, ejecución y toma de datos, (2) utiliza procesamientos de baja carga computacional como un filtro e indicadores estadísticos, (3) no se utilizan procesamientos

previos para tratar la señal. Debido a esto se reduce los requerimientos para la clasificación idónea de los pensamientos, sin embargo, es importante el realizar mejoras siendo estas: (1) crear una base de datos más amplia en cuanto a usuarios y a tomas realizadas (2) Reducir el tiempo de respuesta con un procesamiento paralelo, (3) Generar un umbral de detección de pensamiento para quitar el tiempo de toma de la muestra.

En resumen, la metodología utilizada puede considerarse como un método adecuado para clasificar los diferentes pensamientos motores seleccionados.

5 Conclusiones y perspectivas

5.1 Conclusiones

La imaginación motora es una amplia área de estudio para la ciencia biomédica, que se basa principalmente en el monitoreo de las señales de EEG para diferenciar diversos movimientos imaginados. Este trabajo presenta un nuevo método basado en la integración hábil de tres técnicas de procesamiento de señales, WPT, indicadores estadísticos y RNA, para clasificar tres movimientos imaginados (reposo, arriba y abajo) de manera automática. Los resultados obtenidos muestran que la propuesta es capaz de diferenciar entre tres movimientos imaginados con una precisión del 80%, superando los trabajos reportados en la literatura en un 5% (Cruz Ramírez, 2018, Cantillo Negrete et al., 2014, Hernández González, 2017). Además es de suma importancia mencionar que la interfaz desarrollada admite el monitoreo y procesamiento de la imaginación motora, permitiendo el control de un brazo robótico en línea donde este es controlado con una exactitud del 83%. Por lo tanto, la integración de diversos métodos propuestos en este trabajo puede ser considerada como una alternativa para evaluar el IM. Además, se puede considerar como una alternativa de baja complejidad computacional, que permitirá una futura implementación en un sistema hardware de costo bajo.

Los resultados obtenidos pueden considerarse preliminares porque es relevante probar la propuesta con una gran base de datos, así como probar otras técnicas de pre procesamiento para evaluar la posibilidad de aumentar la precisión.

5.2 Prospectivas

Durante el trabajo de tesis realizado se observaron áreas importantes de mejora para incrementar el nivel de clasificación, así como el tiempo de respuesta en el sistema, por lo cual, debido a los resultados obtenidos y las conclusiones realizadas, se plantean las siguientes prospectivas para futuros trabajos y avance del tema.

Para el primer punto es colocar un apartado en la interfaz donde el usuario pueda colocar el movimiento que desea aprender, para así practicar de poco en poco y pueda ser de mejor precisión para la interfaz y menos tedioso para el usuario aprender el movimiento evitando saturarlo de información. Esto a su vez representa dos mejoras, ya que por un lado se genera

un mejor seguimiento del usuario que utilizo el dispositivo y otro es una base de datos más amplia para el sistema

Para el segundo punto de mejora se requiere emplear un umbral de detección del movimiento pensado, ya que el sistema actual reconoce un lapso de tiempo y lo clasifica de acuerdo a lo ya entrenado. Con este umbral se podrá disminuir la ventana de cinco segundos para clasificar el pensamiento.

Por último, la propuesta se podría implementar en un procesamiento en paralelo en lugar del actual que es secuencial, de esta forma podemos aprovechar el umbral y clasificar con un menor tiempo de procesamiento evitando esperar la toma del pensamiento y después procesarla, ya que generaría un proceso en conjunto.

Referencias

- Abbasi, H., Bennet, L., Gunn, A. J., & Unsworth, C. P. (2017). Robust Wavelet Stabilized 'Footprints of Uncertainty' for Fuzzy System Classifiers to Automatically Detect Sharp Waves in the EEG after Hypoxia Ischemia. *International Journal of Neural Systems*, 27(03), 1650051. <https://doi.org/10.1142/S0129065716500519>
- Altenmüller, E., & E. James, C. (2020). The impact of music interventions on motor rehabilitation following stroke in elderly. *Music and the Aging Brain*, 407–432. <https://doi.org/10.1016/B978-0-12-817422-7.00016-X>
- Alvarez, M. A. (2003). *Lenguaje de programación de propósito general, orientado a objetos, que también puede utilizarse para el desarrollo web*. <https://desarrolloweb.com/articulos/1325.php>.
- Aviles, M. R. (2020). *Metodología basada en la transformada wavelet e indicadores estadísticos para la clasificación de señales electromiográficas aplicadas a un brazo robótico*. Universidad Autónoma de Querétaro.
- Bala, R., & Kumar, D. (2017). Classification Using ANN: A Review. In *International Journal of Computational Intelligence Research* (Vol. 13, Issue 7). <http://www.ripublication.com>
- Barcenas. (2020). *Diagnóstico automático del deterioro cognitivo leve empleando magnetoencefalogramas*. Universidad Autónoma de Querétaro.
- Bashar, S. ., & Bhuiyan, M. I. . (2016). *Classification of motor imagery movements using multivariate empirical mode decomposition and short time Fourier transform based hybrid method*.
- Batres-Mendoza, P., Montoro-Sanjose, C., Guerra-Hernandez, E., Almanza-Ojeda, D., Rostro-Gonzalez, H., Romero-Troncoso, R., & Ibarra-Manzano, M. (2016). Quaternion-Based Signal Analysis for Motor Imagery Classification from Electroencephalographic Signals. *Sensors*, 16(3), 336. <https://doi.org/10.3390/s16030336>
- Bermúdez G., García P. J., Brizion D., & R. J. (2013). *Adquisición procesamiento y clasificación de señales EEG para el diseño de sistemas BCI basados en imaginación de movimiento*.
- Bradley, A. P. (1997). The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern Recognition*, 30(7), 1145–1159. [https://doi.org/10.1016/S0031-3203\(96\)00142-2](https://doi.org/10.1016/S0031-3203(96)00142-2)
- Cantillo Negrete, J., Gutiérrez Martínez, J., Flores Rodríguez, T. B., Cariño Escobar, R. I., & Elías Viñas, D. (2014). Caracterización de la actividad eléctrica cerebral relacionada con

- la imaginación del movimiento de la mano en sujetos sanos. *Revista de Investigación Clínica*, 66, 111–121.
- Casallas, E. C., David, J., & Toro, R. (2015). *SISTEMA DE ENTRENAMIENTO VIRTUAL PARA PRÓTESIS MIOELÉCTRICA TRANSRADIAL A PARTIR DEL TRATAMIENTO DE SEÑALES BIOELÉTRICAS* (Vol. 11).
- Chu, N. N. Y. (2015). Brain-Computer Interface Technology and Development: The emergence of imprecise brainwave headsets in the commercial world. *IEEE Consumer Electronics Magazine*, 4(3), 34–41. <https://doi.org/10.1109/MCE.2015.2421551>
- Corona Ramirez, L. (2014). *Sensores y actuadores, aplicaciones con Arduino*.
- Cruz Ramírez, H. (2018). *Metodología basada en la descomposición empírica de modos completa y fractales para la clasificación de la imaginación motora usando señales electroencefalográficas*. Universidad Autónoma de Querétaro.
- D’Croz-Baron, D., Ramirez, J. M., Baker, M., Alarcon-Aquino, V., & Carrera, O. (2012). A BCI motor imagery experiment based on parametric feature extraction and Fisher Criterion. *CONIELECOMP 2012, 22nd International Conference on Electrical Communications and Computers*, 257–261. <https://doi.org/10.1109/CONIELECOMP.2012.6189920>
- De la Torre Abauita, J. (2012). *No Title Procesado de señales EEG para un interfaz cerebro maquina*. Carlos III de Madrid.
- Guevara, M., A, S.-M., & M, C.-C. (2010). programa para revisar señales EEG fuera de línea. *CHECAsEN*.
- Hassan, A. R., & Hassan Bhuiyan, M. I. (2016). Automatic sleep scoring using statistical features in the EMD domain and ensemble methods. *Biocybernetics and Biomedical Engineering*, 36(1), 248–255. <https://doi.org/10.1016/j.bbe.2015.11.001>
- Hernández González, C. E. (2017). *Clasificación de señales EEG bajo paradigma de imaginación motora usando descomposicion wavelet y maquinas de soporte vectorial*. Instituto Nacional de Astrofísica, óptica y Electrónica.
- Jeannerod, M., & Frak, V. (1999). Mental imaging of motor activity in humans. *Current Opinion in Neurobiology*, 9(6), 735–739. [https://doi.org/10.1016/S0959-4388\(99\)00038-0](https://doi.org/10.1016/S0959-4388(99)00038-0)
- Kevric, J., & Subasi, A. (2017). Comparison of signal decomposition methods in classification of EEG signals for motor-imagery BCI system. *Biomedical Signal Processing and Control*, 31, 398–406. <https://doi.org/10.1016/J.BSPC.2016.09.007>

- Khan, J., Bhatti, M. H., Khan, U. G., & Iqbal, R. (2019). *Multiclass EEG motor-imagery classification with sub-band common spatial patterns*.
- Kokontis, L., & Gutmann, L. (2016). *Current Treatment of Neuromuscular Diseases*. 57(July 2000).
- Larger, E. C. E. Al. (2018). *Development Of Prosthesis For Replacement OF Upper Lim Prehensile Function In Amputee User*. 8.
- Lin, S., Liu, J., Li, W., Wang, D., Huang, Y., Jia, C., Li, Z., Murtaza, M., Wang, H., Song, J., Liu, Z., Huang, K., Zu, D., Lei, M., Hong, B., & Wu, H. (2019). A Flexible, Robust, and Gel-Free Electroencephalogram Electrode for Noninvasive Brain-Computer Interfaces. *Nano Letters*, 19(10), 6853–6861. <https://doi.org/10.1021/acs.nanolett.9b02019>
- Luna-Angulo, A., R, S.-S., & H, C.-C. (2016). *Diagnóstico molecular de enfermedades neuromusculares en el Instituto Nacional de Rehabilitación*.
- Medical, S. (2020). *Enfermedades neuromusculares*. <https://www.sunrisemedical.es/blog/enfermedades-neuromusculares>
- Moghaddasi, M. R., & Noorian-Bidgoli, M. (2018). ICA-ANN, ANN and multiple regression models for prediction of surface settlement caused by tunneling. *Tunnelling and Underground Space Technology*, 79, 197–209. <https://doi.org/10.1016/J.TUST.2018.04.016>
- Monteiro, K. B., Cardoso, M. dos S., Cabral, V. R. da C., Santos, A. O. B. dos, Silva, P. S. da, Castro, J. B. P. de, & Vale, R. G. de S. (2021). Effects of Motor Imagery as a Complementary Resource on the Rehabilitation of Stroke Patients: A Meta-Analysis of Randomized Trials. *Journal of Stroke and Cerebrovascular Diseases*, 30(8), 105876. <https://doi.org/10.1016/J.JSTROKECEREBROVASDIS.2021.105876>
- Montes Martínez, K. D. (2019). *Metodología basada en la transformada wavelet y fractales para la clasificación de la imaginación motora*. Universidad Autonoma de Querétaro.
- Morales, G., Egozcue, S., & Alonso, M. T. (2009). *Técnicas básicas de electroencefalografía : principios y aplicaciones clínicas Basic techniques of electroencephalography : principles and clinical applications*. 32, 69–82.
- Neuper, C., Scherer, R., Reiner, M., & Pfurtscheller, G. (2005). Imagery of motor actions: Differential effects of kinesthetic and visual–motor mode of imagery in single-trial EEG. *Cognitive Brain Research*, 25(3), 668–677. <https://doi.org/10.1016/J.COGBRAINRES.2005.08.014>
- Perez-Sanchez, A. V., Perez-Ramirez, C. A., Valtierra-Rodriguez, M., Dominguez-Gonzalez,

- A., & Amezquita-Sanchez, J. P. (2020). Wavelet Transform-Statistical Time Features-Based Methodology for Epileptic Seizure Prediction Using Electrocardiogram Signals. *Mathematics*, 8(12), 2125. <https://doi.org/10.3390/math8122125>
- Pérez-Vidal, A., Garcia-Beltran, C., Martínez-Sibaja, A., & Posada-Gómez, R. (2018). Use of the Stockwell Transform in the Detection of P300 Evoked Potentials with Low-Cost Brain Sensors. *Sensors*, 18(5), 1483. <https://doi.org/10.3390/s18051483>
- 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. <https://doi.org/10.1016/j.eswa.2010.11.050>
- Royal, R., Khanna, D., Sandhu, J. K., Hooda, N., & Rana, P. S. (2019). N-semble: neural network based ensemble approach. *International Journal of Machine Learning and Cybernetics*, 10(2), 337–345. <https://doi.org/10.1007/s13042-017-0718-0>
- Renfrew, M. (2009). *A Comparison of Signal Processing and Classification Methods for Brain-Computer Interface*. August, 89.
- Rodriguez, M., Llanos, C., & Sabate, M. (2009). The kinematics of motor imagery: Comparing the dynamics of real and virtual movements. *Neuropsychologia*, 47(2), 489–496. <https://doi.org/10.1016/J.NEUROPSYCHOLOGIA.2008.10.009>
- Ruiz, C. (2019). *Metodología basada en la transformada wavelet y los parámetros de Hjorth para la clasificación de imaginación motora usando señales electroencefalográficas*. Universidad Autónoma de Querétaro.
- Shih, J. J., Krusienski, D. J., & Wolpaw, J. R. (2012). Brain-Computer Interfaces in Medicine. *JMCP*, 87(3), 268–279. <https://doi.org/10.1016/j.mayocp.2011.12.008>
- Solorzano, G. V. P. (2016). *INFLUENCIA DE LA ACTIVIDAD LÚDICA EN EL DESARROLLO DE LA HABILIDAD MOTORA GRUESA EN LOS NIÑOS DE 2 A 3*. UNIVERSIDAD DE GUAYAQUIL.
- Terrasa Navarro, J. L. (2020). *Efectos del envejecimiento y la neuromodulación sobre la corteza somatomotora*. <http://dspace.uib.es/xmlui/handle/11201/154595>
- Übeyli, E. D. (2009). Combined neural network model employing wavelet coefficients for EEG signals classification. *Digital Signal Processing*, 19(2), 297–308. <https://doi.org/10.1016/J.DSP.2008.07.004>
- Vargas Lopez, O. (2022). *Detección de estrés en conductores automovilísticos a través de medidas estadísticas y señales electromiográficas*. Universidad Autónoma de Querétaro.
- Vargas Parra Raymundo. (2020). *Metodología Basada en los Parámetros de Hjorths Para la*

Detección del Deterioro Cognitivo Leve. Universidad Autónoma de Querétaro.

Wang, S.-C. (2003). Artificial Neural Network. In *Interdisciplinary Computing in Java Programming* (pp. 81–100). Springer US. https://doi.org/10.1007/978-1-4615-0377-4_5

Zhou, S. M., Gan, J. Q., & Sepulveda, F. (2008). Classifying mental tasks based on features of higher-order statistics from EEG signals in brain–computer interface. *Information Sciences*, 178(6), 1629–1640. <https://doi.org/10.1016/J.INS.2007.11.012>

A.1 Carta de consentimiento informado

CONSENTIMIENTO INFORMADO

Lugar y fecha: _____

Por medio del presente acepto participar en el protocolo de investigación titulado: "**Clasificación automática de la imaginación motora empleando indicadores estadísticos y señales electroencefalográficas**", cuyo objetivo es: determinar y encontrar indicadores propios para la clasificación de los diferentes estímulos mediante el estudio de señales electroencefalográficas. Se me ha explicado que mi participación consistirá en: la medición de señales electroencefalográficas, mediante electrodos no invasivos. Posteriormente se llevará a cabo el muestreo de la señal por medio de un casco EGG en un cuarto de baja iluminación durante 3 minutos aproximadamente. Entiendo que se conserva el derecho de retirarse del estudio en cualquier momento que lo considere conveniente. También se han comprometido a proporcionarme la información actualizada que se obtenga durante el estudio, aunque esta pudiera cambiar de parecer respecto a la permanencia en el mismo. El número telefónico al cual puedo comunicarme en caso de emergencia, dudas o preguntas relacionadas con el estudio es _____.

El Investigador Responsable se ha comprometido a darme información oportuna sobre cualquier procedimiento alternativo, así como a responder cualquier pregunta y aclarar cualquier duda que le plantee.

Nombre y firma del participante.

A.2 Carta de confidencialidad

CARTA CONFIDENCIALIDAD

Lugar y fecha: _____

Por medio de la presente yo, **Emmanuel Zárate de Vicente**, en calidad de investigador del proyecto titulado "**Clasificación automática de la imaginación motora empleando indicadores estadísticos y señales electroencefalográficas**" entiendo que toda aquella información brindada por el paciente es de carácter confidencial y queda prohibido cualquier tipo de revelación o divulgamiento por cualquiera de las partes por medios escritos, orales o de cualquier otra forma.

Me comprometo a restringir el acceso a la información confidencial solo a aquellas personas vinculadas al proyecto de investigación en calidad de investigadores o auxiliares de investigación que tengan necesidad de conocerla para el desarrollo de este y por tanto mantener la más estricta confidencialidad y no revelar a otras personas físicas o morales cualquier información confidencial con otros fines distintos a los del proyecto.

De la misma manera confirmo que los datos personales y cualquier identificación del paciente serán manejados de forma confidencial en las presentaciones o publicaciones que deriven de este estudio.

Ing. Emmanuel Zarate de Vicente
Investigador responsable del proyecto



CONiIN

XVIII INTERNATIONAL ENGINEERING CONGRESS

THE QUERÉTARO STATE UNIVERSITY THROUGH THE ENGINEERING FACULTY GRANT THE PRESENT ACKNOWLEDGMENT TO:

Emmanuel Zárate-de Vicente, Martín Valtierra-Rodríguez and Juan P. Amezcua-Sánchez.

CONFERENCE:

A Wavelet transform, Statistical Indices and Neural Networks-based Methodology for Motor Imagery Classification employing Electroencephalographic Signals

QUERÉTARO, MEX.
MAY 2022

Dr. Manuel Toledano Ayala
PRINCIPAL
ENGINEERING FACULTY

Dr. Gonzalo Macías Bobadilla
GENERAL COORDINATOR CONIIN
ENGINEERING FACULTY

Figura 29. Reconocimiento Congreso CONIIN.

A Wavelet transform, Statistical Indices and Neural Networks-based Methodology for Motor Imagery Classification employing Electroencephalographic Signals

Emmanuel Zárate-de Vicente, Martín Valtierra-Rodríguez, and Juan P. Amezquita-Sánchez*

ENAP-RG, CA Sistemas dinámicos y Control, Facultad de Ingeniería, Posgrado Mecatrónica, Universidad Autónoma de Querétaro, Campus San Juan del Río, San Juan del Río, Querétaro, México

*Corresponding author: jamezquita@uaq.mx

Abstract: Motor imagery (MI) is responsible for body movements, which has immense potential for its applicability in medical purposes, industrial applications, gaming, among others. It is based mainly on monitoring of electroencephalographic (EEG) signals, which are noisy signals with nonstationary properties. Hence, identifying suitable features associated with MI using EEG signals is a challenge due to their properties. In this sense, the article has introduced a new method based on the integration of wavelet packet transform, statistical indices, and an artificial neural network for classifying to automatically three fancied movements (e.g., rest, up, and down) using EEG signals. The proposed method demonstrates an accuracy of 80%, suggesting that the use of statistical indices at frequency bands related to brain activity that can be suitable for motor imagery classification.

Keywords: ECG signals, Motor Imagery, Wavelet transform, Statistical Index.

I. INTRODUCTION

MI is known as a mental representation of movements (e.g., the hand movements) performed by individuals, where the motor planning and internal simulation of motor activity without a physical movement is involved [1], [2]. It is characterized to activate and involve the same brain areas that the activated during a real movement [3], [4]. In this regard, it has been employed in the treatment of patients with stroke, a disease caused by the sudden interruption of cerebral circulation after an injury to the blood vessels in this area, limiting their motor skills [5], [6]. This treatment is based on the evocation, by person, of a movement and the monitoring of EEG signals in order to identify patterns in the EEG signals to associate them with the movement fancied[7]. Consequently, it is crucial to propose a method for identifying suitable patterns into the EEG.

In the last decade, several researchers have presented different methods in the literature for processing EEG signals to be applied for classifying the MI to assist the persons with disabilities [7-12]. For example: In [8] was presented a methodology based on autoregressive models and the Fisher method for classifying two movements fancied (e.g., right and left direction movement), obtaining an accuracy of 80.8%. In [9]

was integrated the empirical mode decomposition, fractals and an artificial neural network (ANN) for automatic classification of three movements fancied (e.g., rest, right and left), reaching an accuracy of 71%. In [10] was characterized the brain electrical activity related to hand movement imagination, particularly left- and right-hand movement. The acquired EEG signals were characterized by using the Fourier transform, obtaining a fidelity of 76%. In [11] was implemented the wavelet method for classify the EEG signals monitored for body movements (e.g., tongue, right hand, feet, and left hand). In this test, the authors obtained a 98% of exactness and noted that a high computational load is required. In [12] was presented a methodology based on wavelet transform and fractals in order to classify three different movements with pictures (up, down and rest), reaching aprecision of 74.5%. Despite, the remarkable results obtained in the discussed works, it is of primordial importance to continue investigating other alternatives/methods in order to (1) increase the accuracy, (2) reduce the computational load for obtaining a classification on line of diverse movement fancied.

A few years ago, the statistical indices (SIs) have demonstrated to be effective tools for distinguishing significant changes into the time signals for diagnosis the health condition of civil structures[13] cardiac diseases [14], sleeping disorders [15], induction motors [16] and more applications. In general, the SIs allow measuring diverse properties in the non-stationary time signals e.g., convergence, asymmetry, dispersion, among others properties [17], [18]. In this sense, they present a low complexity and computational cost [15], which can be useful to identify relevant characteristics into the EEG signals in order to classify automatically the IM.

According to the aforementioned, this article presented a method based on the integration of SIs with ANN (i.e., a multilayer perceptron) for classifying automatically three fancied movement (e.g., rest, up and down), using EEG signals. This work investigates 17 SIs (i.e., Mode (MO), Magnitude (Me), Root Mean Square (RMS), Range (RG), Mean (M),

Figura 30. Artículo de investigación.