



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Ingeniería Biomédica

**CLASIFICACIÓN DE LA IMAGINACIÓN MOTORA A PARTIR DE
SEÑALES EEG EMPLEANDO LA TRANSFORMADA DE
DESCOMPOSICIÓN EMPÍRICA DE MODOS Y ENTROPÍA**

TESIS

Que como parte de los requisitos para obtener el título de
Ingeniero Biomédico

Presenta:

Miguel Alejandro Salazar Guerrero

Dirigida por:

DR. Carlos Andrés Pérez Ramírez

DR. Juan Pablo Amézquita Sánchez

Querétaro, Qro., Agosto de 2019

Dirección General de Bibliotecas de la UAQ



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
 FACULTAD DE INGENIERÍA
 CAMPUS AEROPUERTO



CLASIFICACIÓN DE LA IMAGINACIÓN MOTORA A PARTIR DE SEÑALES EEG
 EMPLEANDO LA TRANSFORMADA DE DESCOMPOSICIÓN EMPÍRICA DE MODOS Y
 ENTROPÍA

TESIS

Como parte de los requisitos para obtener el título de

INGENIERO BIOMÉDICO

Línea Terminal

BIOSEÑALES Y BIOINSTRUMENTACIÓN

Presenta

MIGUEL ALEJANDRO SALAZAR GUERRERO

Dirigido por:

DR. CARLOS ANDRÉS PÉREZ RAMÍREZ.

DR. JUAN PABLO AMEZQUITA SANCHEZ.

SINODALES:

M.C. CARLOS ANDRÉS PÉREZ RAMÍREZ (14209)

Presidente

Firma

DR. JUAN PABLO AMEZQUITA SÁNCHEZ (11508)

Secretario

Firma

M.C. LUISA RAMIREZ GRANADOS (11607)

Vocal

Firma

DRA. VANESSA VALLEJO BECERRA (12718)

Suplente

Firma

Santiago de Querétaro, Qro., Junio 2019

RESUMEN

En el México actual, existen diversos factores que provocan pérdida de extremidades, el número de personas amputadas asciende a más de 780000 según el INEGI, todas estas personas se encuentran con la imposibilidad de realizar sus tareas plenamente y puedan desarrollarse en sociedad de manera adecuada, a lo largo de los años se han propuesto algunas soluciones que puedan aportar un beneficio a este sector de la población, entre estas se encuentra la imaginación motora.

La imaginación motora propone que mediante el pensamiento concreto de realizar algún movimiento sin necesidad de realizarlo, y a través de señales EEG se obtenga la señal que emite el cerebro al realizar dicha acción y esta pueda ser discriminada y encontrada de manera singular.

La manera de separar dicha señal es mediante la Descomposición Empírica de Modos (EMD por sus siglas en inglés) esta separa la señal en distintas bandas por sus componentes de frecuencia para el manejo de la señal de una manera más sencilla. Se obtienen características propias de la señal a través del análisis de Entropía de Shannon, para finalmente someter los resultados a un clasificador difuso, el cual será capaz de discernir entre los estados de pensamiento.

Palabras clave: imaginación motora, EEG, entropía de Shannon, clasificador difuso

DEDICATORIA

Esta tesis está dedicada a mis padres Martín Salazar y Juanita Guerrero, quienes me dieron la vida y me han enseñado a vivirla, su apoyo incondicional siempre ha estado presente

A mis hermanos Mauricio y Lucía quienes siempre me han alentado y me han liberado de estrés en momentos complicados, siempre sacándome una sonrisa

A Andrea Jimenez quien ha sido mi compañera en este viaje, siempre teniendo fe en mi y ayudándome

A mi tía Maria Luisa Guerrero quien siempre me brindó su apoyo desde incluso antes de ingresar a la universidad

AGRADECIMIENTOS

Agradezco a mi papá por siempre dar todo por sus hijos, todo el sacrificio que ha realizado para que podamos lograr nuestros sueños, siempre trabajando duro para que no nos falte nada

A mi madre por toda una vida dedicada a sus hijos, todas esas mañanas madrugando para que tengamos algo para comer en las horas de escuela, por todo el amor que siempre me brindó

A mi hermana Lucía por ser esa chispa en mi vida, la alegría de mi casa, sus abrazos siempre me reconfortan

A mi hermano Mauricio porque aunque no siempre lo demuestra se preocupó por mi y me ayudó en lo que necesitara

A todos mis amigos, de la universidad por tantos momentos vividos en esos 4 años y medio, al resto de mis amigos por siempre brindarme su amistad y cariño

A Andrea por estar conmigo todo este tiempo, siempre al pendiente y siempre alentándome, escuchándome y aconsejándome para tomar las mejores decisiones

A mis maestros que durante mi universidad me ofrecieron sus conocimientos, en especial a mis asesores que no solo durante la tesis, sino a lo largo de la carrera demostraron disponibilidad para todas mis dudas, el Dr. Carlos Perez, el Dr. Amezquita, la Mtra. Luisa Ramirez y la Dra. Vanessa Vallejo

ÍNDICE GENERAL

RESUMEN.....	iii
DEDICATORIA.....	iv
AGRADECIMIENTOS.....	v
ÍNDICE GENERAL.....	vi
INDICE DE FIGURAS.....	viii
ÍNDICE DE TABLAS.....	ix
1. Capítulo I: Introducción.....	1
1.1 Introducción	2
1.2 Antecedentes.....	3
1.3 Descripción	del
problema.....	5
1.4 Justificación.....	6
1.5 Hipótesis.....	7
1.6 Objetivos.....	7
1.6.1 Objetivo General.....	7
1.6.2 Objetivos	7
particulares.....	7
1.7 Planteamiento General.....	8
2. Capítulo II: Fundamentación teórica.....	9
2.1 Revisión Bibliográfica.....	10
2.2 Señales EEG.....	10
2.3 Procesamiento	de
señales.....	13
2.3.1 MATLAB	13
2.3.2 Técnica	de
de	descomposición
empírica	de
modos.....	15
2.3.3 Entropía	16

2.3.3.1	Entropía	de	Shannon	
			16
2.3.3.2	Entropía		de	
	permutación.....			17
2.3.4	Análisis		de	
	ANOVA.....			17
2.3.5	Clasificador	de	Lógica	
	Difusa.....			18
3.	Capítulo		III:	
	Metodología.....			21
3.1	Metodología Propuesta			22
3.2	Casco EMOTIV.....			23
3.3	Material			
	empleado.....			25
3.4	Sistema	de	adquisición	de
	datos.....			26
3.5	Procesamiento	de	la	
	señal.....			27
4.	Capítulo	IV:	Pruebas	y
	Resultados.....			31
4.1	Puesta		de	
	experimento.....			32
4.2	Resultados.....			32
4.3	Discusión de Resultados			37
5.	Capítulo	V:	Conclusiones	y
	Prospectivas.....			40
5.1	Conclusiones.....			41
5.2	Prospectivas.....			41

ÍNDICE DE FIGURAS

Figura 1.1. Planteamiento General.....	8
Figura 2.1. Dibujo de una neurona.....	11
Figura 2.2. Electrodo EEG de oro.....	12
Figura 2.3. Pantalla principal de MATLAB.....	14
Figura 2.4. Editor de código.....	14
Figura 2.5. Diagrama de Sistema difuso.....	19
Figura 3.1. Diagrama de la metodología propuesta.....	22
Figura 3.2. Casco EMOTIV EPOC+.....	23
Figura 3.3. Sistema de colocación de electrodos 10-20.....	24
Figura 3.4. Señal a través de los distintos intervalos de tiempo según el estado.....	25
Figura 3.5. Señal muestra conformada por 3 frecuencias distintas.....	28
Figura 3.6. IMFs obtenidas de la señal prueba.....	29
Figura 3.6. (a) Señal de 50 Hz constantes durante 2 minutos, (b) Señal de 50 Hz interrumpidos.....	30
Figura 4.1. Pantalla mostrada a los participantes.....	32
Figura 4.2. Descomposición de la señal en IMFs.....	33
Figura 4.3. Diagrama de cajas y bigotes de sensores 7 y 12, en las IMFs 6 y 5.....	36

ÍNDICE DE TABLAS

Tabla 3.1. Principales características del casco empleado.....	26
Tabla 4.1. Valores P obtenidos.....	33
Tabla 4.2. Valores de media, desviación estándar, valores P y valores F (μ : media, σ desviación estándar).....	36
Tabla 4.3. Matriz de confusión del clasificador desarrollado.....	37
Tabla 4.4. Diversas metodologías empleadas para la clasificación de señales de imaginación motora.....	38

CAPÍTULO I

Introducción

Dirección General de Bibliotecas de la UAQ

1.1 Introducción

En México existe un gran número de personas amputadas por diversas razones y padecimientos, el INEGI reportó en 2015 que el número de amputados en el país es cercano a 780,000 (Vázquez, 2015). La Academia Nacional de Cirugía reporta que 75 personas son amputadas diariamente, de los cuales la mayoría presenta una incapacidad, y estas personas van desde bebés hasta personas de edad avanzada (Vázquez, 2015). Por estas razones, es necesario la creación de prótesis que permitan a la persona tratar de llevar una vida normal.

Existen distintos tipos de prótesis, clasificadas en distintas formas, la clasificación más sencilla es en pasivas y activas (Fundación Materialización 3D, 2017). Las prótesis pasivas son aquellas que únicamente son utilizadas con fines estéticos, mientras que las activas son las que cumplen la función deseada. Las prótesis activas se clasifican a partir del método empleado para realizar el movimiento, algunas simplemente actúan a razón de los movimientos del cuerpo, son llamadas prótesis mecánicas. Dentro de las prótesis activas, las prótesis eléctricas son aquellas que realizan sus funciones a partir de impulsos eléctricos, ya sea por algún tipo de control o por las señales emitidas por el organismo del usuario. Las señales emitidas por el organismo pueden ser de distintos tipos; por ejemplo, señales mioeléctricas (señales provenientes o medidas en las terminales nerviosas de los músculos), electroencefalografías (EEG) (señales medidas en la corteza cerebral), entre otras.

La señal EEG, como se menciona en el párrafo anterior, es el registro y evaluación de los potenciales eléctricos generados por el cerebro, entre neuronas y obtenidos por medio de electrodos situados sobre la superficie del cuero cabelludo (Vázquez et al., 1998). El origen de la señal eléctrica está en las células piramidales de la corteza cerebral. Cada neurona constituye un dipolo eléctrico, cuya polaridad depende del impulso inhibitorio o excitatorio. Para poder recoger la señal de cada región cerebral se colocan electrodos que captan la diferencia de potencial entre ellos (uno activo y otro de referencia) dicha señal es amplificada, al arreglo de electrodo activo y de referencia se le conoce como canal, regularmente

se miden entre 16 y 24 canales. La medición de señales EEG se realiza con la finalidad de conocer qué secciones del cerebro interactúan al realizar una actividad determinada. Por lo tanto, el análisis de las señales EEG es de gran interés para la creación prótesis mecánicas automáticas a través de la imaginación motora. La imaginación motora consiste en generar imágenes de cosas o eventos, que preparan al individuo para actuar de manera adecuada en el ambiente. Es comúnmente utilizada para imaginar en el cuerpo las fuerzas que actúan en el movimiento, sin generar los efectos al exterior del cuerpo. Estas señales de EEG, mediante una interfaz Cerebro-computadora a través de la imaginación motora, se puede convertir en una respuesta artificial que opere en favor del cuerpo humano (Guillot et al., 2010).

1.2 Antecedentes

El área de la imaginación motora no es un campo nuevo del todo, pues alrededor del mundo y del país se han propuesto algunas metodologías para la clasificación de patrones producidos por la imaginación motora. Por ejemplo, en el ámbito internacional, Pfurtscheller et al. (1998) utilizó la discriminación lineal y redes neuronales para clasificar el pensamiento de movimientos izquierda-derecha. Los resultados obtenidos presentan un error máximo del 38%, indicando que la metodología propuesta no es acertada. Con el fin de mejorar los resultados obtenidos por Pfurtscheller et al. (1998), Pfurtscheller et al. (2001) replanteó su metodología propuesta, discriminación lineal y redes neuronales, pero con un sistema retroalimentado de rápido prototipado. Los resultados obtenidos ahora arrojaron que la metodología propuesta es capaz de clasificar el patrón de movimientos con gran exactitud; sin embargo, a costa de un procesamiento muy lento, el cual no podría ser implementado en prótesis que requieran de un movimiento en tiempo real. Por otro lado, Qin et al. (2005) empleó la transformada wavelet para analizar las señales EEG provenientes de pensamientos de izquierda o derecha. La prueba consistió en asignar al paciente cada 5 segundos la idea de

izquierda y derecha, obteniéndose una eficiencia del 78%. Un trabajo similar fue presentado por Bao-Guo et al. (2008) y Wei-Yen et al. (2009), donde los autores emplearon la transformada wavelet para clasificar patrones relativos al pensamiento de derecha-izquierda en señales EEG. Los resultados arrojaron que una eficiencia de clasificación del 90% es obtenida. A pesar de los buenos resultados obtenidos por Bao-Guo et al. (2008) y Wei-Yen et al. (2009), es importante mencionar que estos dependen de una calibración muy ardua de los parámetros de la transformada wavelet, además de ser susceptibles a la cantidad de ruido que contenga la señal.

Velásquez-Martínez et al. (2013) empleó el método llamado patrones espaciales comunes para la calificación de la imaginación motora en pensamiento de izquierda y derecha obteniendo una eficiencia que varía entre 95.21 y 4.21%. Batres-Mendoza et al. (2017) combinó el método de cuaterniones con algoritmos de inteligencia artificial (máquina vectorial de soporte y árboles de decisiones), para clasificar tres patrones de movimiento (reposo, pensamiento hacia la izquierda y pensamiento hacia la derecha) empleando señales EEG. Los resultados muestran que los autores fueron capaces de clasificar los patrones con una eficiencia del 80%, concluyendo que una investigación futura de otros algoritmos de procesamiento es necesaria con el fin de encontrar características dentro de las señales EEG que permitan incrementar la eficiencia de la clasificación del patrón.

Con respecto a trabajo relacionado con la imaginación motora en el país (México), Lemus-Lopez et al. (2014) formuló un algoritmo que clasifica los sensores relacionados a la imaginación motora, redujo de 118 a 35, los sensores implicados. Torres-García et al. (2013) utilizó la transformada wavelet discreta y 3 clasificadores: Ingenuo de Bayes (NB), Bosques Aleatorios (RF) y Máquina de vectores de soporte (SVM) para distinguir entre 14 y 4 canales, logrando clasificar con una exactitud de entre 47 y 60% en imaginación del habla. Por lo tanto, a nivel nacional la investigación se ha centrado en optimizar el número de sensores para

la clasificación de patrones a partir de la imaginación motora producida por el habla.

Dentro de la Universidad Autónoma de Querétaro (UAQ) existen trabajos relacionados a procesamiento de señales del cuerpo humano. Por ejemplo, Vázquez (2013) realizó un análisis de imágenes termográficas para diagnosticar cuando una persona tiene o no pie diabético. Jiménez (2015) continuando con el trabajo de Vázquez (2013), desarrolló un sistema de visión artificial para procesar y segmentar imágenes para la detección temprana de ulceraciones en la planta de los pies. Por otro lado, Vega (2016) empleó imágenes termográficas del pecho de mujeres, para detección temprana de cáncer de mama. Dentro de la carrera de Ingeniería Biomédica, los trabajos de Cruz (2018), Carrasco (2019), Pérez (2019) y Pacheco (2019) indican que el área de procesamiento de Bioseñales es de gran relevancia en todos los niveles tanto industrial como académico, ya que el procesamiento de bioseñales permite la identificación de patrones o características dentro de señales biomédicas para poderlas asociar a un fenómeno estudiado. Por estas razones, se observa que, en lo referente a lo local, UAQ, se trabaja con procesamiento de señales, y con técnicas de caracterización y obtención de patrones para el diagnóstico de enfermedades; sin embargo, hasta el momento no se han trabajado con señales EEG e imaginación motora, siendo esta la primera tesis en trabajar con estas para la clasificación de patrones de la imaginación motora.

1.3 Descripción del problema

Actualmente, una gran parte de la población sufre discriminación por falta de movilidad en sus extremidades debido a amputaciones, lo que puede llegar a ocasionar afectaciones en el desarrollo de su vida cotidiana, laboral y social. Estas personas generalmente recurren a prótesis estéticas, pero éstas no solucionan el problema por completo, puesto que no cumplirán la función del miembro perdido. Otra opción consiste en prótesis motorizadas, pero son muy costosas y en algunas

ocasiones no poseen o es baja su capacidad de movimiento bajo las órdenes del usuario.

Es por eso que surge la necesidad de un sistema que involucre al ser humano en el movimiento de la prótesis que va a utilizar, por ello las señales de EEG obtenidas durante el pensamiento motor es una posible opción para lograr tal necesidad. Al realizar una interpretación correcta de las señales obtenidas en la imaginación del movimiento, se puede lograr hacer un control de los movimientos deseados y, clasificando de manera correcta los patrones, se puede tener movimientos más certeros y una conexión más sincronizada entre el usuario y la prótesis.

1.4 Justificación

El sector de la población que ha sufrido amputaciones no sólo tiene dificultades para la movilidad en su día a día, sino también gastos extras en prótesis estéticas, que la mayoría de las veces son de corta duración y requieren de una transportación especial. La generación de prótesis capaces de moverse con indicaciones de su usuario podría ser una solución integral al problema. Las señales de EEG son de las principales señales que son empleadas para generar patrones de movimientos; sin embargo, este tipo de señales poseen características no estacionarias, es decir, sus características tales como frecuencia y amplitud varían a lo largo del tiempo, así como un gran nivel de ruido debido a que estas señales son de muy baja amplitud.

Por lo tanto, se requiere de un sistema basado en procesamiento avanzado que permita trabajar con este tipo de señales y que sea capaz de identificar características en estas para poder genera un patrón de movimiento a partir de señales EEG que puedan ser empleadas en las prótesis mecánicas. Al poder clasificar estas señales, se puede pensar en el control de prótesis, que representaría un beneficio psicológico, económico y social para las personas que

presenten algún problema de amputación que no les permita desarrollarse plenamente en la sociedad

1.5 Hipótesis

Mediante la utilización de la descomposición empírica de modos, la entropía de la señal y un clasificador de lógica difusa es posible generar una metodología que permita realizar la clasificación del pensamiento o imaginación motora.

1.6 Objetivos

1.6.1 Objetivo General

Proponer y desarrollar una metodología basada en la descomposición empírica de modos, la entropía y un clasificador de lógica difusa para la clasificación del pensamiento o imaginación motora, particularmente pensamientos que simulan movimientos hacia la izquierda, derecha y reposo.

1.6.2 Objetivos particulares

- Leer las señales EEG mediante el uso del software MATLAB para su entendimiento y análisis.
- Programar la técnica descomposición empírica de modos haciendo uso del software MATLAB para procesar y descomponer una señal en tiempo en sus diferentes bandas de frecuencia.
- Programar los algoritmos de entropía de Shannon y Permutación haciendo uso del software MATLAB para estimar la regularidad de una señal en el dominio del tiempo.

- Desarrollar una metodología mediante la conjunción de la descomposición empírica de modos y la entropía que sea capaz de distinguir entre una persona que piensa que se mueva a su izquierda, derecha o está en reposo.
- Realizar un análisis estadístico de las diferentes pruebas con el fin de validar la metodología propuesta buscando realizar la clasificación de manera eficiente.

1.7 Planteamiento General

En la Figura 1.1 se muestra el planteamiento general de la tesis que consta de 3 pasos:




Figura 1.1. Planteamiento General.

Como se aprecia, para el problema planteado en el presente trabajo, se propone un enfoque de 3 pasos: (1) el sistema de adquisición es el encargado de proceder con la medición y adquisición de las señales EEG durante la prueba de imaginación motora, (2) en la etapa de procesamiento se trabajan las señales obtenidas en el sistema de adquisición con la finalidad de identificar alguna característica del patrón de pensamiento para ser clasificadas mediante [JA1] (3) un clasificador consiste en un algoritmo de inteligencia artificial que permite realizar la distinción entre las características obtenidas en la etapa de procesamiento, y con base en esto poder estimar el patrón que está pensando la persona (reposo, izquierda o derecha).

CAPÍTULO II

Fundamentación Teórica

2.1 Revisión Bibliográfica

En esta sección se presenta la información teórica necesaria para demostrar lo realizado en el presente trabajo de tesis.

2.2. Señales EEG

La electroencefalografía es la medición de potenciales emitidos por la actividad cerebral y permite conocer cómo es que el cerebro funciona. El electroencefalograma funciona a partir de electrodos colocados en la superficie craneal. Los electrodos detectan cargas eléctricas que son el resultado de la actividad de las células cerebrales. Esas cargas son amplificadas y recibidas. Existen 2 tipos de EEG: superficiales, colocados en el cuero cabelludo e intracraneales, implantados de forma quirúrgica en la corteza cerebral.

La amplitud de las señales de EEG abarca entre 1 y 100 μV en adultos normales. Los electrodos se colocan bajo el método internacional de la regla 10-20, dichos números representan que la distancia entre electrodos debe ser 10 o 20% del total de distancia del cráneo. La posición se determina mediante 2 puntos; nasión, que es el punto entre la frente y la nariz, al nivel de los ojos e inión que es la prominencia ósea de la base del cráneo en la línea media de la parte posterior de la cabeza

El cerebro humano está compuesto por neuronas (figura 2.1) que poseen la característica electroquímica para transmitir energía eléctrica en forma de señales que representan mensajes hacia otras neuronas. Las neuronas cuentan con 3 partes, el cuerpo o soma, axón y dendrita. El axón es la parte de la neurona que conecta el núcleo de la misma a la dendrita de otra neurona, mientras que la dendrita es una sección corta con receptores para neurotransmisores. La conexión entre dendritas y axones implica la comunicación entre una neurona y otra.

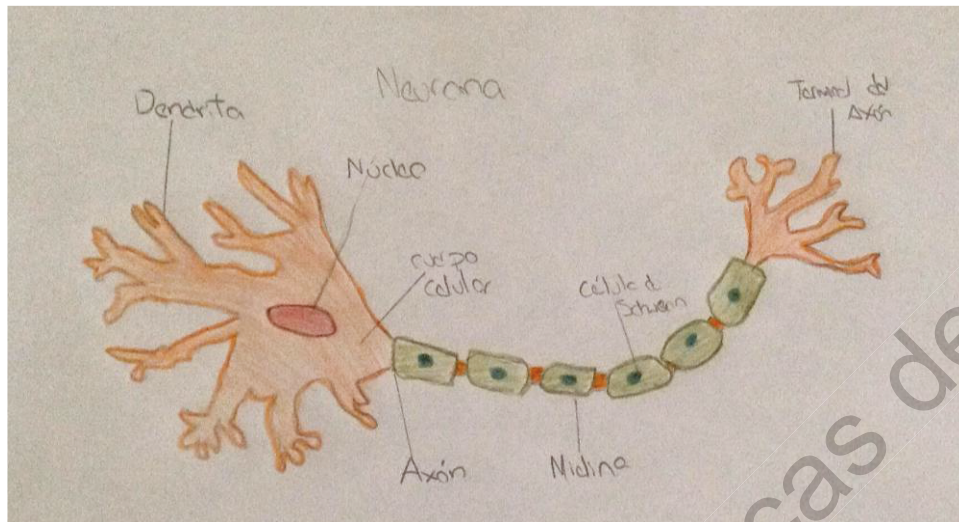


Figura 2.1. Dibujo de una neurona.

La comunicación se da mediante potenciales de acción, que es el proceso en el cual un ion bombea a un axón realizando un intercambio iónico provocando una señal eléctrica que viaja del axón a la dendrita. Estos impulsos son recibidos por los electrodos y posteriormente enviados al sistema del EEG.

La actividad eléctrica cerebral se puede medir mediante sensores que encuentren el potencial entre un electrodo y otro. Los electrodos son dispositivos que facilitan la conducción de potenciales electrocorticales hacia el dispositivo de amplificación (Rowan et al., 2004). De manera regular son discos de tamaño pequeño no reactivos que se colocan sobre el cuero cabelludo mediante una pasta de conducción. Se elaboran con diversos metales, tales como oro, plata, plata/cloruro de plata, estaño y platino. En la figura 2.2 se muestran los electrodos de oro comerciales para EEG. El contacto del electrodo con el cuero cabelludo debe ser firme para generar resistencia al flujo de corriente, es decir, impedancia, con la finalidad de disminuir los artefactos (ruido) relacionados al electrodo y al entorno en el que se encuentra.



Figura 2.2. Electrodo EEG de oro.

Los electrodos se colocan de manera estandarizada en todo el mundo, de manera que se puedan interpretar en cualquier laboratorio existente. El sistema de colocación fue generado por el Dr. Herbert Jasper, especialista en electroencefalografía, este sistema se nombra *10-20 International System of Electrode Placement* (Rowan et al., 2004). Los electrodos se colocan de la siguiente manera, por convención los números impares se colocan a la izquierda y los pares a la derecha:

- Fp1/Fp2= frontopolar o prefrontal (en la frente, registra la actividad de los polos frontales)
- F3/F4= mediofrontal (sobre el lóbulo frontal, registra la actividad frontal)
- C3/C4= central (aproximadamente, sobre la cisura de Rolando, también denominada surco central)
- P3/P4= parietal (registra la actividad parietal)
- O1/O2= occipital (registra la actividad occipital)

- F7/F8= frontal inferior, en ocasiones denominado temporal anterior (registra la actividad de las regiones orbitofrontal, frontal lateral y temporal anterior)
- T3/T4= temporal medial (registra la actividad de las regiones temporales anterior y medial)
- T5/T6= temporal posterior (registra la actividad existente en las regiones temporales posteriores)
- Fz, Cz, Pz= electrodos de la línea media en las regiones frontal, central y parietal (registran los potenciales procedentes de las superficies de la línea media y mediales de los hemisferios)
- A1/A2= electrodos de referencia en los pabellones auriculares (registran actividad de las regiones temporales mediales)
- T1/T2= electrodos temporales anteriores verdaderos (temporales anteriores)
- Sp1/Sp2= electrodos esfenoidales (no son parte del sistema 10-20, pero registran actividad de la superficie inferomedial de los lóbulos temporales) (Rowan et al., 2004)

2.3 Procesamiento de señales

2.3.1 MATLAB

El programa Matrix Laboratory (MATLAB) consiste en una serie de herramientas utilizadas en la resolución de problemas comunes, donde el procesamiento de señales es una de las aplicaciones más claras de MATLAB, ya que permite analizar señales en un rango de datos fuente, el software permite adquirir, medir, transformar, filtrar y visualizar. Las herramientas de MATLAB en procesamiento permiten:

- Preprocesar y filtrar señales previo a su análisis

- Explorar y extraer características de datos
- Analizar tendencias y descubrir patrones en señales
- Visualizar y medir características de tiempo y frecuencia en las señales

En la Figura 2.3 se muestra la interfaz inicial de MATLAB, es decir, la pantalla en la cual se trabaja, se trata de la pantalla donde se genera el código a partir del cual se va a trabajar

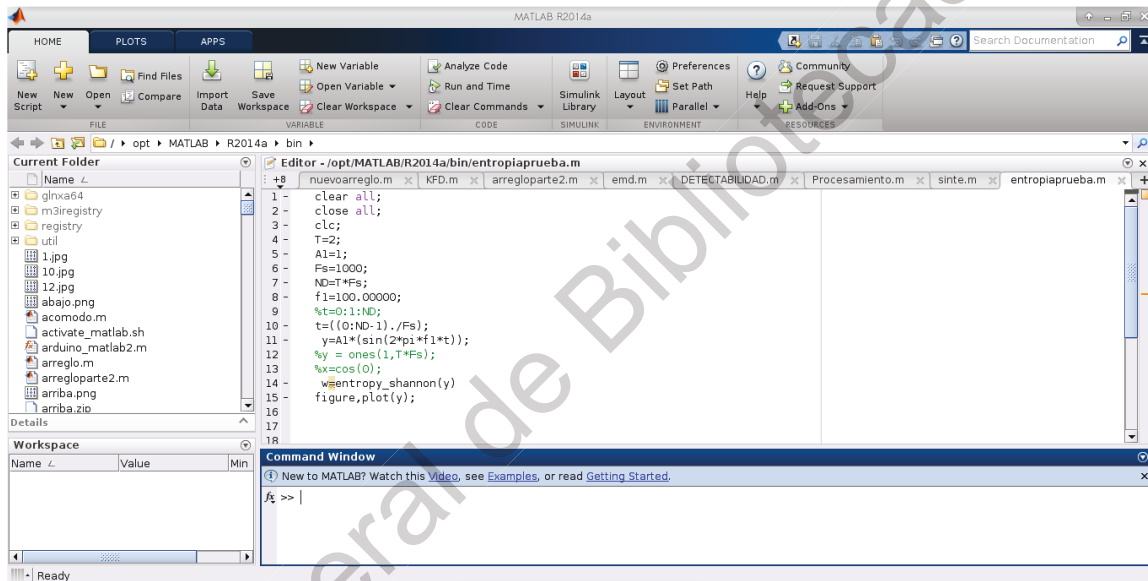


Figura 2.3. Pantalla principal de MATLAB.

El editor (Figura 2.4) es la sección en la cual se escribe el código en el cual se va a trabajar, dicha sección permite escribir y realizar los cambios pertinentes



Figura 2.4. Editor de código

2.3.2 Técnica de descomposición empírica de modos

El método de EMD es una técnica de procesamiento de datos para analizar señales no estacionarias y no lineales, al descomponer cualquier dato en un conjunto de funciones de bandas limitadas cuasi-estacionarias, llamadas funciones intrínsecas de modos (IMFs, por sus siglas en inglés). Cada IMF tiene que satisfacer las condiciones: i) el número de cruces por cero y el número de extremos debe ser igual o diferente en menos de 1 y ii) el valor medio de la envolvente definida por los máximos locales y la envolvente definida por los mínimos locales debe ser cero. El proceso para obtener cada IMF es llamado proceso de cernido, el cual se describe a continuación:

1. Identificar el máximo y el mínimo de la señal $x(t)$
2. Generar una envolvente superior e inferior mediante el uso de interpolación spline cúbica. El promedio de las 2 envolventes es $m_1(t)$. Se resta $m_1(t)$ de la señal original $x(t)$ para obtener

$$h_1(t) = x(t) - m_1(t) \quad (2.1)$$

Determinar si la Ecuación (2.1) satisface las condiciones (i) y (ii). Si no, repetir los 2 primeros pasos hasta que $h_k(t)$ satisfaga las condiciones (i) y (ii); entonces $h_k(t)$ es la primer IMF definida como

$$c_1(t) = h_k(t) = \text{IMF 1} \quad (2.2)$$

3. Después de obtener la IMF 1, restar $c_1(t)$ de la señal original $x(t)$ y calcular la señal residuo $r_1(t)$ de la siguiente forma:

$$r_1(t) = x(t) - c_1(t) \quad (2.3)$$

4. Tratar $r_1(t)$ como la señal original y repetir el procedimiento del paso 1 al 3 para obtener las siguientes IMFs (c_2, c_3, \dots, c_n). El proceso termina cuando el residuo final $r_n(t)$ es una función monótona. Una función se define como monótona cuando en un cierto intervalo, en el que está definida, para cualquier par de valores x_1 y x_2 de x , en el intervalo, $f(x_2) - f(x_1)$ tiene el

mismo signo que $x_2 - x_1$. En otras palabras, la función se define como monótona si mantiene la misma pendiente (Hebert, 2008).

5. Al final del procedimiento, la señal $x(t)$ es descompuesta en n modos intrínsecos $c_n(t)$ y el residuo $r_n(t)$. Ahora, la señal original puede representarse como:

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (2.4)$$

2.3.3 Entropía

La entropía es una medida de incertidumbre. El nivel de caos puede ser medido usando entropía del sistema. La entropía más alta representa mayor incertidumbre y un sistema más caótico (Camarena-Martinez et al., 2016). La entropía es usada en el cálculo de muchos otros parámetros útiles, como información mutua, negentropía, no gaussianidad y divergencia de Kulback-Leiber (Piedra et al., 2008). Estas variables son ampliamente usadas en la estimación de los grados de no linealidad de sistemas y sus correspondientes señales.

2.3.3.1 Entropía de Shannon

La Entropía describe cuánta información acerca de los datos es provista de manera aleatoria por una señal o evento. Ha sido utilizada en procesamiento de imágenes en detección de falla de caja de engranes, en monitoreo de salud estructural, para análisis de señales de electroencefalografía para diagnosticar condiciones clínicas, y en diagnóstico de falla de motores entre otros. (25) particular, la entropía de Shannon, nombrado por Claude Shannon (Nason, 2008), de una señal aleatoria $x(t)$ con n posibles salidas $x_1, x_2, x_3, \dots, x_n$ puede ser computada de la forma:

$$H(X) = - \sum_{i=0}^{N-1} p(x_i) \log_2 [p(x_i)]$$

donde $p(x_i)$ es la probabilidad de ocurrencia del dato x_i , obtenida con mediante el uso de un histograma, ya que no se conoce *a priori* la distribución de probabilidad que la señal tenga.

2.3.3.2 Entropía de permutación

La Entropía de Permutación fue propuesta por Bandt et al. (2002) para mapear una serie continua en el tiempo en una secuencia simbólica. Dada una serie de tiempo escalar $(x_t, t = 1, 2, \dots, T)$, de un procedimiento embebido forma un vector: $X_t = [x_t, x_{t+1}, \dots, x_{t+(n-1)I}]$ con una dimensión embebida, n , y el retraso, I (aquí $I = 1$). Entonces, X_t es arreglado en orden creciente: $[x_{t+(j_1-1)I} \leq x_{t+(j_2-1)I} \leq \dots \leq x_{t+(j_n-1)I}]$. Para n números diferentes habrá $n!$ posibles patrones de orden, que también son llamadas permutaciones. Entonces f denota su frecuencia en la serie de tiempo, su frecuencia relativa es $p(\pi) = \frac{f(\pi)}{T-(n-1)I}$ La entropía de permutación se define entonces:

$$H_p(n) = - \sum_{\pi=1}^{n!} p(\pi) \ln p(\pi) \quad (2.6)$$

La permutación normalizada se describe de la siguiente forma:

$$H_p = \frac{H_p(n)}{\ln(n!)} \quad (2.7)$$

El valor más alto de H_p es uno, que significa que la serie de tiempo es completamente aleatoria, el valor más bajo de H_p es cero, que significa que la serie de tiempo es regular (Ouyang et al., 2007)

2.3.4 Análisis de ANOVA

El análisis de varianza (ANOVA) consiste en una forma de conocer si los resultados de un experimento son significantes, ya que ayuda a encontrar hipótesis nula o hipótesis alternas. De manera general, ANOVA consiste en probar

distintos grupos y encontrar diferencias entre ellos. Contrasta la igualdad de medias de tres o más poblaciones independientes y con distribución normal. El análisis ANOVA genera 2 valores, el valor-P y el índice de discriminación de Fisher o valor-F. Estos 2 parámetros cuantifican qué tan apta es la característica elegida para encontrar diferencias entre las poblaciones que se desean discriminar. En particular, el valor-P encuentra sus valores en el rango de $[0,1]$, si el valor tiende a 0, el parámetro posee un alto nivel de distinción; por el contrario, si el valor tiende a 1, su capacidad de distinción es baja. Por otra parte, el valor-F tiende a valores altos cuando la tasa de separación es alta y mientras los valores sean bajos, la tasa será baja (Amezquita-Sanchez et al., 2016).

Para este trabajo, el análisis ANOVA por tanto permite determinar los datos que mejor representan las 3 situaciones a evaluar, imaginación motora derecha, izquierda y reposo.

2.3.5. Clasificador de Lógica Difusa

Una de las principales formas de clasificación automática en los años recientes ha sido mediante algoritmos de reconocimiento de patrones. Un clasificador es un algoritmo que asigna un objeto con características específicas a una clase con esas mismas cualidades (Martin, 2000). Esto es posible porque el algoritmo aprende a reconocer un objeto utilizando una estrategia de entrenamiento y un banco de datos de entrenamiento o porque es designado por conocimiento previo.

Un sistema basado en lógica difusa es capaz de tratar simultáneamente con variables numéricas y lingüísticas de modo formal. A modo de ejemplo, se tiene la temperatura, numéricamente podemos hablar de 35° . Su contraparte lingüística sería decir que la temperatura es alta. Un sistema difuso es un mapeo no lineal de un vector de entrada en una salida escalar; puede expresarse matemáticamente como una combinación lineal de funciones base difusas, y es un

aproximador universal no lineal de funciones base difusas (Martin, 2000). Por tanto, un clasificador basado en lógica difusa puede utilizarse si los datos pueden ser descritos mediante reglas de si-entonces (if-then). Estas reglas representan el conocimiento del diseñador.

Un sistema difuso consiste en 4 etapas:

1. Fuzzificación: es donde las entradas se convierten en información que el mecanismo pueda reconocer, contiene variables lingüísticas cuantificadas por funciones de pertenencia que pueden tener formas triangulares, trapezoidales, entre otras.
2. Reglas: Es un arreglo de reglas if-then que son programadas según convenga, para que cada objeto pertenezca a cada clase
3. Mecanismo de inferencia: realiza el proceso y otorga la conclusión del resultado óptimo
4. Defuzzificación: convierte la conclusión del mecanismo de interferencia en una señal entendible para el usuario, es decir, la clase a la que el objeto pertenece. (Amezquita-Sanchez et al., 2017)

De manera más gráfica la figura 2.5 muestra el diagrama del proceso del sistema difuso




Figura 2.5. Diagrama de Sistema difuso

El sistema difuso en este trabajo hará la función de relacionar las variables numéricas, obtenidas durante el proceso, es decir, los valores numéricos obtenidos tras el análisis ANOVA y posteriormente relacionarlo directamente con la variable lingüística, que en este caso sería derecha, izquierda y reposo

Dirección General de Bibliotecas de la UAQ

CAPÍTULO III

Metodología

3.1 Metodología Propuesta.

En este capítulo se presenta la metodología empleada para resolver el problema planteado en el capítulo 1. En la Figura 3.1 se muestra un diagrama esquemático de la metodología propuesta para la clasificación de patrones a partir de la imaginación motora.




Figura 3.1. Diagrama de la metodología propuesta.

A partir de la Figura 3.1, se observa que ésta está compuesta de 4 pasos.

1. Se hace uso de la descomposición empírica de modos (EMD) es empleada para descomponer o separar las señales EEG en un conjunto de IMFs de acuerdo con la información frecuencial contenida en la señal (Huang et al., 1998), ya que de esta manera se encuentran las componentes fundamentales que la señal tiene, lo que facilita la extracción de características a fin de generar un clasificador efectivo.
2. A cada IMF se le hace el análisis de entropía de permutación y de Shannon, el cual permite monitorear la incertidumbre, es decir la aleatoriedad de los valores de la señal, es empleado para analizar las sub-bandas obtenidas. Dos alás pequeño-goritmos para la estimación de la entropía son investigados, entropía de Shannon y entropía de permutación, con el fin de verificar cuál de las dos permite una mayor discriminación.
3. Posteriormente, se realiza un análisis estadístico (AE) mediante el análisis de ANOVA para evaluar las características estimadas por los algoritmos de entropía de Shannon de cada sub-banda o banda de frecuencia, las cuales deben ser capaz de discriminar los patrones reposo, izquierda y derecha

generados a partir de la imaginación motora. Es importante resaltar que las características a emplear deben tener el valor-P tan bajo como sea posible, ya que de esta manera se asegura que las características aportan información útil para el clasificador.

4. Finalmente, un clasificador de lógica difusa (CLD) es desarrollado para la clasificación entre los patrones reposo, izquierda y derecha de forma automática.

3.2 Casco EMOTIV

El casco Emotiv EPOC+ (Figura 3.2) de grado investigación está designado para investigación de aplicaciones de interfaz de control cerebral (BCI). Sus principales características son:

- Posee 14 canales: F3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4 y 2 referencias
- El método de muestreo es mediante muestreo secuencial por un convertidor analógico digital (ADC)



Figura 3.2. Casco EMOTIV EPOC +

Los electrodos están configurados en orden a modo de cumplir con el sistema 10-20, que consiste en que los electrodos mantengan una distancia entre ellos de entre el 10 y 20% de la distancia total entre puntos reconocibles del cráneo.

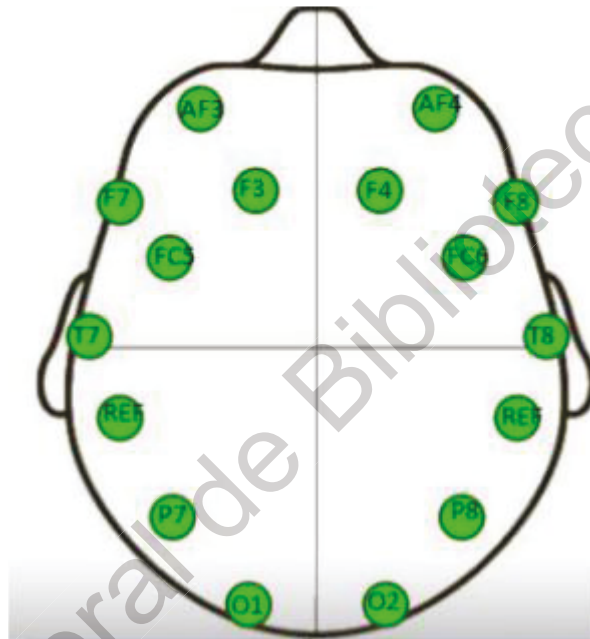


Figura 3.3. Sistema de colocación de electrodos 10-20.

A modo de ejemplo, se tomaron los datos del sensor AF3, y se dividió por los intervalos de tiempo en los cuales se piensa en reposo, derecha, reposo nuevamente e izquierda, y se graficó el resultado obtenido en la Figura 3.3, en la que se puede apreciar que es muy complicado encontrar diferencias entre los distintos estados, ya que las señales son muy similares y poco regulares, es decir, son muy impredecibles a través del tiempo

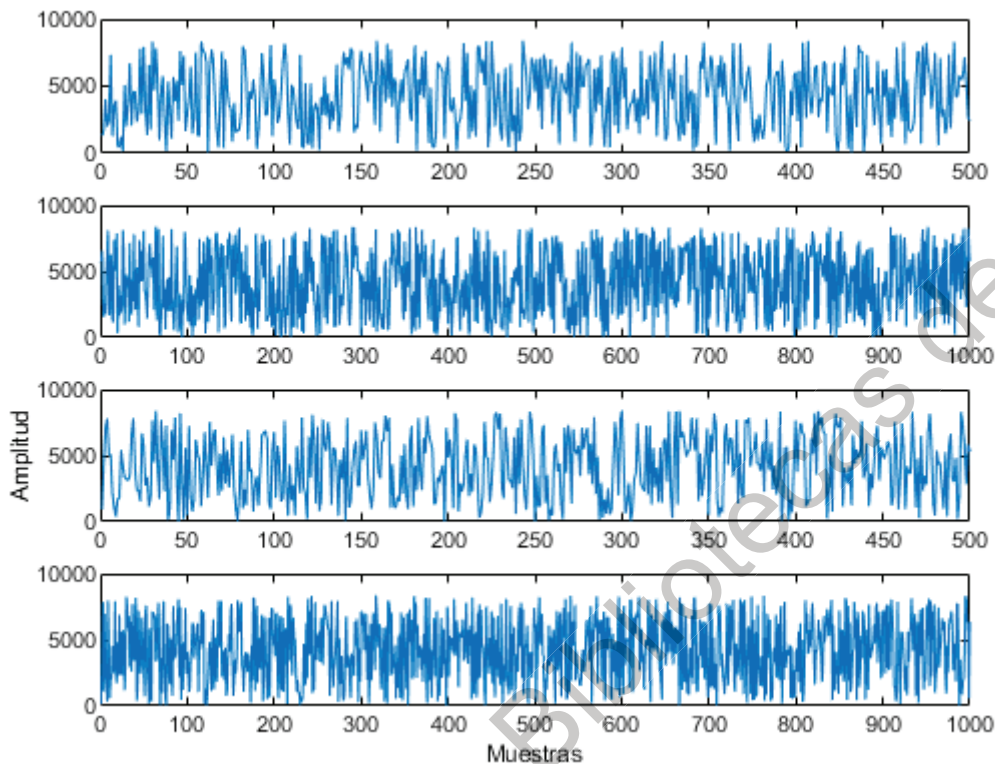


Figura 3.4. Señal a través de los distintos intervalos de tiempo según el estado

3.3 Material empleado

Se realizaron las pruebas aquí presentadas en 10 voluntarios de distintos sexos y edades durante la mañana. Las pruebas se realizaron a todas las personas bajo condiciones iguales, es decir, en la misma habitación, con electrodos desechables del mismo tipo y especificaciones, así como el mismo casco EMOTIV. Se solicitó a los participantes ciertas condiciones para evitar problemas al momento del experimento, no haber ingerido bebidas alcohólicas en los últimos 2 días, realizar la prueba tras una alimentación correcta, asistir al experimento y la mañana posterior a haber dormido 8 horas o más

3.4 Sistema de adquisición de datos

El sistema de adquisición que posee el casco permite obtener la señal a través de una frecuencia de muestreo de 128 Hz. La resolución a la que trabaja el casco es de 14 bits, donde el bit menos significativo permite leer una variación de voltaje de 0.51 μ V. La Tabla 3.1 resume las principales características del sistema del casco empleado.

Tabla 3.1. Principales características del casco empleado.

Característica	Valor
Número de canales	14 (más referencias CMS/DRL, ubicaciones P3/P4)
Nombre de los canales (Regla 10-20 de colocación)	AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4
Método de muestreo	Muestreo secuencial. ADC sencillo
Rango de muestreo	128 SPS / 256 SPS (2048 Hz internos)
Resolución de EEG	14 bits 1 LSB = 0.51 μ V (ADC de 16bits, 2 bits para descartar ruido de instrumental) se puede aumentar a 16 bits
Ancho de banda	0.2 - 45Hz, filtro notch digital a 50Hz y 60Hz
Filtrado	Construido en 5to orden digital
Rango dinámico (entrada referida)	8400 uV (pp)
Modo de acoplamiento	AC acoplado
Conectividad	Exclusivo inalámbrico 2.4GHz, BLE y USB (sólo extendido)
Capacidad de batería	Batería LiPo 680 mAh
Vida de batería	12 h

Medición de impedancia	Calidad de contacto en tiempo real mediante sistema patentado
Acelerómetro	3 ejes (± 8 g)
Giroscopio	3 ejes (± 2000 °/s)
Magnetómetro	3-axis (± 12 G)
Muestreo en movimiento	32 / 64 / 128 Hz (Definido por usuario)
Resolución en movimiento	14/16 bits (Definido por usuario)
Material de sensor	Ag/AgCl + Filtro + Salina

3.5 Procesamiento de la señal

A fin de ilustrar el funcionamiento de la metodología propuesta, se propone el análisis de una señal por medio de la EMD, a fin separar la señal en bandas conteniendo las distintas frecuencias que hay en ella. Para tal fin, se emplea una señal sintética, que está conformada por la suma de 3 señales senoidales

$$x(t) = \sum_{i=1}^3 \sin(2\pi f_i t) \quad (3.1)$$

con frecuencias f_i de 10, 50 y 100 Hz, durante 4 segundos con una frecuencia de muestreo de 1000 Hz, obteniendo 4000 muestras. La señal resultante se muestra en la Figura 3.4.

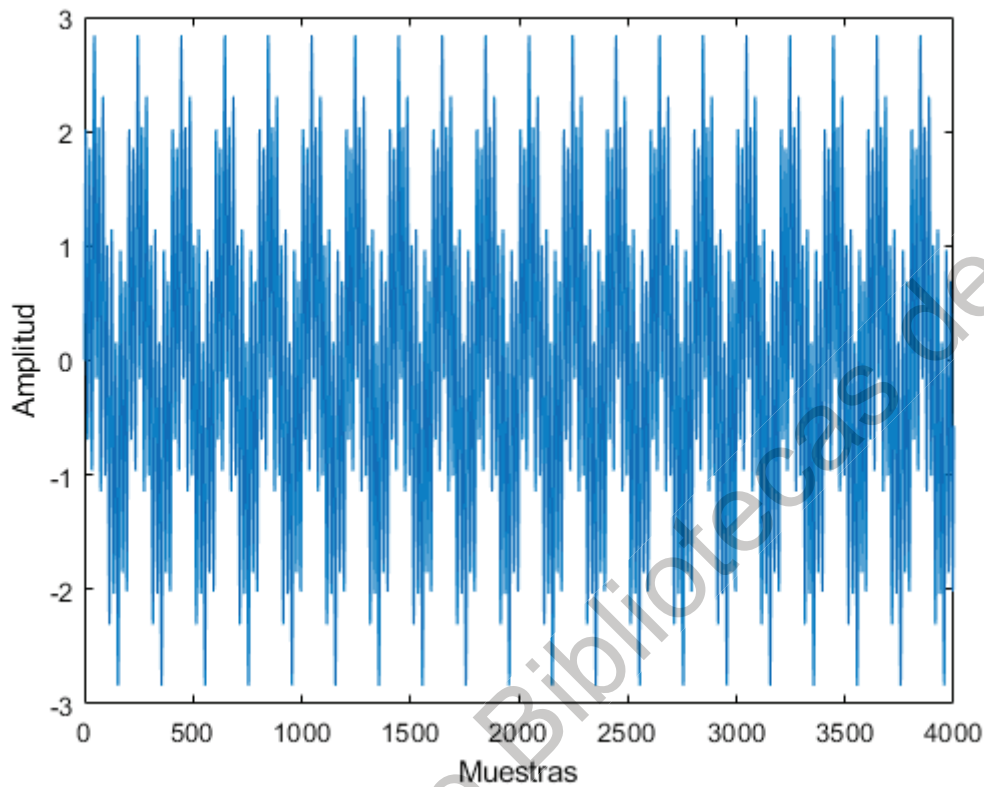


Figura 3.5. Señal muestra conformada por 3 frecuencias distintas

A esta señal se le aplicó la EMD, con la finalidad de descomponer ésta las componentes fundamentales. La Figura 3.5 muestra las descomposiciones obtenidas, donde se observa que de las 6 IMFs, en las primeras 3 están contenidas las frecuencias en orden descendente en relación a la frecuencia de cada componente; es decir, la IMF 1 tiene la componente de 100 Hz, la IMF 2 la de 50 Hz y la IMF 3 la de 10 Hz. Esto se debe a que la EMD descompone según el número de oscilaciones que la señal tenga, por lo que las señales de alta frecuencia, al tener más oscilaciones, salen primero (Perez-Ramirez et al., 2019). Las IMFs restantes constituyen el ruido de la interpolación, por lo que no tienen un significado físico y pueden ser descartadas.

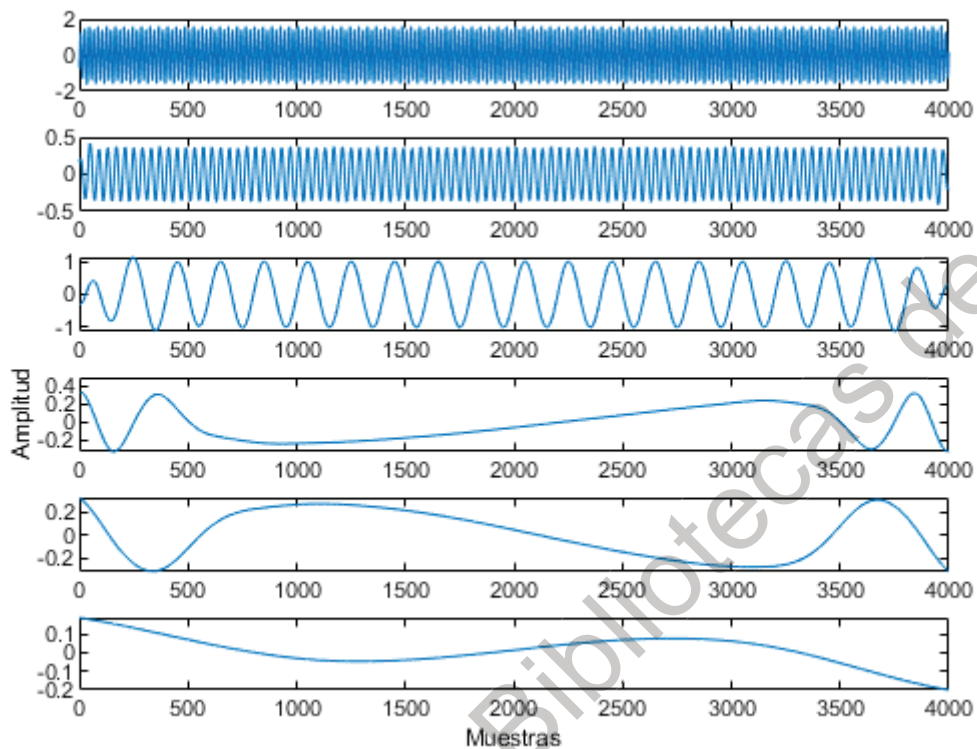


Figura 3.6. IMFs obtenidas de la señal prueba.

A fin de validar la hipótesis de que, al cambiar la complejidad de la señal, cambia la entropía de la misma, se generaron las señales de las Figuras 3.6(a) y 3.6(b). La primera es una señal con frecuencia constante de 50 Hz durante 1 minuto, mientras que la segunda toma como base la señal previa a la que se generan interrupciones cada 0.2 minutos hasta alcanzar 1 minuto. Ambas señales emplean una frecuencia de muestreo de 1000 Hz, obteniendo 1000 muestras.

En el primer caso, tras realizar el cálculo se obtuvo una entropía de Shannon de 2.5219 y en el segundo caso se obtuvo un valor de 2.1797. Al remontarse a la definición de entropía, que habla en palabras sencillas de la cantidad de bits necesarios para representar una señal, se comprueba entonces que, a misma frecuencia y misma amplitud, el valor de la entropía disminuye con los espacios en los que la frecuencia de 50 Hz no se encuentra, es decir, en dicha

señal el valor disminuye puesto que requiere menor cantidad de bits para representar la señal.




Figura 3.7. (a) Señal de 50 Hz constantes durante 2 minutos, (b) Señal de 50 Hz interrumpidos.

CAPÍTULO IV

Pruebas y Resultados

4.1 Puesta de experimento

La prueba para obtener las señales consistió en colocar una pantalla frente a los participantes. Dicha pantalla como se ilustra en la Figura 4.1, mostraba en primera instancia un vacío, representando el reposo, tras 10 segundos la pantalla mostraba una flecha apuntando a la derecha durante 10 segundos, con la finalidad de lograr estimular el pensamiento de derecha en el individuo. Posteriormente se mostraba la pantalla de reposo durante otros 10 segundos, al finalizar estos 10 segundos la pantalla mostró una flecha apuntando a la izquierda representando el estímulo de la izquierda. Se realizó dicho procedimiento repetidamente hasta completar 8.25 minutos.




Figura 4.1. Pantalla mostrada a los participantes.

4.2 Resultados

Como se describió en la metodología durante el capítulo anterior, las señales EEG son tratadas con la técnica de EMD, la cual descompone la señales en 7 IMFs para cada canal o sensor como se muestra en la Figura 4.2. Resultando a la vista, más útiles algunas IMFs de ciertos sensores que algunas que no poseen información distinguible. Dichas IMFs fueron sometidas a las técnicas de entropía de Shannon y entropía de Permutación, esta última sin valores numéricos con los que se pueda distinguir entre las etapas de reposo, izquierda y derecha. En el caso de la entropía de Shannon, los sensores 7 y 12,

en sus IMFs 6 y 5 respectivamente, presentaron valores tras el análisis ANOVA valores cercanos a cero en las entropías de Shannon en cuanto a diferencia de reposo, izquierda y derecha, por lo que se decidió trabajar inicialmente con ellos.




Figura 4.2. Descomposición de la señal en IMFs

En la Tabla 4.1 se muestran los valores de entropía de Shannon de todas las IMFs a partir de la cual se decidieron utilizar las previamente mencionadas.

Sensor	IMF	Valor P
1	1	0.6484
	2	0.3294
	3	0.7343
	4	0.8426
	5	0.895
	6	0.908
	7	0.8718
2	1	0.6863
	2	0.7264
	3	0.9498
	4	0.8124
	5	0.0599

	6	0.8468
	7	0.8448
3	1	0.8525
	2	0.497
	3	0.2713
	4	0.3509
	5	0.6863
	6	0.7278
	7	0.4605
4	1	0.0522
	2	0.5394
	3	0.0848
	4	0.0527
	5	0.7045
	6	0.4762
	7	0.7552
5	1	0.8992
	2	0.9036
	3	0.9121
	4	0.9916
	5	0.9404
	6	0.9443
	7	0.726
6	1	0.4181
	2	0.5373
	3	0.1345
	4	0.3772
	5	0.0831
	6	0.352
	7	0.6362
7	1	0.6816
	2	0.9984
	3	0.2125
	4	0.6096
	5	0.1663
	6	0.0123
	7	0.8797
8	1	0.5882
	2	0.4587
	3	0.4648
	4	0.8245
	5	0.2253
	6	0.8614
	7	0.2991
9	1	0.8574
	2	0.087
	3	0.0743

	4	0.1686
	5	0.1524
	6	0.5623
	7	0.5069
10	1	0.4492
	2	0.1063
	3	0.6509
	4	0.3072
	5	0.8886
	6	0.6173
	7	0.8719
11	1	0.9039
	2	0.4636
	3	0.6683
	4	0.7709
	5	0.8399
	6	0.5667
	7	0.2477
12	1	0.9604
	2	0.6092
	3	0.8444
	4	0.5763
	5	0.0111
	6	0.4801
	7	0.7064
13	1	0.4152
	2	0.4695
	3	0.2383
	4	0.6579
	5	0.5367
	6	0.4105
	7	0.5739
14	1	0.0795
	2	0.9903
	3	0.4294
	4	0.6872
	5	0.3765
	6	0.2609
	7	0.0207

Tabla 4.1. Valores P obtenidos.

Como se aprecia en la tabla 4.1, se seleccionan las IMFs de los sensores que tienen el menor valor de P . En la tabla 4.2 se presentan los valores de Media y desviación estándar de los sensores 7 y 14 con las IMFs 6 y 5 que respectivamente resultaron útiles

Sensor	IMF	Reposo		Derecha		Izquierda		Valor P	Valor F
		μ	σ	μ	σ	μ	σ		
7	6	9.3085	0.0067	10.2925	0.0072	10.2956	0.0086	0.0123	6.4
12	5	9.3084	0.0071	10.2930	0.0081	10.2919	0.0075	0.0111	6.3

Tabla 4.2. Valores de media, desviación estándar, valores P y valores F (μ : media, σ desviación estándar)

Los datos presentados en la tabla representan los 2 sensores e IMFs que proporcionan valores más útiles, los cuales fueron utilizados para crear el sistema difuso, es decir, a partir de estos valores se establecieron los parámetros y límites. Así mismo se muestran los diagramas de cajas y bigotes en las figuras 4.3(a) y 4.3(b)

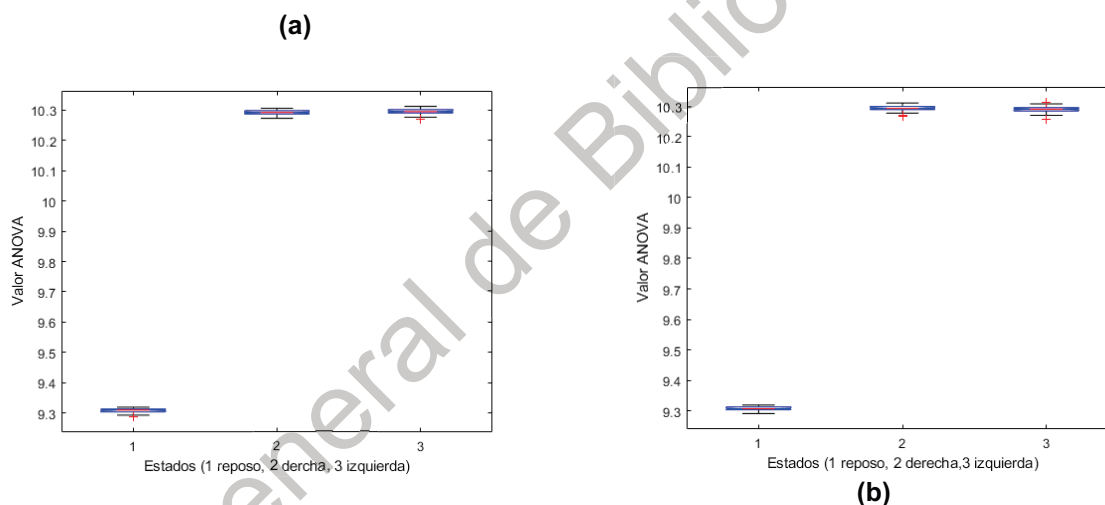


Figura 4.3. Diagrama de cajas y bigotes de sensores 7 y 12, en las IMFs 6 y 5.

A partir de los valores obtenidos y de los sensores 7 y 12 en las IMFs 6 y 5, en el análisis ANOVA, se generaron en el toolbox de Lógica difusa de MATLAB, los correspondientes límites a seguir en la clasificación asignando cada valor superior del diagrama de cajas y bigotes como el valor elegido para representar cada uno de los estados. Posteriormente, se generaron las 5 reglas, las cuales deciden si el valor obtenido entrara en cada uno de los intervalos, incluyendo los

casos en los que el valor recaiga en 2 intervalos, es decir, las reglas deciden por cual estado se inclinará. Las reglas propuestas fueron las siguientes:

- 1) Si entrada 1 es reposo y entrada 2 es reposo, la salida será reposo
- 2) Si la entrada 1 es izquierda y entrada 2 es izquierda, la salida será izquierda
- 3) Si la entrada 1 es derecha y la entrada 2 es derecha, la salida será derecha
- 4) Si la entrada 1 es derecha y la entrada 2 es izquierda, la salida será derecha
- 5) Si la entrada 1 es izquierda y la entrada 2 es derecha, la salida será izquierda

Finalmente, el valor se clasifica en cualquiera de los estados, encontrando cierto grado de error. Para la clasificación final entre reposo, derecha e izquierda, se obtuvo 100%, 40% y 71.76% de eficiencia para cada caso respectivamente y una clasificación global de 70.58%

4.3 Discusión de Resultados

Los valores obtenidos del sistema difuso en forma de porcentaje se observan más claramente en una matriz de confusión, se trata de un arreglo compuesto por entradas y salidas, evaluando el desempeño del algoritmo, donde la tasa de clasificación se estima como:

$$Tasa\ de\ clasificación = \frac{Pruebas\ correctas}{Pruebas\ totales} = \frac{Pruebas\ correctas}{Pruebas\ correctas + Pruebas\ incorrectas} \times 100\% \quad (4.1)$$

	Reposo	Derecha	Izquierda	Porcentaje
Reposo	85	0	0	100%
Derecha	0	34	51	40%

Izquierda	0	24	61	71.76%
Total				70.58%

Tabla 4.3. Matriz de confusión del clasificador desarrollado

Con la matriz de confusión (Tabla 4.3) se observa que el reposo se puede diferenciar en su totalidad de ambos pensamientos tanto izquierdo como derecho. Sin embargo, la clasificación entre izquierda y derecha sufre debido a su cercanía, una confusión, en mayor proporción en el caso de la derecha que de la izquierda. Una hipótesis al respecto que se tiene es que la mayoría de los sujetos de prueba son diestros, dando pauta a mayor desarrollo del pensamiento derecho. Sin embargo, el porcentaje global, es decir el promedio de los 3 estados, es considerablemente bueno, del 70.58%.

A fin de poder posicionar el trabajo desarrollado, la Tabla 4.4 muestra algunos trabajos que realizaron la clasificación de imaginación motora, la metodología que emplean y la eficiencia del clasificador

Trabajo	Metodología utilizada	Porcentaje de clasificación
Naseer et al. (2013)	Adquisición de señales mediante Espectroscopia funcional de Infrarrojo (fNIRS) Clasificación mediante Analisis Lineal de Discriminantes (LDA)	73.35%
Hsu et al. (2015)	Se obtuvieron características a partir de wavelet fuzzy approximate entropy (wfApEn) Se clasificaron las señales mediante Máquinas de soporte de Vectores (SMV)	88.2%
Pattnaik et al. (2016)	Clasificador por red neuronal	78.57%
Chatterjee et al. (2016)	Extracción de características mediante Wavelet Clasificador a través de Maquinas de	85% y 85.71%

	soporte de Vectores (SMV) y Perceptrón Multicapa (MLP)	
Ma et al. (2016)	Características obtenidas mediante Inicialización de Enjambre de Partículas Se clasifica utilizando Máquinas de soporte de Vectores (SMV)	89.7%
Trabajo actual	Entropía de Shannon como extractor de características Clasificador de Lógica difusa	70.58%

Tabla 4.4. Diversas metodologías empleadas para la clasificación de señales de imaginación motora.

En la literatura se puede encontrar una efectividad de 80% en clasificación motora (Quin et al., 2004), pero ésta se logró de manera invasiva, es decir, obteniendo las señales de la corteza cerebral. En otro caso Pattnaik et al. (2016) logró mediante una red neuronal una clasificación del 80.71%, pero utilizó agregado a la desviación estándar y la potencia pico, dándole mayor certeza a su discriminación de la señal. Adicionalmente, los trabajos de Chatterjee et al. (2016) y Ma et al. (2016) obtienen eficiencias similares, a costa de emplear algoritmos con una mayor carga computacional. Esta situación provoca que dichas metodologías requieran de un mayor trabajo de adopción para poder ser ejecutadas en una plataforma de cómputo en tiempo real, en el mejor de los escenarios, o bien, el no poder ser ejecutadas. En este sentido, el presente trabajo emplea la EMD, que es conocida por ser una técnica de cómputo eficiente (Perez-Ramirez et al., 2019), lo que hace que la señal pueda ser procesada rápidamente.

En conclusión, la mayor ventaja del trabajo presente es que, aunque el nivel de clasificación no es el mayor, se trata de un sistema ligero, es decir, de rápida respuesta y no requerir de algoritmos de procesamiento que no requieren excesivo tiempo para extraer las características necesarias, a diferencia de los trabajos presentes que pueden llegar a durar hasta días enteros procesando, el experimento aquí presentado, realiza el procesamiento en algunos segundos, lo que lo hace más viable, por ejemplo, para aplicaciones en tiempo real.

CAPÍTULO V

Conclusiones y Prospectivas

5.1 Conclusiones

Tras los resultados obtenidos se puede concluir que se logró el objetivo planteado inicialmente, pues se consiguió que durante un estudio de electroencefalografía en el que se realice pensamiento de izquierda, derecha y reposo en distintos lapsos se diferencie entre ellos, es decir, el algoritmo distingue en un 70.58% estas señales, un porcentaje muy alto considerando que en la sección de reposo se consiguió clasificar el 100%, mientras que en izquierda un 71.76% y en el caso de derecha un 40%. En comparación con algunos otros proyectos de imaginación motora, la efectividad presentada en este trabajo es bastante buena, como el caso de Hong et al. 2015, quien logró una clasificación con efectividad del 75.6%, este tenía un sistema de adquisición llamado Functional near-infrared spectroscopy (fNIRS) que es mucho más exacto al momento de recibir las señales cerebrales, por lo que se puede decir que el sistema de clasificación utilizado en este trabajo es muy completo, puesto que el sistema de adquisición es más ligero, obteniendo buenos resultados.

En la literatura se puede encontrar una efectividad de 80% en clasificación motora (Quin et al., 2004), pero esta se logró de manera invasiva, es decir, obteniendo las señales de la corteza cerebral, o bien incrementando la cantidad de variables que deben ser obtenidas para mejorar el resultado del clasificador. Por el contrario, el presente trabajo emplea técnicas de procesamiento de señales eficientes, que permiten obtener resultados muy similares a los obtenidos en este trabajo, teniendo como ventaja el poder ser ejecutada en un sistema de procesamiento de señales en tiempo real.

5.2 Prospectivas

Se propone, a modo de mejorar la obtención de datos un sistema de adquisición más robusto que el casco EMOTIV. Agregar algún otro método o cambiar alguno de los previamente utilizados para acentuar las diferencias entre

cada uno de los 3 estados, así como el realizar más pruebas que permitan al algoritmo tener más datos para hacerlo más efectivo, así como utilizar algunos otros parámetros además de la entropía de Shannon y el análisis ANOVA.

Dirección General de Bibliotecas de la UAQ

Referencias

Amezquita-Sanchez, J. P., Adeli, A., & Adeli, H. (2016). A new methodology for automated diagnosis of mild cognitive impairment (MCI) using magnetoencephalography (MEG). *Behavioural Brain Research*, 305, 174-180.

Amezquita-Sanchez, J. P., Valtierra-Rodriguez, M., Perez-Ramirez, C. A., Camarena-Martinez, D., Garcia-Perez, A., & Romero-Troncoso, R. J. (2017). Fractal dimension and fuzzy logic systems for broken rotor bar detection in induction motors at start-up and steady-state regimes. *Measurement Science and Technology*, 28(7), 075001.

Batres-Mendoza, P., Montoro-Sanjose, C. R., Guerra-Hernandez, E. I., Almanza-Ojeda, D. L., Rostro-Gonzalez, H., Romero-Troncoso, R. J., & Ibarra-Manzano, M. A. (2016). Quaternion-Based Signal Analysis for Motor Imagery Classification from Electroencephalographic Signals. *Sensors*, 16(3), 336.

Camarena-Martinez, D., Amezquita-Sanchez, J. P., Valtierra-Rodriguez, M., Romero-Troncoso, R. J., Osornio-Rios, R. A., & Garcia-Perez, A. (2014). EEMD-MUSIC-Based Analysis for Natural Frequencies Identification of Structures Using Artificial and Natural Excitations. *The Scientific World Journal*, 2014, 1-12.

Camarena-Martinez, D., Valtierra-Rodriguez, M., Amezquita-Sanchez, J. P., Granados-Lieberman, D., Romero-Troncoso, R. J., & Garcia-Perez, A. (2016). Shannon Entropy and K-Means Method for Automatic Diagnosis of Broken Rotor Bars in Induction Motors Using Vibration Signals. *Shock and Vibration*, 2016, 1-10.

Carrasco Gonzaga, A. (2019). Desarrollo de un sistema de adquisición y procesamiento basado en la transformada de Fourier y LabVIEW para señales eléctricas cardiacas. Tesis de Licenciatura. Universidad Autónoma de Querétaro.

Chatterjee, R., & Bandyopadhyay, T. (2016). EEG Based Motor Imagery Classification Using SVM and MLP. *2016 2nd International Conference on Computational Intelligence and Networks (CINE)*.

Cruz Ramírez, H. (2018). Metodología basada en la Descomposición Empírica de Modos Completa y Fractales para la Clasificación de Imaginación Motora usando Señales Electroencefalográficas. Tesis de Licenciatura. Universidad Autónoma de Querétaro.

Fundación Materialización 3D (2017), <http://www.m3dmadrid.com/proyectos/protesis-3d/protesis-mio-electrica/tipos-de-protesis/>, Tipos de prótesis.

Guillot, A., & Collet, C. (2010) *The Neurophysiological Foundations of Mental and Motor Imagery*. OUP Oxford.

bert, . (1 0 . Cahors impr. de Coueslant.

Hsu, W. (2015). Assembling A Multi-Feature EEG Classifier for Left–Right Motor Imagery Data Using Wavelet-Based Fuzzy Approximate Entropy for Improved Accuracy. *International Journal of Neural Systems*, 25(08), 1550037.

Hsu, W., & Sun, Y. (2009). EEG-based motor imagery analysis using weighted wavelet transform features. *Journal of Neuroscience Methods*, 176(2), 310-318.

Huang, N., Shen, Z., Long, S., Wu, M., Shih, H., Zheng, Q., Yen, N., Tung, C., & Liu, H. (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. Gran Bretaña: The Royal Society.

Jimenez Arthur, A. M. (2015). Sistema de visión artificial basado en termografía para segmentación automática y detección de puntos críticos en la planta del pie, Tesis de Maestría, Repositorio de la Universidad Autónoma de Querétaro.

Li, X., Ouyang, G., & Richards, D. A. (2007). Predictability analysis of absence seizures with permutation entropy. *Epilepsy Research*, 77(1), 70-74.

Lemus-Lopez, R., Gómez-López, W., Ayaquica-Martínez, I., Guillén-Galván, C. (2014). Electrode Selection Based on k-means for Motor Activity Classification in EEG. *Revista Mexicana de Ingeniería biomédica*, 35.

Ma, Y., Ding, X., She, Q., Luo, Z., Potter, T., & Zhang, Y. (2016). Classification of Motor Imagery EEG Signals with Support Vector Machines and Particle Swarm Optimization. *Computational and Mathematical Methods in Medicine*, 2016, 1-8.

Martin, J. (2000). Implementación de Redes Neuro-Difusas Para Per Aplicadas en Problemas de Clasificación Y Modelización. España: Universal Publishers.

Nason, G. (2008). *Wavelet methods in statistics with R*. New York, NY: Springer.

Naseer, N., & Hong, K. (2013). Classification of functional near-infrared spectroscopy signals corresponding to the right- and left-wrist motor imagery for development of a brain-computer interface. *Neuroscience Letters*, 553, 84-89.

Pacheco Rubio, L. E. (2019). Dispositivo detector de Glucosa no Invasivo instrumentado con Electrodo Serigrafados Modificados con la Enzima Glucosa Oxidasa. Tesis de Licenciatura. Universidad Autónoma de Querétaro.

Pattnaik, S., Dash, M., & Sabut, S. K. (2016). DWT-based feature extraction and classification for motor imaginary EEG signals. *2016 International Conference on Systems in Medicine and Biology (ICSMB)*.

Perez-Ramirez, C. A., Amezquita-Sanchez, J. P., Valtierra-Rodriguez, M., Adeli, H., Dominguez-Gonzalez, A., & Romero-Troncoso, R. J. (2019). Recurrent neural network model with Bayesian training and mutual information for response prediction of large buildings. *Engineering Structures*, 178, 603-615.

Pérez Sánchez, A. V. (2019). Metodología basada en la transformada wavelet y fractales para la detección anticipada de eventos epilépticos. Tesis de Licenciatura. Universidad Autónoma de Querétaro.

Piedra, J. (2008). Aplicación de los sistemas neurodifusos a la interpretación automática de imágenes de satélite. España: Universidad de Almería.

Pfurtscheller, G., & Neuper, C. (2001). Motor imagery and direct brain-computer communication. *Proceedings of the IEEE*, 89(7), 1123-1134.

Pfurtscheller, G., Neuper, C., Schlogl, A., & Lugger, K. (1998). Separability of EEG signals recorded during right and left motor imagery using adaptive autoregressive parameters. *IEEE Transactions on Rehabilitation Engineering*, 6(3), 316-325.

Qin, L., & He, B. (2005). A wavelet-based time-frequency analysis approach for classification of motor imagery for brain-computer interface applications. *Journal of Neural Engineering*, 2(4), 65-72.

Qin, L., Kamousi, B., Liu, Z., Ding, L., & He, B. (n.d.). Classification of Motor Imagery Tasks by means of Time-Frequency-Spatial Analysis for Brain-Computer Interface Applications. *Conference Proceedings. 2nd International IEEE EMBS Conference on Neural Engineering, 2005*.

Rowan, A. J., & Tolunsky, E. (2004). *mini-atlas*. Madrid (etc.): Elsevier.

Torres-García, A.A., Reyes-García, C.A., Villaseñor-Pineda, L., & Ramírez-Cortés, J.M. (2013). Análisis de señales electroencefalográficas para la clasificación de habla imaginada. *Revista mexicana de ingeniería biomédica*, 34(1), 23-39.

Vazquez Rodríguez, P. (2013). Evaluación termográfica del pie diabético y su asociación con la retinopatía diabética, Tesis de Maestría, Repositorio de la Universidad Autónoma de Querétaro.

Vázquez Vela, E., (2015). Los amputados, un reto para el estado. Academia Nacional de Medicina, (9 paginas).

Vázquez, B., Bergasa., L., Navarro, B., & Garcia, R. (1998). Control neuronal de los movimientos de una silla de ruedas. V seminario anual de automática, electrónica, industrial e instrumentación, Pamplona.

Vega Mancilla, S. Y. (2016). Procesamiento de imágenes termográficas en la detección de cáncer de mama, Tesis de Maestría, Repositorio de la Universidad Autónoma de Querétaro.

Velásquez-Martínez, L. F., Álvarez-Meza, A. M., & Castellanos-Domínguez, C. G. (2013). Motor Imagery Classification for BCI Using Common Spatial Patterns and Feature Relevance Analysis. *Natural and Artificial Computation in Engineering and Medical Applications Lecture Notes in Computer Science*, 365-374.

Xu, B., & Song, A. (2008). Pattern Recognition of Motor Imagery EEG using Wavelet Transform. *Journal of Biomedical Science and Engineering*, 01(01), 64-67.

Zafar, A., Khan, M. J., & Hong, K. (2017). Classification of prefrontal and motor cortex initial dips for fNIRS-based-BCI. *2017 International Automatic Control Conference (CACS)*.