



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Ingeniería Biomédica



**Metodología basada en la transformada wavelet y fractales para
la clasificación de la imaginación motora**

TESIS

Que como parte de los requisitos para obtener el título de
Ingeniero Biomédico línea terminal en Bioseñales y
Bioinstrumentación.

Presenta:

Karla Daniela Montes Martínez

Dirigida por:

Dr. Juan Pablo Amézquita Sánchez

Dr. Carlos Andrés Pérez Ramírez

Santiago de Querétaro, Qro, Julio del 2019



Universidad Autónoma de Querétaro

Facultad de Ingeniería

Ingeniería Biomédica



"Metodología basada en la transformada wavelet y fractales para la clasificación de la imaginación motora"

Tesis

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

Presenta:

Karla Daniela Montes Martínez

Dirigido por:

Dr. Juan Pablo Amézquita Sánchez

Dr. Carlos Andrés Pérez Ramírez

Dr. Juan Pablo Amézquita Sánchez
Presidente



Firma

Dr. Carlos Andrés Pérez Ramírez
Secretario




Firma

Ing. Eduardo Martínez Segoviano
Vocal



Firma

Dr. Martín Valtierra Rodríguez
Suplente



Firma

Centro Universitario
Querétaro, Qro.
Julio 2019

RESUMEN

La falta de alguna extremidad ya sea por nacimiento, por enfermedad o por accidentes, es un factor limitante para que un individuo se pueda desarrollar en la sociedad de manera normal, conllevando a que su calidad de vida se vea mermada, es por ello, que con el fin de atender y ayudar a esta problemática se planteó la presente tesis, la cual tiene como fin la clasificación en tres estados mentales mediante la imaginación motora y así usar estas clasificaciones para lograr un determinado movimiento en un actuador.

Gracias a los avances en las técnicas de procesamiento de señales de encefalografía (EEG) es posible extraer de ellas propiedades como amplitud y frecuencia, las cuales son de ayuda para realizar análisis y clasificación de dichas señales. Para el desarrollo de esta tesis se plantea una metodología basada en la transformada wavelet de paquetes, fractales (Katz, Higuchi y conteo de cajas), un análisis estadístico conocido como análisis de varianzas ANOVA y, por último, el uso de redes neuronales (perceptron multicapa) para clasificar la imaginación motora en tres estados mentales.

Palabras clave: Imaginación motora, procesamiento de señales, transformada wavelet, fractales, redes neuronales.

DEDICATORIA

Con todo mi amor dedico esta tesis a mi mamá Rosalia Martínez por sus cuidados, su amor, por alentarme y apoyarme en todas mis decisiones, a mis hermanas Ivonne e Itzel, las cuales me han apoyado y han estado a mi lado siempre alentándome y dándome ánimos para cumplir mis sueños.

A mis abuelos maternos Petra Martínez (Q.E.P.D.), y Eliodoro Martínez (Q.E.P.D.), a quienes agradezco su amor y cuidados que me brindaron siempre procurando mi felicidad mientras crecía.

AGRADECIMIENTOS

Agradezco a mi madre Rosalia, que siempre creyó en mi y sin la cual no hubiera podido concluir esta importante etapa de mi vida, gracias porque durante estos años estuviste ahí con todo tu amor y cariño procurando que nada me faltara y siempre tuviera todo lo necesario para terminar mis estudios.

Agradezco a mi padre Carlos por su ayuda y apoyo brindado para poder culminar mis estudios.

Agradezco a mis hermanas, Ivonne e Itzel, las cuales hicieron más amenos estos años con sus risas y bromas, también les agradezco sus palabras de aliento cuando las requerí.

A mi tía Ana, la cual estuvo siempre presente en esta etapa apoyandome para seguir adelante. Agradezco a mi prima Monse, quien compartió conmigo sus experiencias y consejos para lograr esta meta. A su esposo Rodrigo, quien siempre me tendió la mano para ayudarme.

A Mario, quien me brindo su cariño y apoyo para culminar esta etapa, siempre alentándome a superar los obstáculos que se presentaron y nunca dejar que me rindiera.

A mi tío José agradezco sus consejos, enseñanzas y experiencias para ser una buena ingeniera biomédica.

A mi asesor el Dr. Juan Pablo Amézquita Sánchez y mis sinodales Dr. Carlos Andrés Pérez Ramírez, Dr. Martín Valtierra Rodríguez y el Ing. Eduardo Martínez Segoviano por su apoyo, consejos y tiempo para el desarrollo de esta tesis.

ÍNDICE GENERAL

RESUMEN	II
DEDICATORIA	III
AGRADECIMIENTOS	IV
Índice General	V
Índice de Figuras	VII
Índice de Tablas	IX
CAPÍTULO 1	1
1.1. Introducción	2
1.2. Antecedentes	3
1.3. Descripción del Problema	5
1.4. Justificación	6
1.5. Hipótesis	6
1.6. Objetivos	7
1.6.1. Objetivo General	7
1.6.2. Objetivos Particulares	7
1.7. Planteamiento general	8
CAPÍTULO 2	10
2.1. Revisión de la literatura	11
2.2. Señales EEG	11
2.2.1 Tipo de sensores para monitorear señales EEG	12
2.3. Procesamiento Digital de Señales	15
2.3.1. MATLAB	15
2.3.2. Transformada Wavelet	16
2.3.2.1 Transformada Wavelet Discreta	17
2.3.2.2 Transformada Wavelet de Paquetes	18
2.3.3. Dimensión Fractal	19
2.3.3.1. Algoritmo de Katz	20
2.3.3.2. Algoritmo de Higuchi	20
2.3.3.3. Algoritmo dimensión de caja	21
2.3.4. ANOVA	22
2.3.5. Clasificador basado en Redes Neuronales	22

2.4. Microcontrolador Arduino	23
CAPÍTULO 3	25
3.1. Metodología	26
3.2 Casco EMOTIV	28
3.3 Material	30
3.4. Procesamiento de señales EEG	31
3.5. Actuador	33
CAPÍTULO 4	35
4.1. Puesta de Experimento	36
4.2. Resultados	37
4.3. Discusión de Resultados	62
CAPÍTULO 5	64
5.1. Conclusiones	65
5.2. Prospectivas	65
REFERENCIAS	66
ANEXOS	71

ÍNDICE DE FIGURAS

Figura 1.1. Planteamiento general	8
Figura 2.1. Sensores de superficie	14
Figura 2.2. Sensores de subdurales	15
Figura 2.3. MATLAB	16
Figura 2.4. Algoritmo de Mallat	17
Figura 2.5. TWP	18
Figura 2.6. Perceptrón Multicapa.	23
Figura 2.7. Placas Arduino	24
Figura 3.1. Metodología propuesta	26
Figura 3.2. Casco EMOTIV	28
Figura 3.3. Ubicación de electrodos de la diadema EMOTIV	29
Figura 3.4. Señales EEG de la zona Parietal (Sensor P7) para (a) reposo, (b) pensamiento a la izquierda y (c) pensamiento a la derecha	30
Figura 3.5. Señal sintética	31
Figura 3.6. Bandas de frecuencia estimadas del nivel 2	32
Figura 3.7. Brazo mecánico	34
Figura 3.8. Script de la conexión serial del Arduino programada desde Matlab	34
Figura 4.1. Puesta de experimento: Señales visuales con esquema de tiempo	36
Figura 4.2. Puesta de experimento. Movimiento actuador.	37
Figura 4.3. Nodo 1: Banda de Frecuencia (0-2 Hz)	38
Figura 4.4. Nodo 2: Banda de Frecuencia (2-4 Hz)	39
Figura 4.5. Nodo 3: Banda de Frecuencia (4-6 Hz)	39
Figura 4.6. Nodo 4: Banda de Frecuencia (6-8 Hz)	40
Figura 4.7. Nodo 5: Banda de Frecuencia (8-10 Hz)	40
Figura 4.8. Nodo 6: Banda de Frecuencia (10-12 Hz)	41
Figura 4.9. Nodo 7: Banda de Frecuencia (12-14 Hz)	41
Figura 4.10. Nodo 8: Banda de Frecuencia (14-16 Hz)	42
Figura 4.11. Nodo 9: Banda de Frecuencia (16-18 Hz)	42
Figura 4.12. Nodo 10: Banda de Frecuencia (18-20 Hz)	43
Figura 4.13. Nodo 11: Banda de Frecuencia (20-22 Hz)	43

Figura 4.14. Nodo 12: Banda de Frecuencia (22-24 Hz)	44
Figura 4.15. Nodo 13: Banda de Frecuencia (24-26 Hz)	44
Figura 4.16. Nodo 14: Banda de Frecuencia (26-28 Hz)	45
Figura 4.17. Nodo 15: Banda de Frecuencia (28-30 Hz)	45
Figura 4.18. Nodo 16: Banda de Frecuencia (30-32 Hz)	46
Figura 4.19. Nodo 17: Banda de Frecuencia (32-34 Hz)	46
Figura 4.20. Nodo 18: Banda de Frecuencia (34-36 Hz)	47
Figura 4.21. Nodo 19: Banda de Frecuencia (36-38 Hz)	47
Figura 4.22. Nodo 20: Banda de Frecuencia (38-40 Hz)	48
Figura 4.23. Nodo 21: Banda de Frecuencia (40-42 Hz)	48
Figura 4.24. Nodo 22: Banda de Frecuencia (42-44 Hz)	49
Figura 4.25. Nodo 23: Banda de Frecuencia (44-46 Hz)	49
Figura 4.26. Nodo 24: Banda de Frecuencia (46-48 Hz)	50
Figura 4.27. Nodo 25: Banda de Frecuencia (48-50 Hz)	50
Figura 4.28. Nodo 26: Banda de Frecuencia (50-52 Hz)	51
Figura 4.29. Nodo 27: Banda de Frecuencia (52-54 Hz)	51
Figura 4.30. Nodo 28: Banda de Frecuencia (54-56 Hz)	52
Figura 4.31. Nodo 29: Banda de Frecuencia (56-58 Hz)	52
Figura 4.32. Nodo 30: Banda de Frecuencia (58-60 Hz)	53
Figura 4.33. Nodo 31: Banda de Frecuencia (60-62 Hz)	53
Figura 4.34. Nodo 32: Banda de Frecuencia (62-64 Hz)	54
Figura 4.35. Sensor 1 nodo 19. 1: Reposo, 2: Izquierda y 3: Derecha	55
Figura 4.36. Sensor 2 nodo 3. 1: Reposo, 2: Izquierda y 3: Derecha	55
Figura 4.37. Sensor 3 nodo 5. 1: Reposo, 2: Izquierda y 3: Derecha	56
Figura 4.38. Sensor 4 nodo 18. 1: Reposo, 2: Izquierda y 3: Derecha	56
Figura 4.39. Sensor 6 nodo 25. 1: Reposo, 2: Izquierda y 3: Derecha	57
Figura 4.40. Sensor 9 nodo 30. 1: Reposo, 2: Izquierda y 3: Derecha	57
Figura 4.41. Sensor 10 nodo 21. 1: Reposo, 2: Izquierda y 3: Derecha	58
Figura 4.42. Sensor 11 nodo 9. 1: Reposo, 2: Izquierda y 3: Derecha	58
Figura 4.43. Sensor 14 nodo 31. 1: Reposo, 2: Izquierda y 3: Derecha	59
Figura 4.44 Comportamiento del efector final (a) reposo, (b) apertura y (c) izquierda	61

ÍNDICE DE TABLAS

Tabla 2.1. Características de la Arduino modelo UNO	24
Tabla 3.1. Valores de fractalidad de cada nodo con las 3 técnicas	32
Tabla 4.1 Resultados ANOVA para el algoritmo, sensores y nodos más discriminativos	60
Tabla 4.2 Matriz de confusión	62

Dirección General de Bibliotecas de la UAQ

CAPÍTULO 1

Dirección General de Bibliotecas de la UAQ

1.1 INTRODUCCIÓN

Hoy en día, un gran número de la población mexicana sufre algún tipo de discapacidad por diferentes causas, ya sea por enfermedad, edad avanzada, nacimiento o accidentes, afectando la calidad de vida de quien la padece. En el año 2014 el INEGI reportó en la Encuesta Nacional de la Dinámica Demográfica, que de una población total de 119,990,073 habitantes 23,069,830 padecen de alguna discapacidad o limitación entre las que se encuentran problemas visuales (aunque se use lentes), aprender, recordar o concentrarse, escuchar (aunque se use aparato auditivo), bañarse, vestirse o comer, hablar o comunicarse, problemas emocionales o mentales, dificultad para mover o usar brazos o manos, así como para caminar, subir o bajar usando sus piernas. Dentro de esta cifra 6, 975,016 habitantes tienen discapacidad o limitaciones en extremidades (INEGI, 2014).

La pérdida de alguna extremidad como lo es un brazo o una pierna siempre ocasiona que el individuo vea limitada su capacidad de movimiento y de acción, de igual manera se ve afectado emocionalmente debido a la falta de dicha extremidad (Santillán, 2014). Con el tiempo los avances en la tecnología en los campos de la robótica aplicados a la medicina, en particular de la biónica, han proporcionado al ser humano extremidades complementarias que cada día se perfeccionan (Dorador et al. 2004).

El cerebro es, sin duda, el objetivo último de la mayoría de los implantes como lo son las prótesis, dado que muchos de los trastornos motores, de audición o de visión están causados por la disfunción o carencia de las redes nerviosas que conectan el cerebro al resto del cuerpo. Como consecuencia, las órdenes neuronales no llegan a su destino causando una pérdida en la realización de las funciones (García et al. 2004). Por lo tanto, a partir de su condición de ordenador central, el interés en establecer comunicación directa entre el cerebro y otros dispositivos externos que usan señales producidas por el cerebro tales como electroencefalográficas (EEG) o magnetoencefalográficas (MEG), ha aumentado con el uso de sistemas de interfaz cerebro-computadora (BCI).

Según Wolpaw et al. (2000), "*las interfaces BCI permiten registrar las señales cerebrales de un individuo, extraer sus características y convertirlas en salidas artificiales que operan en el exterior o en su propio cuerpo*". En otras palabras, la interfaz establece un canal de comunicación y control entre un individuo y un dispositivo externo. En consecuencia, un análisis avanzado de las señales provenientes del cerebro y la imaginación motora es de gran interés, con el fin de permitirle al individuo poder realizar diversas tareas, como controlar una prótesis operativa, entre otras tareas (Mendoza et al. 2016).

1.2 ANTECEDENTES

En los últimos años, diversas investigaciones tanto a nivel internacional, nacional y local han incursionado en el área del análisis de señales EEG para el desarrollo de interfaz cerebro computador e imaginación motora.

Por ejemplo, a nivel internacional, Pfurtscheller et al. (2005) empleó un filtrado de señales EEG para la clasificación de la imaginación motora de la apertura y cerrado de una mano. El filtro del tipo pasa banda se emplea para la extracción de la banda beta (15-19 Hz) donde un umbral de la señal fue fijado en base a las pruebas. Cuando la señal filtrada excede el umbral predefinido, se generó un disparador de una secuencia de agarre. Así lograron la restauración no invasiva de la función de agarre manual del paciente, logrando el agarre de un vaso con la mano paralizada completamente solo. Arboleda et al. (2009) presentó una metodología basada en el filtrado de la señal y clasificadores lineales tales como el criterio de Fisher para facilitar la comunicación de personas con discapacidad motora y con problemas de comunicación empleando señales EEG. Los autores reportan una eficiencia del 50% para la clasificación de patrones provenientes de letras. Otro ejemplo del avance en BCI para mejorar la calidad de vida de las personas es el Sistema para Rehabilitación del Síndrome del Miembro Fantasma desarrollado por Arango et al. (2013). Los autores están enfocados en el trabajo para la clasificación de la imaginación motora de dos movimientos: apertura y cerrado de un modelo virtual de una mano (prótesis). Para ello emplean el software Emotiv Pro, el cual contiene herramientas para el procesamiento tales como filtrado de las señales eléctricas del

cerebro. Los autores reportan una eficiencia del 82.1% para la distinción entre los dos patrones antes mencionados. Por otra parte, Bermúdez et al. (2013) presentó una metodología basada en los parámetros de Hjorth y modelos autorregresivos para la clasificación motora de pensamientos hacia la izquierda y derecha. Los autores reportaron un 73.33% de efectividad en poder distinguir estos 2 patrones de pasamiento con los 6 sujetos en todas las sesiones.

En cuanto a trabajos nacionales, Negrete et al. (2014) caracterizó la actividad eléctrica cerebral relacionada con la imaginación del movimiento de la mano, en particular movimiento izquierda y derecha. El registro de EEG inició con una evaluación de la actividad cerebral basal del sujeto, seguido por una serie de pruebas de movimiento de cada una de las manos e imaginación del movimiento de la mano. Las señales EEG adquiridas fueron caracterizadas empleado la transformada de Fourier. Los autores reportan una eficiencia del 73% y 76% para un movimiento izquierdo y derecho, respectivamente a partir de un grupo de 30 sujetos sanos de entre 21 y 30 años, 15 sujetos del género femenino y 15 del género masculino, todos diestros.

A nivel local, 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 la detección temprana de ulceraciones en la planta de los pies basado en el procesamiento de imágenes. Por otro lado, Vega (2016) empleó imágenes termográficas del pecho de mujeres, para detección temprana de cáncer de mama.

Recientemente, Cruz (2018) propuso una nueva metodología basada en la técnica de descomposición de modos empíricos de conjunto completo, teoría del caos y redes neuronales para la clasificación de tres pensamientos: reposo, izquierda y la derecha, reportando una eficiencia de clasificación del 71%. La tesis de Cruz sienta las bases en la UAQ para investigaciones futuras en torno a la clasificación de patrones en señales de EEG; sin embargo, es importante seguir

evaluando/proponiendo otras metodologías que permitan incrementar la eficiencia de clasificación y reducir la cantidad de carga computacional con el fin de que esta sea aplicada para mover un actuador tal como un brazo robótico comercial, lo que complementaría el trabajo de Cruz (2018), donde solamente es analizada la señal EEG. Si bien un brazo robótico es un paso que complementa la tesis de Cruz y en el cual se puede ver la diferencia física entre los diferentes estados de la imaginación motora, existen algunas problemáticas que se podrían encontrar al trabajar con un actuador, como lo es la carga computacional, pues se debe contar con un procesamiento rápido y eficiente, también se debe pensar en una protección para el equipo, ya que pueden existir picos de corriente que dañen el equipo con el que se está trabajando.

1.3 DESCRIPCIÓN DEL PROBLEMA

Gracias a las distintas propiedades de las señales de EEG, como su forma, amplitud, frecuencia, etc., es posible determinar un estado mental asociado a actividades motoras, sensoriales y estados del sueño o de diferentes enfermedades (Bermúdez, 2013). El objetivo principal de las técnicas de procesamiento de señales de EEG, es el de extraer ciertas características a partir de estas propiedades que faciliten luego su clasificación y/o evaluación en diferentes clases. A medida que dichas clases se encuentren estadísticamente más separadas, menor será el error cometido al clasificar las muestras (Bermúdez, 2013). Sin embargo, la extracción de dichas características es una tarea compleja, ya que, por naturaleza, las señales de EEG presentan características no lineales y no estacionarias, además presentan gran variación entre sujetos, o incluso para un mismo sujeto en distintos momentos o estados. Por estas razones, el uso de una técnica de procesamiento que sea capaz de trabajar con este tipo de señales es necesaria (Bermúdez, 2013).

En los últimos años, una gran cantidad de técnicas de procesamiento empleadas para el procesado de señales de EEG es extensa y se encuentra en permanente crecimiento, apareciendo continuamente nuevas técnicas, puesto que las primeras técnicas utilizadas para obtener la potencia del espectro de una señal

como la transformada de Fourier (FFT) requiere que las señales bajo estudio sean estacionarias, por lo cual resulta no eficiente. Como alternativa se puede emplear técnicas tales como la Transformada Wavelet (Bermúdez, 2013). En el procesamiento con wavelet no se asume que la señal procesada es periódica; por lo tanto, es posible representar señales con cambios abruptos y discontinuidades obteniendo descripciones con buena localización tanto en frecuencias como en el tiempo. Por ello, esta técnica de procesamiento es investigada en este trabajo de tesis (Gigola et al. 2004; Tapan Gandhi et al. 2011).

1.4 JUSTIFICACIÓN

Hoy en día, debido a enfermedades, accidentes, edad avanzada e incluso por nacimiento una gran parte de la población en nuestro país sufre la falta de extremidades, provocando un desarrollo no pleno en sus vidas, ya que actividades de la vida cotidiana se ven afectadas por su condición. Es por ello que es importante desarrollar nuevas tecnologías en cuanto a prótesis que permitan hacer más eficientes su control. Actualmente, una alternativa para el control de estas es a partir del uso de señales EEG, ya que permite evitar problemas tales como enfrentarse con un músculo atrofiado y que no mande una señal mio-eléctrica y así lograr que la persona recupere el movimiento con un control más eficiente y seguir con su vida.

Es por ello, que la principal justificación de este trabajo de tesis es lograr una metodología basada en señales EEG que permita diferenciar entre diferentes estados mentales que permita el control de dispositivos como sillas de ruedas o prótesis robóticas, motivo por el cual con el presente trabajo se busca implementar un brazo robótico como actuador, el cual se pretende sea controlado con la clasificación de diferentes estados mentales obtenidos y diferenciados gracias a el procesamiento aplicado a las señales EEG.

1.5 HIPOTESIS

Mediante la transformada wavelet, fractales y redes neuronales es posible generar una metodología que permita realizar la clasificación entre diferentes acciones motoras de forma automática, misma que sea capaz de ser ejecutada en

plataformas de procesamiento digital de señales de alto rendimiento con bajo retardo para la obtención de la respuesta.

1.6 OBJETIVOS

1.6.1 Objetivo General:

Desarrollar una metodología basada en la transformada wavelet, fractales y redes neuronales para la clasificación de la imaginación motora de forma automática, particularmente pensamientos que simulen movimientos hacia la derecha, izquierda, y reposo.

1.6.2 Objetivos Particulares:

1. Leer las señales electroencefalográficas (EEG) proporcionadas por el Dr. Mario Alberto Manzano Ibarra (Mendoza et al. 2016) mediante el uso del software MATLAB para su entendimiento y análisis de las señales.

2. Programar el algoritmo de la transformada wavelet de paquete haciendo uso del software MATLAB para separar la señal en bandas de frecuencia relacionadas con la imaginación motora.

3. Programar los algoritmos diferentes algoritmos de fractales, Katz, Higuchi y dimensión de caja, haciendo uso del software MATLAB para estimar la fractalidad de una señal en el dominio del tiempo.

4. Analizar las señales EEG proporcionadas por la Universidad de Guanajuato mediante los transformada wavelet y fractales programados en el objetivo 2 y 3, para discernir entre una persona que piensa en moverse a su izquierda, derecha, o está en reposo.

5. Diseñar un clasificador basado en redes neuronales empleando las características o valores obtenidos por lo fractales para distinguir entre los diferentes pensamientos de forma automática.

6. Realizar un análisis estadístico de las diferentes pruebas con el fin de validar la metodología propuesta buscando realizar la distinción entre los diferentes pensamientos de manera eficiente y confiable.

7. Aplicar la metodología propuesta a través de la fusión MATLAB-Arduino para mover el efector final de un robot comercial.

1.7 PLANTEAMIENTO GENERAL

El planteamiento general de desarrollo de este trabajo se basa en 5 etapas como se muestra en la Figura 1.1




Figura 1.1. Planteamiento General.

1. **Señales ECG:** En este primer paso se requiere la adquisición de señales de ECG de una base de datos proporcionada por del Dr. Mario Ibarra Manzano de la Universidad de Guanajuato (Mendoza et al. 2016). Dichas señales contienen información de 3 estados mentales izquierda, derecha y reposo.
2. **Procesamiento:** En el segundo paso, las técnicas de procesamiento tales como wavelets y fractales son aplicadas a las señales EEG para extraer características que permitan diferenciar entre los 3 estados mentales
3. **Análisis estadístico:** En el tercer paso, un análisis estadístico conocido como análisis de varianzas ANOVA es empleado para determinar cuáles de las características calculadas en el paso 2 son las que permiten una mayor discriminación entre los 3 estados mentales
4. **Clasificador:** En la cuarta etapa, se emplea una técnica de clasificación inteligente que permita reconocer el estado mental (izquierdo, derecha y reposo) de forma automática a partir de las características seleccionadas en el paso anterior, con el fin de obtener una salida específica en un actuador.

5. **Actuador:** Finalmente, en la quinta etapa, se llevan a un actuador las salidas obtenidas por el clasificador, para observar los cambios de estado en él.

Dirección General de Bibliotecas de la UAQ

Dirección General de Bibliotecas de la UAQ

CAPÍTULO 2

2.1 REVISIÓN DE LA LITERATURA

Como se mostró en el capítulo anterior, este trabajo de tesis se basa en la extracción de características de señales EEG para la clasificación de la imaginación motora. Por lo tanto, en este capítulo se presentan los fundamentos de las señales EEG, así como la matemática de los algoritmos empleados para el análisis de señales EEG.

2.2 SEÑALES EEG

Las señales electroencefalográficas o electroencefalograma (EEG) se encargan de registrar la actividad eléctrica del cerebro en condiciones de reposo, sueño o durante diversas actividades (Ramos et al. 2009). Estas señales eléctricas tienen origen en la unidad básica del sistema nervioso (la neurona), el cual se encarga de captar y procesar las señales internas y externas que viajan entre las neuronas a través de impulsos eléctricos que se transmiten de neuronas a neuronas. Dicha actividad eléctrica se propaga a través del tejido circundante y puede ser detectado con los electrodos (sensores) que cumplen la función de transductores, convirtiendo las corrientes iónicas intra y extra neuronales en corrientes eléctricas (De la Torre, 2012).

Las señales EEG se caracterizan por ser capaces de monitorear los cambios en el cerebro ante diferentes condiciones tales como: manipulaciones hormonales y farmacológicas, respuestas a un estímulo sensorial, procesos cognitivos (memoria, aprendizaje, pensamientos, etc.), el ciclo sueño-vigilia y la edad, entre muchas otras; por lo cual, las señales EEG son una herramienta de gran utilidad para el diagnóstico clínico de patologías y el control de actuadores tales como sillas de ruedas, brazos robóticos, etc. (Guevara et al. 2010; González, 2014).

Las señales EEG contienen diferentes ritmos cerebrales que son definidos como ondas regulares a lo largo del tiempo, los cuales se dividen en 5 bandas de frecuencia denominados banda alfa (α), banda beta (β), banda delta (δ), banda theta (θ) y la banda gamma (γ) (Bermúdez, 2013).

- **Banda alfa (α):** Se presenta en la banda de frecuencias de 8 a 13 Hz, con amplitudes que oscilan entre 20 y 60 μV . Estas señales se encuentran en el electroencefalograma de la mayoría de los adultos sanos, con los ojos cerrados o con reposo visual, despiertos con un estado mental tranquilo y de reposo.
- **Banda beta (β):** Se presenta en frecuencias entre 13 y 30 Hz. Su amplitud aproximada está entre 2 y 20 μV . Estas señales se encuentran en un estado de concentración mental. Se detectan principalmente en la región central y frontal del cuero cabelludo, cerca o sobre la corteza motora primaria. La banda central de este ritmo está relacionada con el movimiento de las extremidades.
- **Banda Delta (δ):** Se encuentran entre 0.5 y 3.5 Hz y presenta amplitudes de 20 a 200 μV . Estas señales se presentan en individuos adultos sanos, exclusivamente durante el sueño profundo. En caso de detectarse en una persona despierta, puede indicar que existe algún tipo de anomalía en el cerebro.
- **Banda Theta (θ):** Se presenta en la banda de frecuencias de 4 a 7 Hz, con amplitudes que oscilan entre 20 y 100 μV . Estas señales se presentan con mayor frecuencia en niños. En adultos sanos, se pueden detectar en estado de adormecimiento y sueño. Se registra en el lóbulo temporal.
- **Banda Gamma (γ):** Este ritmo se manifiesta a frecuencias mayores a los 30 Hz y amplitudes entre 5 y 10 μV . Se presenta como respuesta a estímulos sensoriales, como sonidos contundentes o luces intermitentes. Esta actividad se puede observar en una zona extensa de la corteza cerebral, manifestándose principalmente en la zona frontal y la central.

2.2.1 Tipo de sensores para monitorear señales EEG

Las señales EEG han permitido realizar estudios y análisis de los campos eléctricos cerebrales (topografía, polaridad y su variación espacial temporal)

mediante la amplificación de la diferencia de potencial entre los electrodos receptores de la señal, los cuales pueden estar situados en el cuero cabelludo (sensores de superficie y basales) o subdurales (EEG de profundidad). Es importante mencionar que mientras más cerca del cerebro se tomen los registros, se obtienen señales con mejor relación señal a ruido y mejor resolución (Bermúdez 2013; Ramos et al. 2009; Guevara et al. 2010).

- **Sensores de superficie:** Estos sensores son ubicados sobre el cuero cabelludo. Se caracterizan por ser de fácil colocación, remoción, indoloros y permanecen por un tiempo prolongado en la misma posición sin ningún problema. Dentro de los sensores de superficie se encuentran los electrodos de aguja, adheridos, casco de malla y de contacto, los cuales son descritos a continuación (ver Figura 2.1) (González, 2014):
 - (a) **Electrodos de aguja:** Son sensores de uso muy limitado y de gran complejidad, los cuales son insertados bajo el cuero cabelludo y pueden ser desechables o de uso múltiple (requieren esterilización). Estos sensores permiten registros de larga duración.
 - (b) **Adheridos:** Pequeños discos metálicos de 5 milímetros de diámetro. Se adhieren con pasta conductora y se fijan con un aislante. Se caracterizan por tener resistencias de contactos muy bajas si se aplican bien.
 - (c) **Casco de malla:** Se trata de una especie de casco elástico en el que se introducen los electrodos. Puede encontrarse de diferentes tamaños en función del paciente. Su característica más relevante es la comodidad del paciente, tanto en colocación como en registro.
 - (d) **De contacto:** Pequeños tubos de plata clorurada unidos a soportes de plástico. En su extremo de contacto se le coloca una almohadilla que se empapa con una solución conductora. Su método de sujeción es mediante bandas elásticas. Fácil colocación, aunque suelen ser molestos para los pacientes y no sirven para estudios de larga duración.



Figura 2.1. Sensores de superficie.

- **Sensores basales:** Son sensores que pueden ser colocados sobre el cráneo sin necesidad de realizar un proceso quirúrgico. Se utilizan para inspeccionar la base del cerebro (lóbulos frontales y temporales del cerebro), a través de las diferentes vías de acceso tales como el faríngeo y el timpánico.
- **Sensores subdurales:** Son sensores que se utilizan para registrar la actividad eléctrica directamente desde el cerebro. Los electrodos subdurales se implantan en el quirófano bajo anestesia general. Estos electrodos permiten además la estimulación eléctrica de las neuronas para activar y estudiar ciertas partes del cerebro. Resultan incómodos y pueden ocasionar dolores de cabeza posteriores o a su extracción (ver Figura 2.2) (De la Torre, 2012).

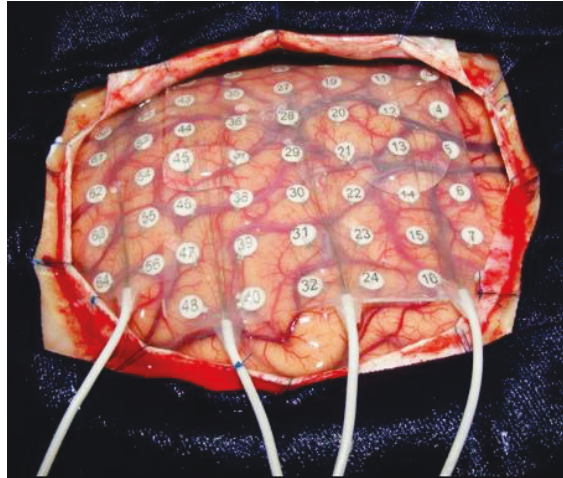


Figura 2.2. Sensores de subdurales.

2.3 PROCESAMIENTO DIGITAL DE SEÑALES

El procesamiento digital de señales es un área de la ingeniería que agrupa un conjunto de operaciones que se aplican a señales discretas y cuantizadas, con el fin de extraer la mayor cantidad de información relevante contenida en imágenes o señales en tiempo. Por lo tanto, el procesamiento de señales trata de la representación, transformación y manipulación de la información que contienen las señales (UPM, 2019).

2.3.1 MATLAB

MATLAB es un lenguaje de nivel alto empleado principalmente para el procesamiento digital de señales. En él se pueden resolver muchos problemas computacionales, como aquellos que involucren vectores y matrices, cálculos numéricos, desarrollo de algoritmos, modelado, simulación y desarrollo de aplicaciones que requieran de una interfaz gráfica de usuario (GUI), así como el análisis de señales con una gran cantidad de datos (Esqueda, 2002).

Al iniciar el software MATLAB una ventana principal es desplegada, la cual a su vez se divide en cuatro sub-ventanas (ver Figura 2.3): (1) la ventana “carpeta actual”, la cual se encarga de mostrar los archivos que se encuentran en la

carpeta/dirección donde se está trabajando, (2) la ventana “detalles”, la cual muestra el historial de las operaciones realizadas, (3) la ventana “ventana de comandos”, la cual permite la programación de algoritmos para el análisis de las señales/datos y (4) la ventana “espacio de trabajo”, la cual permite visualizar las variables empleadas en los algoritmos, así como su valor.

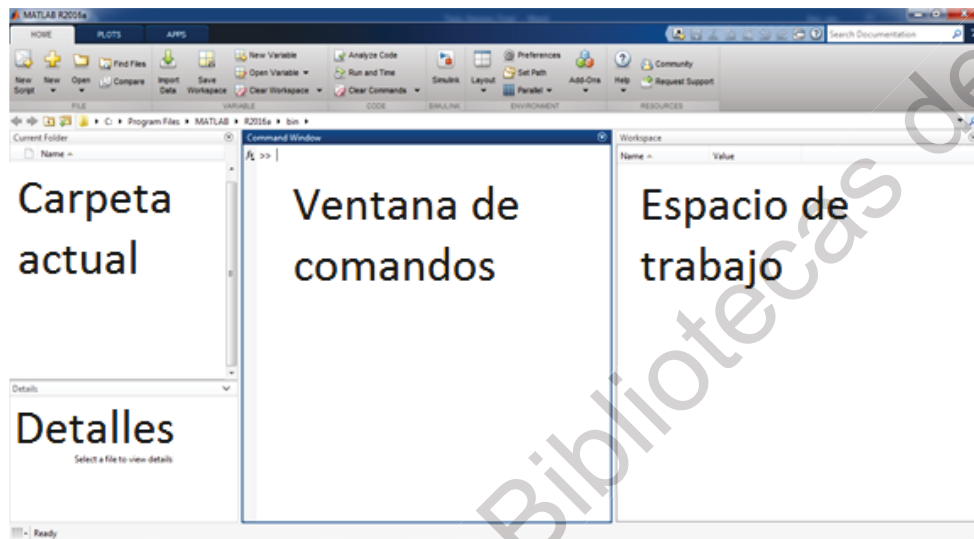


Figura 2.3. MATLAB.

2.3.2 Transformada Wavelet

La transformada wavelet se caracteriza por ser un método o técnica de procesamiento capaz de analizar señales con características estacionarias y no estacionarias. La transformada wavelet se encarga de descomponer la señal a analizar en diferentes bandas de frecuencias de acuerdo con el nivel analizado (Cortés et al. 2007).

Diversos algoritmos han sido desarrollados para el cálculo de la transformada wavelet, siendo los más representativos la transformada wavelet discreta (TWD) y la transformada wavelet de paquetes (TWP), las cuales serán descritos en las siguientes secciones.

2.3.2.1 Transformada Wavelet Discreta

La TWD permite realizar un análisis tiempo-frecuencia sin importar las características de la señal. La TWD es basada en el algoritmo de Mallat como se muestra en la Figura 2.4. Por lo tanto, de acuerdo con la figura y el algoritmo, la señal original es descompuesta en un detalle (filtro pasa altas) y una aproximación (filtro pasa bajas) en el primer nivel (Nivel 1). Posteriormente, en el nivel 2 un nuevo detalle y una nueva aproximación es estimada empleando la aproximación previamente estimada, y así sucesivamente (Gokhale et al. 2010). Los rangos de frecuencia de cada y detalle (Det) y aproximación (Aprox) de acuerdo con el nivel analizado (N) son estimados de la siguiente forma.

$$\text{Det}_N \Rightarrow \left[\frac{F_s}{2^{N+1}}, \frac{F_s}{2^N} \right] \quad (2.1)$$

$$\text{Aprox}_N \Rightarrow \left[0, \frac{F_s}{2^{N+1}} \right] \quad (2.2)$$

donde F_s es la frecuencia de muestreo de la señal.

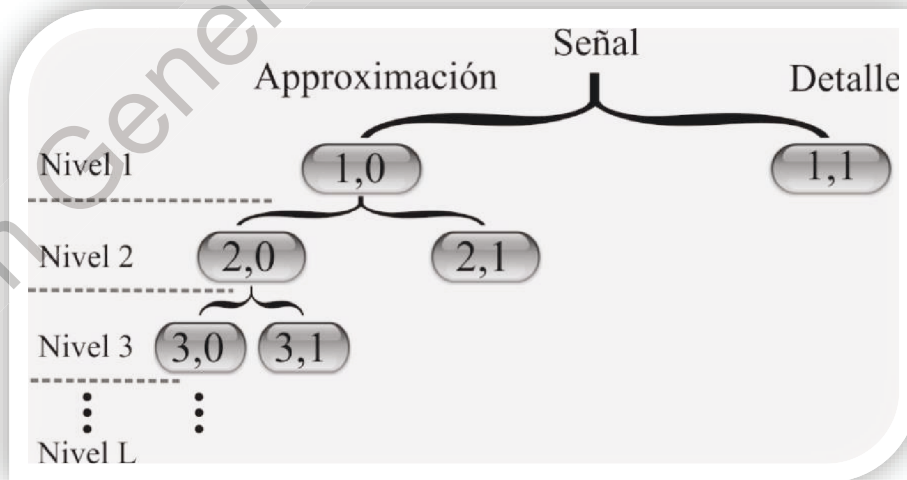


Figura 2.4. Algoritmo de Mallat.

2.3.2.2 Transformada Wavelet de Paquetes

La TWD ha presentado excelentes resultados en diversas aplicaciones tales como detección de epilepsia, monitoreo estructural, entre otras (Adeli et al. 2007; Amezcua-Sanchez & Adeli, 2016); sin embargo, la TWD no provee un análisis detallado de la señal, ya que, solamente las aproximaciones son analizadas, generando que las frecuencias medias altas (detalles) no seas analizadas adecuadamente. En este sentido, la TWP genera un análisis más detallado de ambas bandas de frecuencias, aproximaciones y detalles, ya que ambos son descompuestos en una nueva aproximación y un nuevo detalle como se muestra en la Figura 2.5. Es importante mencionar que en la TWP las aproximaciones y detalles son llamados nodos y que de acuerdo con el nivel que se esté analizando son numerados, siendo el primer número de acuerdo con el nivel y el segundo de acuerdo a la descomposición estimada; por ejemplo, si se está analizado el nivel 3, el primer nodo sería (3,0), el segundo nodo (3,1) y así sucesivamente hasta el nodo (3,7). Por lo tanto, la TWP descompone la señal en bandas de frecuencias uniformes a diferencia de la TWD (Mendoza et al. 2013; Amezcua-Sanchez & Adeli, 2016).

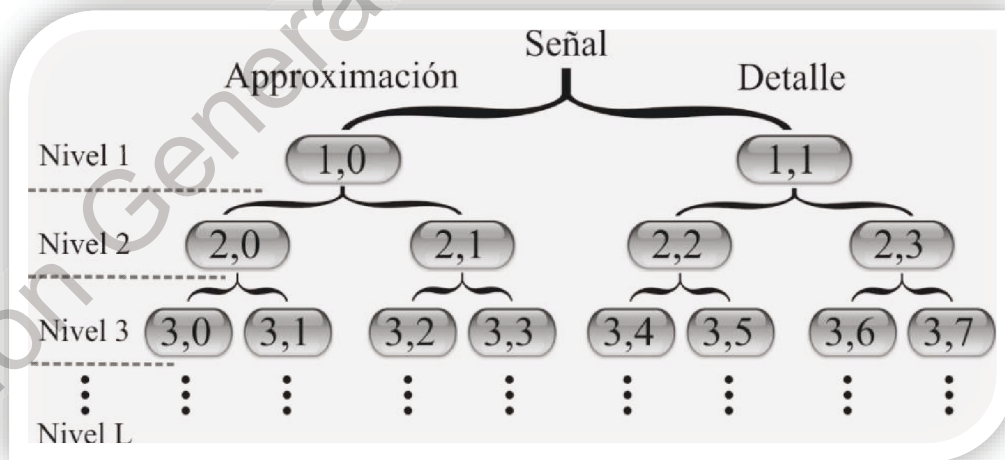


Figura 2.5. TWP.

La TWP se basa en la Ecuación (2.3):

$$W_{j,k}^n(t) = 2^{j/2} W^n(2^j t - k) \quad (2.3)$$

donde j , k y n son la escalada, la translación y la modulación u oscilación de los parámetros, respectivamente.

La TWP es estimada usando las siguientes ecuaciones recursivas:

$$W^{2n}(t) = \sqrt{2} \sum_{k=-\infty}^{\infty} h(k) W^n(2t - k) \quad (2.4)$$

$$W^{2n+1}(t) = \sqrt{2} \sum_{k=-\infty}^{\infty} g(k) W^n(2t - k) \quad (2.5)$$

donde t es el tiempo, $h(k)$ y $g(k)$ son los coeficientes para estimar las aproximaciones y detalles asociados a la función escalada, respectivamente, y W^n es la ondoleta o wavelet madre. Es muy importante mencionar que la selección de wavelet madre es una tarea ardua; sin embargo, la wavelet madre llamada Daubechies 44 es la más empleada para el procesamiento de bioseñales ya que excelentes resultados han obtenidos (Rafiee et al. 2011). Por lo tanto, en este trabajo de tesis se empleada esta wavelet madre.

2.3.3 Dimensión Fractal

La dimensión fractal (DF) es conocida como una medida dinámica no lineal empleada para cuantificar la complejidad geométrica de una señal. En otras palabras, DF mide las regularidades y las auto similitudes encontradas en una señal, lo que indica cuántas veces se repite un patrón en la señal. El valor de la DF varía entre 1 y 2, indicando una cantidad baja y alta de auto-similitudes en la señal, respectivamente. Por lo tanto, la DF es considerada una herramienta adecuada para el reconocimiento de patrones en las señales (López et al. 2018), y es por ello que su utilidad para clasificar la imaginación motora es investigada en este trabajo de tesis.

Diferentes algoritmos para el cálculo de la DF han sido propuestos, siendo los más empleados la DF de Katz (KDF) (Katz, 1988), de Higuchi (HDF) (Higuchi, 1988) y la dimensión de conteo de cajas (BCC) (Wang, 2005). Por ello, en la presente tesis los tres algoritmos son investigados para el análisis de señales EEG para la clasificación de pensamientos.

2.3.3.1 Algoritmo de Katz

De acuerdo con la definición de Katz, la DF de una señal en tiempo se calcular de la siguiente manera:

$$KDF = \frac{\log(n)}{\log(n) + \log(\frac{d}{L})} \quad (2.6)$$

donde L , es la suma de las distancias euclidianas entre los puntos sucesivos de la señal x y está definido por la Ecuación (2.7):

$$L = \text{sum}(\text{dist}(x_i, x_{i+1})) \quad (2.7)$$

d es la distancia euclidiana máxima entre el punto inicial de los datos y los puntos sucesivos

$$d = \max(\text{dist}(x_1, x_{i+1})) \quad (2.8)$$

y $n=L/a$, donde a es el promedio de L .

2.3.3.2 Algoritmo de Higuchi

El algoritmo de Higuchi se basa en cuatro pasos para estimar la DF de una señal, los cuales son descritos a continuación: -

- 1) A partir de una señal con datos x , se construyen señales nuevas k submuestreadas de la siguiente manera:

$$x_m^k = \left[x_m, x_{m+k}, x_{m+2k}, \dots, x_{m+\lfloor \frac{N-m}{k} \rfloor k} \right], m = 1, 2, \dots, k \quad (2.9)$$

donde m y k indican el tiempo inicial y el tiempo de intervalo, respectivamente, y $[.]$ representa la parte entera de un valor específico.

- 2) Estimar la longitud normalizada L_m de cada secuencia x_m^k de la siguiente manera:

$$L_m(k) = \frac{N-1}{k^{\lfloor \frac{N-m}{k} \rfloor}} \sum_{i=1}^{\lfloor \frac{N-m}{k} \rfloor} |x_{m+ik} - x_{m+(i-1)k}| \quad (2.10)$$

donde $\frac{N-1}{k^{\lfloor \frac{N-m}{k} \rfloor}}$ representa el factor de normalización para cada secuencia.

- 3) Calcular la longitud total $L(k)$, promediando la longitud de todas las secuencias $L_m(k)$ como sigue:

$$L(k) = \frac{1}{k} \sum_{m=1}^k L_m(k) \quad (2.11)$$

- 4) Tomando en cuenta que $k \in [1, k_{max}]$, donde k_{max} es un número elegido cuando la pendiente de la mejor línea ajustada para $L(k)$ contra $1/k$ trazada en un plano log-log permanece constante. La pendiente indica el fractalidad de la señal.

2.3.3.3 Algoritmo Dimensión de Caja

Para una señal, el valor de dimensión fractal con el algoritmo dimensión de caja se calcula de la siguiente manera:

$$BD \cong - \frac{\ln(\sum_{i=1}^{N-1} |x_{i+1} - x_i| / \Delta t)}{\ln(\Delta t)}$$

donde N es el número de muestras, x_i ($i=1 \dots N-1$) son las muestras de la señal y Δt es el intervalo de muestreo.

2.3.4 ANOVA

Análisis de varianza o ANOVA es un método estadístico capaz de evaluar si un conjunto de datos comparte información con otro conjunto de datos a través de un valor probabilidad P . Este valor de probabilidad, P , se caracteriza por variar entre 0 y 1, lo que indica que los valores de un conjunto no (valor p tendiendo a 0) y si (valor p tendiendo a 1) se parecen al otro conjunto de datos, respectivamente (Moreno-Gomez et al. 2018).

2.3.5 Clasificador basado en Redes Neuronales

Las redes neuronales se basan en modelos del comportamiento de las neuronas vivas y redes de comunicación de un ser humano. Una neurona viva toma el papel de un nodo en una red neuronal artificial, el papel de nodo en una red neuronal es de una función de suma no lineal para procesar la información. Las conexiones neuronales (fuerzas sinápticas) son traducidas en factores de ponderaciones que ocurren a lo largo de las interconexiones de la red. Dentro de las redes neuronales, esos pesos establecidos son ajustados mediante un proceso de entrenamiento, debido a este entrenamiento, los valores de entrada (a), así como los valores de salida correspondientes (α), son enviados repetitivamente a la red. Los pesos son ajustados en cada repetición, con el propósito de acercar los valores de salida de la red, a los valores deseados (Matich 2001, Izaurieta et.al. 2000). Es propósito de cada neurona específica es dedicarse a funciones de salida o entrada, además que algunas otras capas ocultas se hacen internas a la red creando una configuración de Perceptrón Multicapa para procesamiento de información más específico (Orhan et al. 2011), tal como se muestra en la Figura 2.6.




Figura 2.6. Perceptrón Multicapa.

Es muy importante mencionar que un Perceptrón Multicapa la cantidad de neuronas en la capa oculta se recomienda que sea del doble de las entradas; sin embargo, siempre es importante realizar un ajuste fino para obtener los mejores resultados (Lopez-Ramirez et al. 2016).

2.4 MICROCONTROLADOR ARDUINO

Arduino es una plataforma de desarrollo basada en una placa electrónica de hardware libre que incorpora un microcontrolador re-programable y una serie de pines hembra, los que permiten establecer conexiones entre el microcontrolador y diferentes sensores y actuadores. La placa Arduino no es más que una PCB que implementa un determinado diseño de circuitería interna, de esta forma el usuario final no se debe preocupar por las conexiones eléctricas que necesita el microcontrolador para funcionar, y puede empezar directamente a desarrollar las diferentes aplicaciones electrónicas que necesite.

Los microcontroladores usados en las placas Arduino, tienen una arquitectura de tipo AVR (Automatic Voltage Regulator), arquitectura desarrollada por Atmel. La programación del microcontrolador Arduino es multiplataforma, ya que se puede instalar y ejecutar en sistemas operativos Windows, Mac OS y Linux. Su lenguaje de programación se basa en C++. La placa Arduino es re-utilizable, ya que una vez terminado el proyecto es muy fácil poder desmontar los componentes externos a la placa y empezar con un nuevo proyecto (Arduino, 2019). La Figura 2.7

muestra algunas de las placas Arduino tales como la UNO, nano, la Mega, entre otras, para el desarrollo de diferentes proyectos, ya que cada una de ellas presenta diferentes prestaciones tales como convertidor analógico a digital, mayor cantidad de entradas/salidas, salidas PWM (modulación por ancho de pulso), etc.



Figura 2.7. Placas Arduino.

Para el desarrollo de este trabajo de tesis se optó por trabajar con la placa UNO ya que se adapta al trabajo de tesis, dado que no se requiere una gran cantidad salidas ni tampoco un convertidor analógico a digital para el control del actuador. En la Tabla 2.1 se puede apreciar una lista de características de la placa Arduino UNO.

Tabla 2.1. Características de la Arduino modelo UNO.

Característica de Arduino	UNO
Tipo de microcontrolador	Atmega 328
Velocidad de reloj	16 MHz
Pines digitales de E/S	14
Entradas analógicas	6
Salidas analógicas	0
Memoria de programa (Flash)	32 Kb
Memoria de datos (SRAM)	2 Kb
Memoria auxiliar (EEPROM)	1 Kb

CAPÍTULO 3

Dirección General de Bibliotecas de la UAQ

3.1 METODOLOGÍA

La metodología propuesta en este trabajo de tesis se base en 7 etapas, las cuales son descritas a continuación y mostradas en la Figura 3.1.

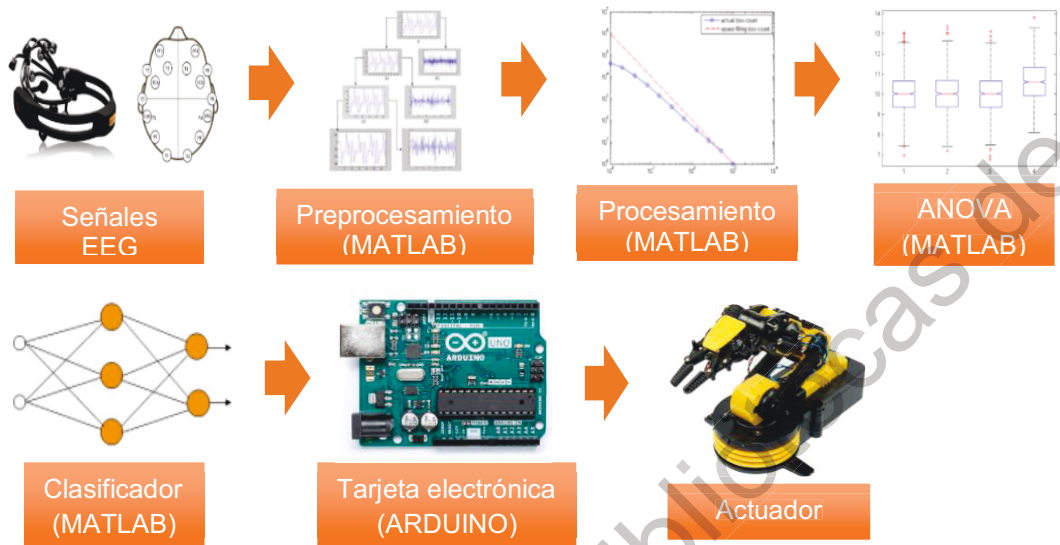


Figura 3.1. Metodología propuesta.

- Etapa 1: **Señales EEG:** Para este trabajo de tesis se utilizó la base de datos proporcionada por el Dr. Mario Alberto Ibarra Manzano de la Universidad de Guanajuato (Mendoza et al. 2016). Dicha base de datos contiene información adquirida por medio del sistema de BCI Emotiv Epoc, el cual es una diadema de 14 electrodos colocados según el sistema internacional 10–20 en 10 pacientes, la adquisición fue realizada con una frecuencia de muestreo de 128Hz. El monitoreo se realizó con 10 participantes de varias edades, tanto hombres como mujeres. El tiempo para cada prueba individual fue aproximadamente de 10 minutos consecutivos, durante los cuales aparecieron tres elementos en la pantalla: una flecha apuntando hacia la izquierda y moviéndose en esa dirección, una cruz representando el tiempo de descanso y una flecha apuntando hacia la derecha y moviéndose en esa dirección. Las flechas izquierda y derecha se alternan después de aparecer durante 10 s (modo de prueba) con un tiempo de descanso de 5 s en el medio, durante el

cual apareció una cruz en el centro de la pantalla. Mostrándose un total de 40 flechas alternativamente durante 10 minutos. El objetivo del experimento era hacer que el participante pensara o imaginara un movimiento mientras la flecha aparecía en la pantalla. Durante el modo de prueba, se les pidió a los participantes que permanecieran inmóviles y evitaran movimientos agudos del cuerpo que pudieran interferir con la señal que se estaba grabando y en el tiempo de descanso se les permitió moverse libremente. De este modo se obtuvo para cada paciente información de 3 estados mentales, los cuales están embebidos en ruido y son los que se pretende rescatar mediante técnicas de preprocesamiento y procesamiento computacional.

- Etapa 2: **Preprocesamiento:** Para el preprocesamiento de las señales EEG se emplea la transformada wavelet de paquete en el software MATLAB. Esta técnica permite la descomposición de la señal original de todos los sensores en diferentes bandas de frecuencias, permitiendo un análisis más detallado de la señal con el fin de una correcta identificación de patrones.
- Etapa 3: **Procesamiento:** El procesamiento consiste en programar y aplicar los diferentes algoritmos de fractales tales como: Katz, Higuchi y dimensión de caja, haciendo uso del software MATLAB, el dato de entrada para cada fractal es cada una de las bandas de frecuencia obtenidos por la transformada wavelet a cada uno de los 14 sensores y así estimar la similitud geométrica de la señal (fractalidad) descompuesta con el fin de observar el comportamiento de los 3 estados mentales.
- Etapa 4: **Análisis estadístico:** Este paso consiste en un análisis estadístico basado en la varianza de los datos llamado ANOVA de los valores de fractalidad calculados en la etapa 3. Este análisis de ANOVA permite hacer una correcta selección de cuales valores de fractales son los más discriminantes, con el fin de poder diferenciar entre los estados mentales (izquierda, derecha y reposo)

- Etapa 5: **Clasificador:** Finalmente, una vez determinadas las características más discriminantes empelando el análisis de varianza (ANOVA), se procede a generar un clasificador de inteligencia artificial basado en redes neuronales, con el fin de clasificar estas características de forma automática y relacionarlas con los diferentes estados mentales (izquierda, derecha y reposo) a fin de mover una articulación de un brazo robótico a partir de ellas.
- Etapa 6: **Tarjeta electrónica Arduino:** En esta etapa se va a controlar las acciones del actuador, dependiendo de la entrada que se reciba de la red neuronal la tarjeta electrónica Arduino mediante sus pines de salida, cerrar, abrirá o simplemente no moverá el actuador (efector final – pinza).
- Etapa 7: **Actuador:** En esta última etapa se usa la pinza de un brazo robótico, la cual abrirá, cerrara o simplemente no se moverá, dependiendo de la entrada que reciba la tarjeta Arduino, que es clasificación hecha por la red neuronal.

3.2 CASCO EMOTIV

Los dispositivos BCI se encargan de capturar las señales EEG cerebrales de personas. Dependiendo de cómo se capturen las señales, los dispositivos BCI se clasifican como invasivos y no invasivos. La diadema Emotiv EPOC (ver Figura 3.2) es un dispositivo BCI móvil no invasivo con un sensor giroscópico y 14 canales EEG (electrodos) y dos canales de referencia, con una frecuencia de muestreo de 128 Hz.



Figura 3.2. Casco EMOTIV.

La distribución de los sensores en los auriculares se basa en el sistema internacional de colocación de electrodos 10-20 con dos sensores como referencia para la colocación correcta en la cabeza. Este dispositivo obtiene la actividad cerebral de un individuo, y es capaz de detectar y procesar sus pensamientos, sentimientos y expresiones en tiempo real. Basado en el sistema 10-20, los canales de la diadema son: AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8 y AF4 (ver Figura 3.3) (Mendoza et al. 2016).

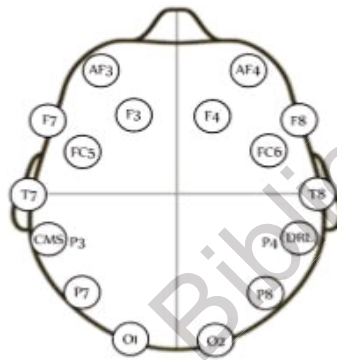


Figura 3.3. Ubicación de electrodos de la diadema EMOTIV.

En este trabajo de tesis se analizan y evalúan las señales cerebrales de los 14 electrodos, de manera que se evalúa el comportamiento de todo el cerebro. Con fines ilustrativos, la Figura 3.4 presentan las señales EEG u ondas cerebrales del sensor P7 (zona parietal), las cuales corresponden con los tres estados de imaginación motora evaluados en este trabajo de tesis: reposo, derecha e izquierda.

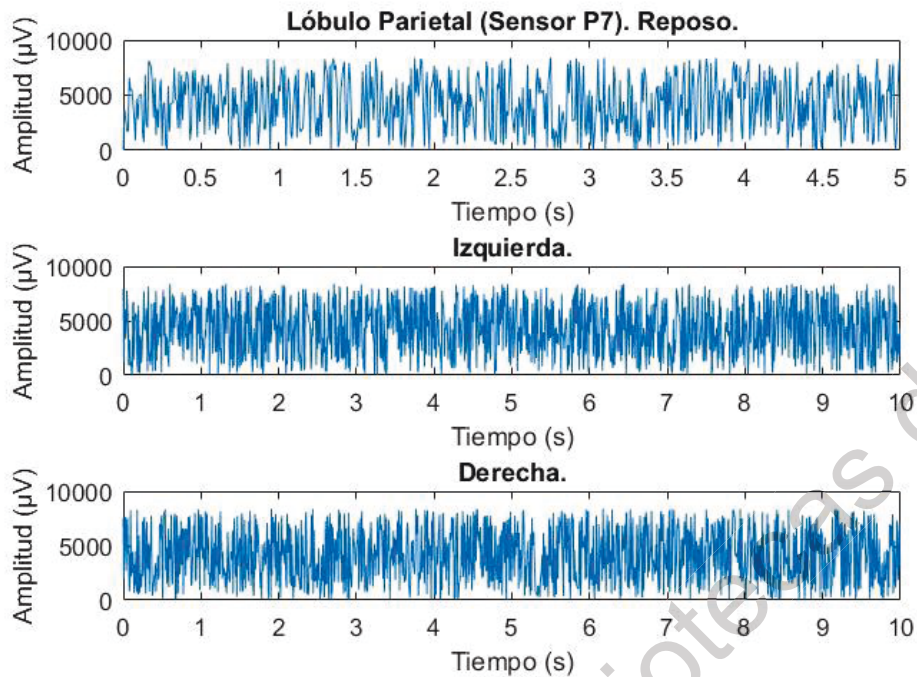


Figura 3.4. Señales EEG de la zona Parietal (Sensor P7) para (a) reposo, (b) pensamiento a la izquierda y (c) pensamiento a la derecha.

Como se puede apreciar en la Figura 3.4, es complicado identificar una característica en ellas que permitan la distinción entre los tres estados mentales. Por lo tanto, la importancia de proponer una metodología capaz de identificar patrones o características en las señales EEG que permitan ser asociados a los 3 pensamientos.

3.3 MATERIAL

Para verificar la viabilidad de la metodología propuesta, se evaluaron las señales EEG provenientes de 10 personas (5 hombres y 5 mujeres) que cumplieron con los siguientes lineamientos: (a) ser mayor de edad, (b) dormir bien antes de las pruebas (mínimo 6 horas), (c) no haber ingerido sustancias embriagantes, energizantes o perjudiciales para la salud, mínimo 24 horas antes de las pruebas, (d) no ser epiléptico o presentar alguna enfermedad psiquiátrica y (e) no tener acondicionador o gel en el cabello, ni cualquier otro producto de higiene/belleza que

impida o altere el contacto con el sistema de adquisición de señales EEG. Es importante mencionar que las edades de los participantes no fueron proporcionadas.

3.4 PROCESAMIENTO DE SEÑALES EEG

Con el objeto de mostrar el funcionamiento de las etapas principales, la TWP y la DF, de esta metodología para el análisis de señales EEG, una señal sintética es utilizada. La señal sintética generada presenta las siguientes características: tres frecuencias distintas (5 ,10 y 30 Hz) con una amplitud $3 \mu\text{V}$ similar a las ondas adquiridas por un electroencefalograma y una frecuencia de muestreo es 128 Hz durante un tiempo de 5 segundo resultando en 640 muestras como se muestra en la Figura (3.5).

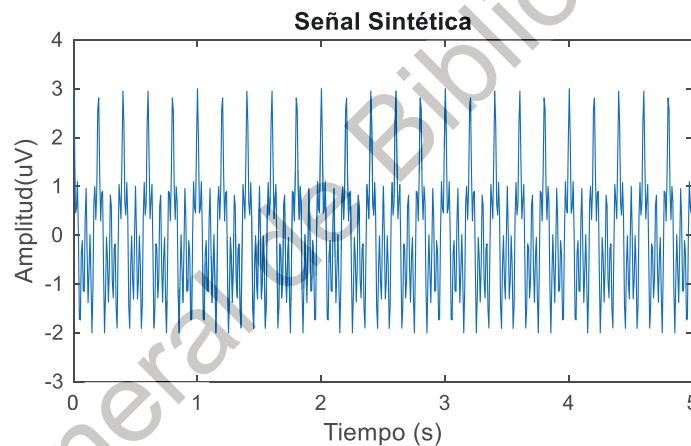


Figura 3.5. Señal sintética.

Como se describió anteriormente, la primera etapa de la metodología es descomponer la señal en diferentes bandas de frecuencias las cuales permitan al procesamiento identificar patrones que puedan ser asociados al pensamiento humano. Con el fin de ejemplificar lo mencionado, la señal sintética es descompuesta hasta el nivel 2 empleando la TWP, donde 4 nodos o 4 bandas de frecuencias mostradas en la Figura 3.6 son obtenidas.

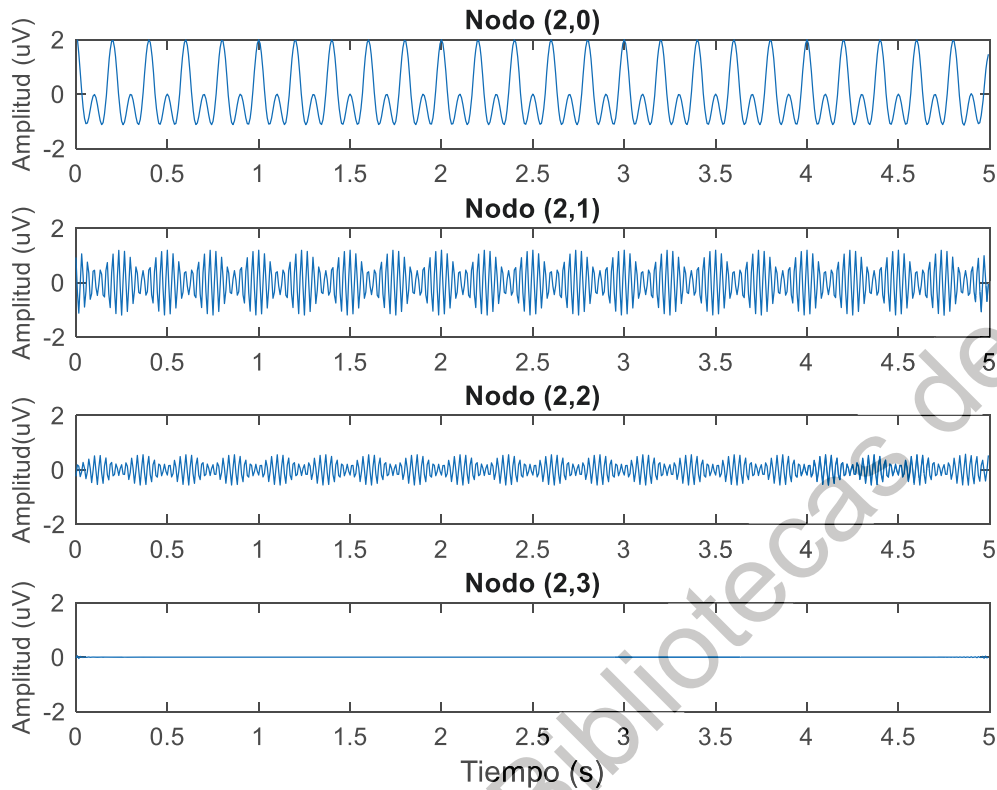


Figura 3.6. Bandas de frecuencia estimadas del nivel 2.

Como se puede apreciar en la Figuras 3.6, la TWP permite la descomposición de una señal en tiempo con el fin de separarlas en diferentes bandas de frecuencias para que el procesamiento identifique de manera más eficiente características que puedan ser asociadas a un fenómeno. Una vez descompuesta la señal en sus diferentes bandas de frecuencias, estas son analizadas por los diferentes algoritmos de fractalidad, BCD, HFD y KFD. Los valores obtenidos por los diferentes algoritmos ante las diferentes bandas de frecuencias son resumidos en la Tabla 3.1.

Tabla 3.1. Valores de fractalidad de cada nodo con las 3 técnicas.

Nodo	BCD	HFD	KFD
2,0	1.6	1.9	1.3
2,1	1.6	2.0	1.4
2,2	1.7	2.0	1.4
2,3	1.0	2.0	1.2

Observando la Tabla 3.1, los valores de fractalidad; BCD, HFD y KFD, son distintos en cada banda de frecuencia, ya que estos estiman de forma distinta las similitudes geométricas en una señal; por lo tanto, es importante evaluarlos con el fin de estimar cuál de ellos es más discriminante para diferencias entre los diferentes pensamientos humanos.

3.5 ACTUADOR

Un actuador es un dispositivo con la capacidad de generar una fuerza que ejerce un cambio de posición, velocidad o estado de algún tipo sobre un elemento mecánico, a partir de la transformación de energía (Corona, 2014).

Como el propósito de la carrera de Ingeniería biomédica es proveer soluciones ingenieriles a problemas de la salud, y en particular al movimiento de extremidades; por lo tanto, para el desarrollo de esta tesis se utilizó como actuador el kit de brazo mecánico de la marca STEREN, modelo K-680. Dicho brazo cuenta con 5 motores, 1 para mover el brazo de izquierda a derecha y hacerlo girar, otros 3 para mover el brazo de arriba para abajo en diferentes ángulos:

- Movimiento vertical de la parte superior del brazo: 120° .
- Movimiento vertical de la parte inferior del brazo: 180° .
- Movimiento horizontal de la base del brazo: 270° .

Y por último un motor para abrir y cerrar la tenaza.

- Abertura máxima de la tenaza: 4,5 cm.
- Movimiento vertical de la tenaza: 120° .




Figura 3.7. Brazo mecánico.

Es muy importante mencionar, que para este trabajo de tesis solamente se emplea el efector final, la tenaza, con el fin de asociarla a los tres distintos pensamientos: reposo, derecha (apertura de la tenaza) e izquierda (cerrado de la tenaza). Con el fin de controlar el brazo robótico, la interacción MATLAB-Arduino-Brazo se hace a través de una comunicación serial descrita en MATLAB y mostrada en la Figura 3.8.

```

Editor - C:\Users\carlo\OneDrive\Documentos\Tesis\Charlie Biomedica\Movimiento.m*
Analisis.m  Movimiento.m*
1  %% Conexión Arduino Matlab programada desde Matlab--%%
2  Clear all; close all; clc;
3  %% CLASIFICACIÓN DE IMAGEN MOTORA%%
4  int input= VALOR DEL MOVIMIENTO;
5  %%--Conexión a la placa
6  a = arduino('COM9')
7  Especificación del pin
8  a.pinMode(8,'output');
9  a.pinMode(9,'output');
10 %%Pines de salida del Arduino
11 int LeftPin=8;
12 int RightPin=9;
13 if (Serial.available())
14 {
15     if (input=='1')%El motor girará a la derecha
16     {
17         digitalWrite(8, LOW);% Valor bajo, cero
18         digitalWrite(9, HIGH);% Valor alto, uno
19     }
20     else if (input=='2')%El motor girará a la izquierda
21     {
22         digitalWrite(8, HIGH);% Valor bajo, cero
23         digitalWrite(9, LOW);% Valor bajo, cero
24     }
25     else if (input=='0'){ %El motor se parara
26         digitalWrite(8, LOW);% Valor bajo, cero
27         digitalWrite(9, LOW);% Valor bajo, cero
28     }
29     delay(10);
30 }

```

Figura 3.8. Script de la conexión serial del Arduino programada desde Matlab.

Dirección General de Bibliotecas de la UAQ

CAPÍTULO 4

4.1 Puesta de Experimento

La puesta de experimento se basa en dos etapas: a) las tareas realizadas para la adquisición de las señales EEG y (b) movimiento del actuador. Para la parte de las tareas realizadas para la adquisición de las señales EEG, estas se realizaron a 10 participantes de varias edades, tanto hombres como mujeres. El tiempo para cada prueba individual fue de aproximadamente 10 minutos consecutivos con una frecuencia de muestreo de 128Hz. Durante ese tiempo se les mostró a los participantes tres elementos en una pantalla: una flecha apuntando hacia la izquierda y moviéndose en esa dirección, una cruz representando el tiempo de descanso y una flecha apuntando hacia la derecha y moviéndose en esa dirección (ver Figura 4.1).




Figura 4.1. Puesta de experimento: Señales visuales con esquema de tiempo.

La cruz, tiempo de reposo, aparece en un lapso de 5 segundos (640 datos) y alterna con las flechas izquierda y derecha, las cuales aparecen durante 10 segundos (1280 datos) cada una representando el modo de prueba. En total se mostraron 40 flechas alternativamente durante los 10 minutos de la prueba, con descansos de 5 segundos entre cada alternancia.

Durante el modo de prueba, se les pidió a los participantes que permanecieran inmóviles y evitaran movimientos agudos del cuerpo que pudieran interferir con la señal que se estaba grabando, y para el tiempo de descanso se les permitió moverse libremente y pensar cualquier otra cosa. El objetivo del experimento era obtener 3 estados mentales haciendo que el participante pensara

o imaginara el movimiento de la flecha (derecha o izquierda) mientras aparecía en la pantalla y el estado de reposo. Los estados 0, 1 y 2 se utilizaron para referirse a los ellos: tiempo de espera (0), izquierda (1) y derecha (2) durante la fase de clasificación (Mendoza et al. 2016).

Por otro lado, la parte del movimiento del actuador se basa en el procesamiento de la señal que a partir de una computadora personal manda la información a la tarjeta de desarrollo Arduino Uno y esta su vez manda la información a un control de sentido de giro (puente H, modelo: L298) del motor que controla la apertura y el cerrado de la tenaza del brazo robótico (ver Figura 4.2).



Figura 4.2. Puesta de experimento: Movimiento actuador.

4.2 Resultados

Siguiendo la metodología propuesta, las señales EEG proporcionadas por el Dr. Mario Alberto Manzano Ibarra de la Universidad de Guanajuato (Mendoza et al.

2016) son analizadas por medio de la TWP, donde las primeras 5 pruebas y los 14 sensores proporcionados por la diadema EMOTIV EPOC+ son empleadas con el objeto de calibrar el método propuesto y el resto se ocupa para validar el método. Las señales EEG fueron descompuestas por la TWP desde el nivel 1 hasta el nivel 8, generándose 510 bandas de frecuencia, resultando que el nivel 5 (32 nodos o bandas de frecuencia) es el que permite tener una mayor discriminación entre los diferentes pensamientos. Con el fin de ejemplificar, las Figuras (4.3) a la (4.34) muestran los 32 nodos estimados para las diferentes condiciones de pensamiento: reposo, izquierda y derecha para el sensor 1. Observando estas figuras, no es posible identificar/determinar características que puedan ser asociados a los diferentes pensamientos, por lo que se requiere de un procesamiento tal como dimensión fractal capaz de identificar características en este tipo de señales.

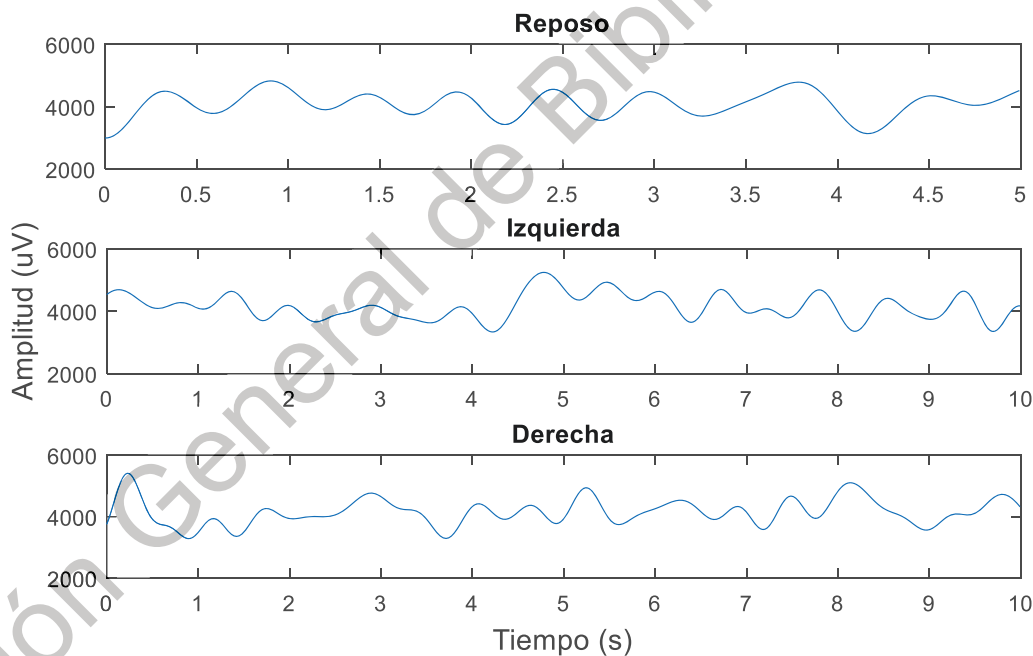


Figura 4.3. Nodo 1: Banda de Frecuencia (0-2 Hz)




Figura 4.4. Nodo 2: Banda de Frecuencia (2-4 Hz)




Figura 4.5. Nodo 3: Banda de Frecuencia (4-6 Hz)

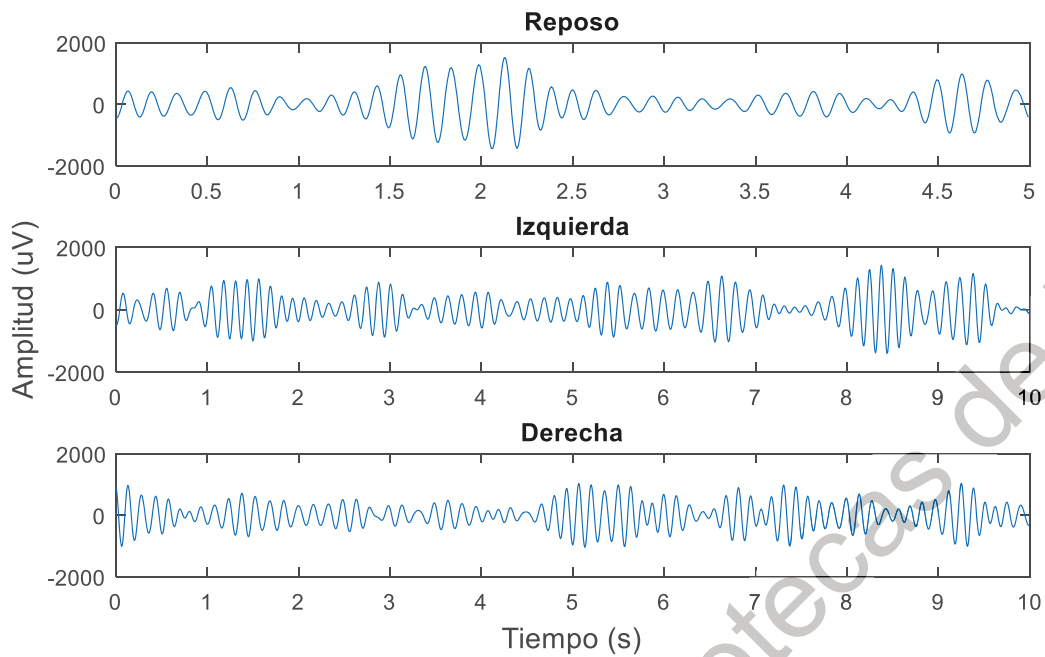


Figura 4.6. Nodo 4: Banda de Frecuencia (6-8 Hz)




Figura 4.7. Nodo 5: Banda de Frecuencia (8-10 Hz)




Figura 4.8. Nodo 6: Banda de Frecuencia (10-12 Hz)




Figura 4.9. Nodo 7: Banda de Frecuencia (12-14 Hz)




Figura 4.10. Nodo 8: Banda de Frecuencia (14-16 Hz)

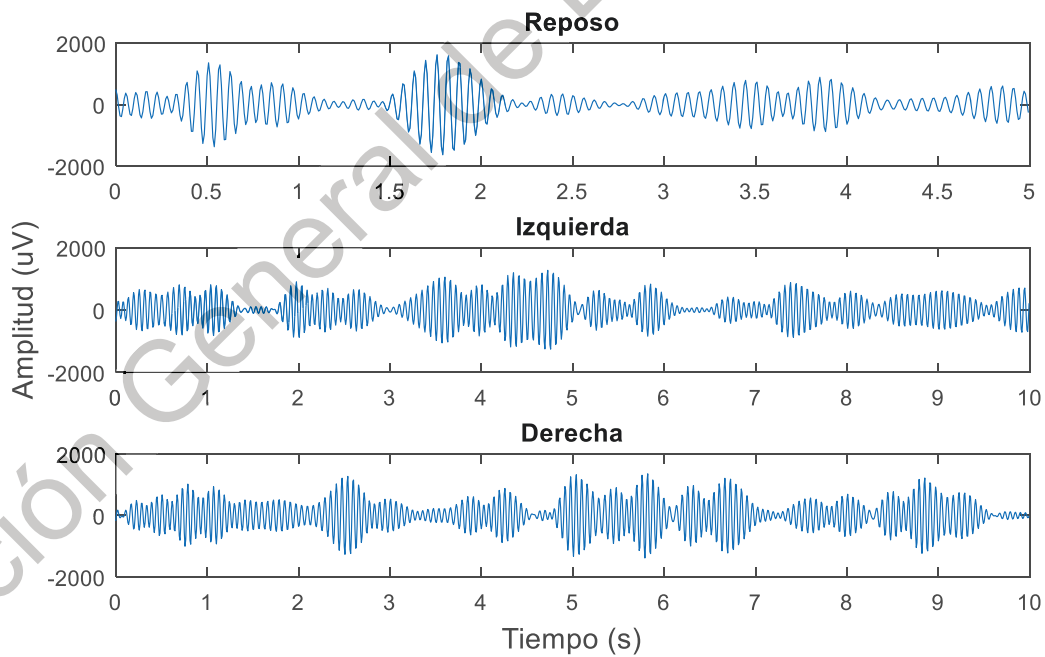


Figura 4.11. Nodo 9: Banda de Frecuencia (16-18 Hz)




Figura 4.12. Nodo 10: Banda de Frecuencia (18-20 Hz)

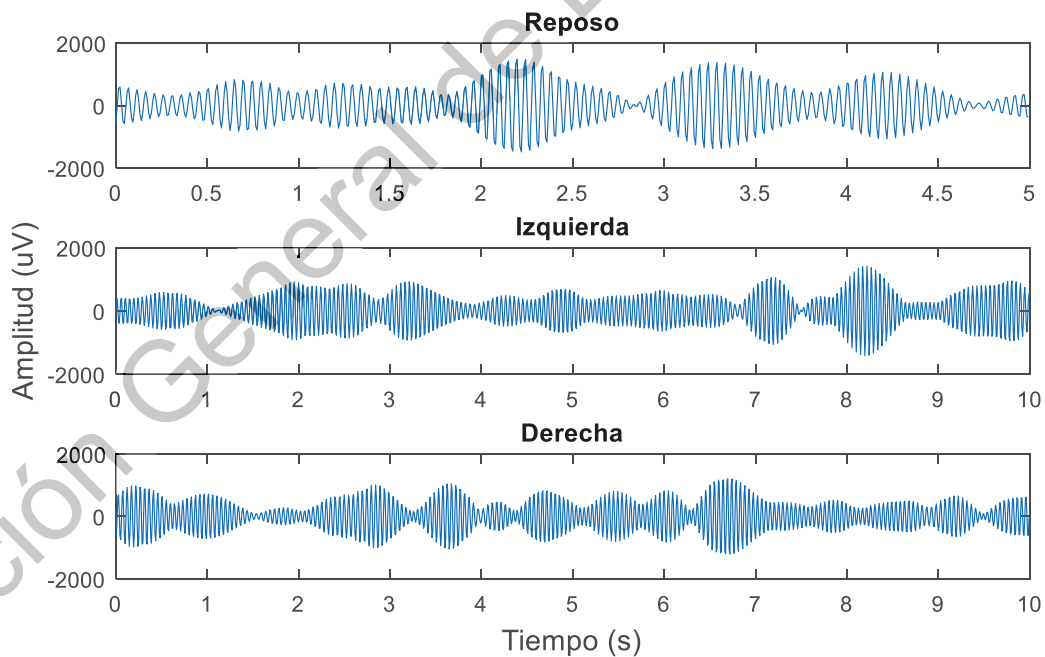


Figura 4.13. Nodo 11: Banda de Frecuencia (20-22 Hz)

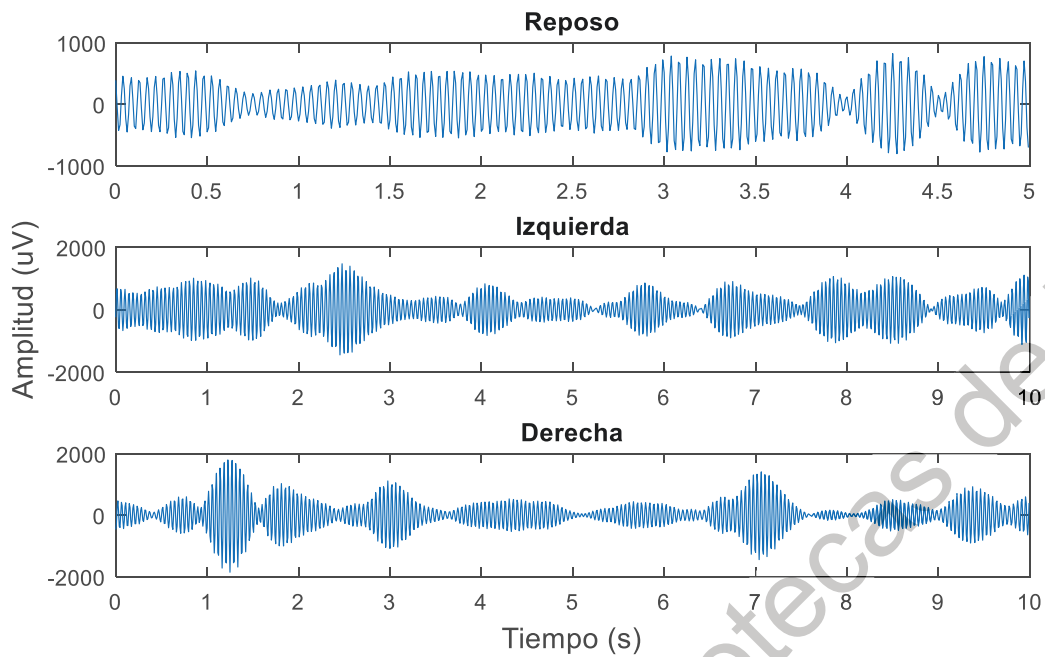


Figura 4.14. Nodo 12: Banda de Frecuencia (22-24 Hz)




Figura 4.15. Nodo 13: Banda de Frecuencia (24-26 Hz)




Figura 4.16. Nodo 14: Banda de Frecuencia (26-28 Hz)




Figura 4.17. Nodo 15: Bandas de Frecuencia (28-30 Hz)




Figura 4.18. Nodo 16: Bandas de Frecuencia (30-32 Hz)

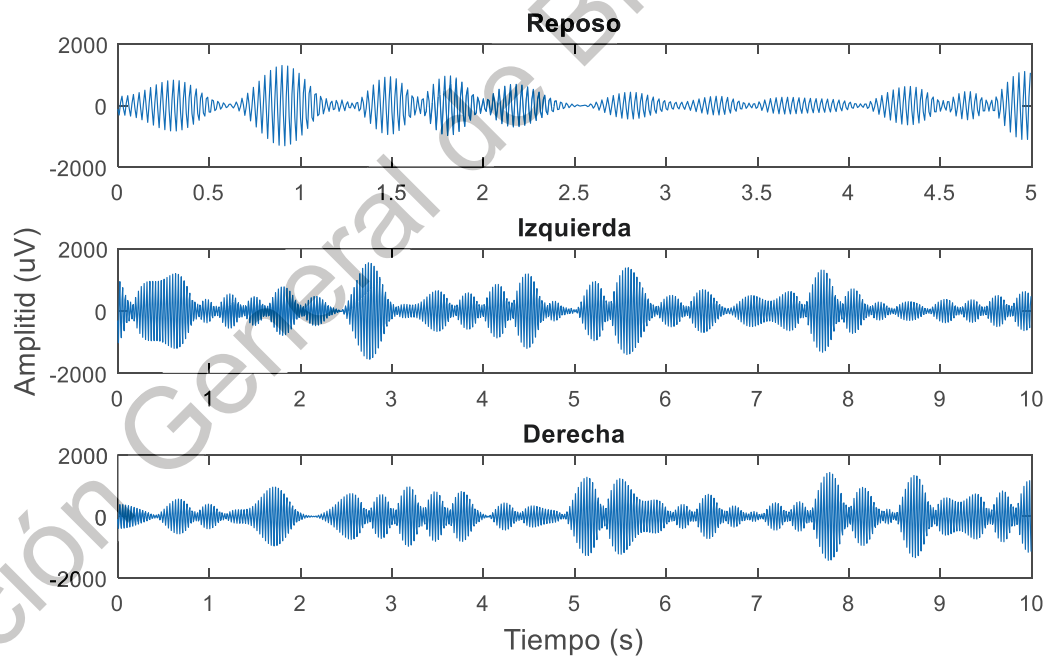


Figura 4.19. Nodo 17: Bandas de Frecuencia (32-34 Hz)




Figura 4.20. Nodo 18: Bandas de Frecuencia (34-36 Hz)




Figura 4.21. Nodo 19: Bandas de Frecuencia (36-38 Hz)




Figura 4.22. Nodo 20: Bandas de Frecuencia (38-40 Hz)




Figura 4.23. Nodo 21: Bandas de Frecuencia (40-42 Hz)




Figura 4.24. Nodo 22: Bandas de Frecuencia (42-44 Hz)




Figura 4.25. Nodo 23: Bandas de Frecuencia (44-46 Hz)




Figura 4.26. Nodo 24: Bandas de Frecuencia (46-48 Hz)




Figura 4.27. Nodo 25: Bandas de Frecuencia (48-50 Hz)




Figura 4.28. Nodo 26: Bandas de Frecuencia (50-52 Hz)




Figura 4.29. Nodo 27: Bandas de Frecuencia (52-54 Hz)




Figura 4.30. Nodo 28: Bandas de Frecuencia (54-56 Hz)




Figura 4.31. Nodo 29: Bandas de Frecuencia (56-58 Hz)




Figura 4.32. Nodo 30: Bandas de Frecuencia (58-60 Hz)



Figura 4.33. Nodo 31: Bandas de Frecuencia (60-62 Hz)




Figura 4.34. Nodo 32: Bandas de Frecuencia (62-64 Hz)

Una vez que las señales EEG son descompuestas por la TWP, las diferentes bandas de frecuencia o nodos obtenidos son analizados a través de los diferentes algoritmos de dimensión fractal: BCD, HFD y KFD, para identificar características en estas bandas que permitan ser asociadas a los pensamientos: reposo, izquierda y derecha.

Con el fin de identificar cuales nodos, sensores y algoritmos de dimensión fractal son los más discriminantes para ser asociados a los 3 pensamientos, estos son evaluados por medio de ANOVA, resultando que el algoritmo BCD en diferentes sensores y diferentes bandas de frecuencia: sensor 1 nodo 19, sensor 2 nodo 31, sensor 3 nodo 5, sensor 4 nodo 18, sensor 6 nodo 25, sensor 9 nodo 30, sensor 10 nodo 21, sensor 11 nodo 9 y sensor 14 nodo 31, son los más útiles para diferenciarlos. Las Figuras (4.35) a la (4.43) muestran la distribución de los datos para los sensores y nodos más discriminantes estimados por ANOVA, de igual manera se muestran algunos ejemplos de otros nodos con las otras técnicas en la

sección de anexos, en ellos se aprecian los 3 estados mentales no tan bien diferenciados como en los nodos seleccionados.

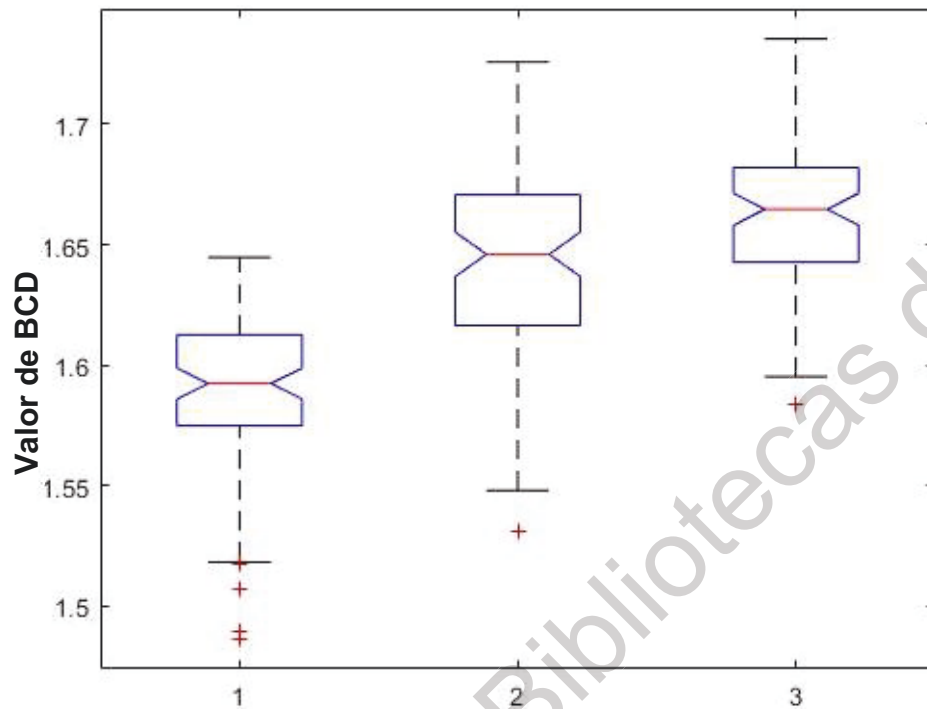


Figura 4.35. Sensor 1 nodo 19. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura 4.36. Sensor 2 nodo 3. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura 4.37. Sensor 3 nodo 5. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura 4.38. Sensor 4 nodo 18. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura 4.39. Sensor 6 nodo 25. 1: Reposo, 2: Izquierda y 3: Derecha.

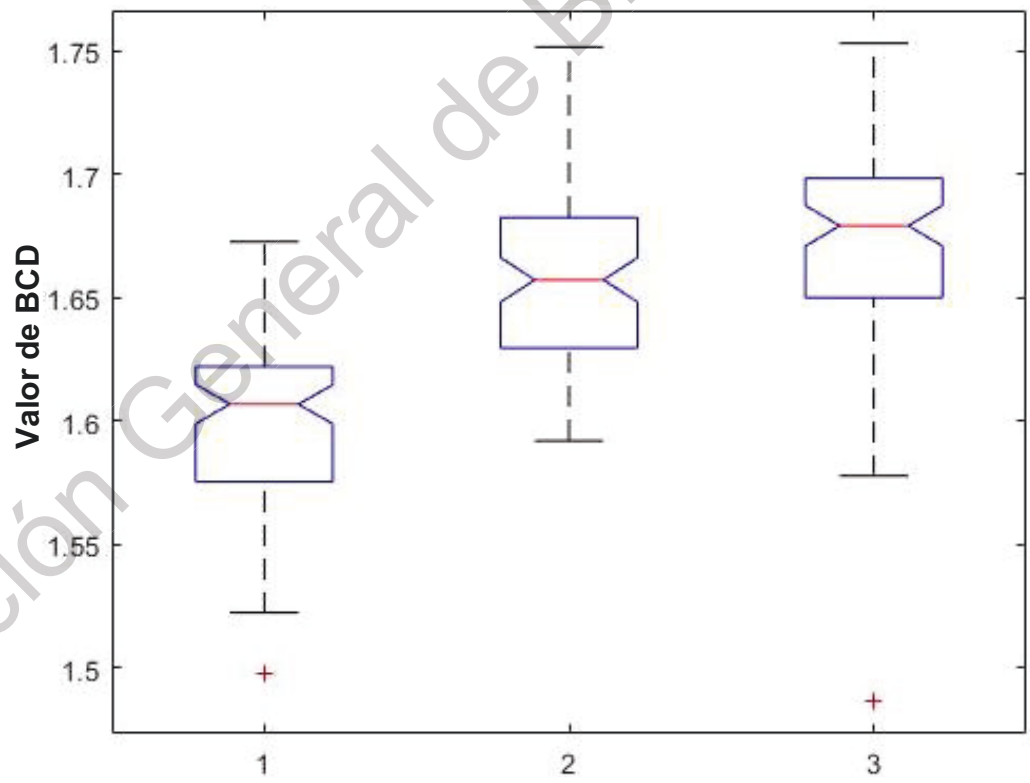


Figura 4.40. Sensor 9 nodo 30. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura 4.41. Sensor 10 nodo 21. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura 4.42. Sensor 11 nodo 9. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura 4.43. Sensor 14 nodo 31. 1: Reposo, 2: Izquierda y 3: Derecha.

Es importante mencionar que la elección del algoritmo BCD, sensores y nodos fueron elegidos en base al valor de P (valor-p < 1×10^{-25} en promedio), el cual es estimado por ANOVA y este indica la probabilidad de que un conjunto de datos se parezca a otro conjunto. La Tabla 4.1 muestra los sensores, la banda de frecuencia (nodo) y el algoritmo más capaz para la discriminar entre los 3 diferentes pensamientos. Adicionalmente, se muestran los valores de media y desviación estándar de la distribución de los datos para los diferentes pensamientos: reposo, izquierda y derecha, así como el valor de probabilidad (valor-P).

Tabla 4.1. Resultados ANOVA para el algoritmo, sensores y nodos más discriminativos.

Algoritmo FD	Sensor	Nodo	REPOSO		IZQUIERDA		DERECHA		ANOVA
			Media	Σ	Media	σ	Media	Σ	Valor-P
BCD	1	19	1.5885	0.0332	1.6446	0.0416	1.6633	0.0317	7.07E-33
BCD	2	31	1.6018	0.0323	1.6772	0.0403	1.6596	0.0366	2.01E-32
BCD	3	5	1.5860	0.0343	1.6462	0.0367	1.6570	0.0391	1.00E-30
BCD	4	18	1.5845	0.0327	1.6403	0.0374	1.6507	0.0362	4.96E-29
BCD	6	25	1.5732	0.0374	1.6189	0.0356	1.6415	0.0373	1.45E-26
BCD	8	30	1.6001	0.0345	1.6577	0.0341	1.6709	0.0411	4.78E-30
BCD	10	21	1.5946	0.0343	1.6431	0.0392	1.6556	0.0414	5.26E-22
BCD	11	9	1.5707	0.0359	1.6301	0.0401	1.6454	0.0441	3.77E-28
BCD	14	31	1.6073	0.0308	1.6587	0.0407	1.6707	0.0338	7.08E-27

Finalmente, una vez que las características (algoritmo, sensor y banda de frecuencia) más discriminantes han sido seleccionadas, estas son empeladas para entrenar una red neuronal con el fin de clasificar los pensamientos de manera automática. Con el fin de realizar esta tarea, los límites de los valores obtenidos con ANOVA son usados para generar datos aleatorios entre estos rangos para entrenar la red neuronal llamada perceptrón multicapa (MLP), la cual fue configurada de la siguiente manera: 9 entradas, neuronas en la capa oculta y 3 salidas las cuales corresponden que son los pensamientos estudiado. Para una correcta elección del número de neuronas en la capa oculta, según la literatura debe ser el doble de las entradas. (Lopez-Ramirez, et al. 2016). Sin embargo, después de un estudio exhaustivo experimental se determinó que 30 neuronas es un valor adecuado para el propósito de clasificación de estos 3 pensamientos. Ya entrenada la red neuronal se valida la red con el resto de la información, la cual pertenece a los sujetos 6 al 10, resultando que una eficiencia del 74.51% es obtenida.

Ya con la red neuronal entrenada y validada, se procedió a enviar la información de la salida de la red: 1-0-0 para reposo (no hacer nada), 0-1-0 apertura

de la tenaza y 0-0-1 para cerrado de la tenaza, a la Arduino UNO con el fin de que esta controle el puente H que manda la información al efector final. La Figura (4.44) muestra el comportamiento del efector final, tenaza, cuando se le manda el pensamiento de 1 persona siendo primero el reposo, apertura y cerrado.




Figura 4.44 Comportamiento del efector final (a) reposo, (b) apertura y (c) cerrado.

Es muy importante mencionar que como el método no es 100% eficiente, si la secuencia de datos afecta el funcionamiento de la tenaza este opta por mandar al efector final que no haga nada. Por ejemplo, si el método interpreta que la persona está pensando reposo, apertura, apertura, lo que indicaría que la tenaza debería abrir 2 veces lo que no es posible ya que apertura de la tenaza en el primer pensamiento llega a su tope, lo que no permite una nueva apertura por lo que el sistema se protege en deja en reposo el sistema y esto indica que siempre se esta evaluando el ultimo pensamiento que se enviará al robot.

4.3 Discusión de Resultados

Los resultados obtenidos por la red neuronal artificial se pueden visualizar por medio de una matriz de confusión. La matriz de confusión es un arreglo compuesto por entradas (datos a clasificar) y salidas (3 estados mentales), que evalúa el desempeño de un algoritmo computacional, en este caso, la red neuronal. Dicho de otra manera, es una tabla que muestra el número de datos clasificados correctamente del total analizado.

Para cada estado, la tasa de clasificación (T. clasif.) se calcula mediante la Ecuación (4.1):

$$T. \text{ clasif.} = \frac{\text{Pruebas Correctas}}{\text{Pruebas Totales}} \times 100\% \quad (4.1)$$

Tabla 4.2. Matriz de confusión.

Salidas \ Entradas	Reposo	Izquierda	Derecha	Núm de Pruebas	Clasificación (%)
Reposo	71	14	0	85	83.53%
Izquierda	0	59	26	85	69.41%
Derecha	0	25	60	85	70.59%
Eficiencia Total					74.51%

Haciendo un análisis de la matriz de confusión, se aprecia que la clasificación para el estado de imaginación motora “reposo” es claramente diferenciable, ya que se obtuvo una tasa de clasificación de 83.55%, confundiendo solamente 14 entradas del total con otra clasificación. En cuanto a la imaginación motora para el estado izquierdo se obtuvo una eficiencia del 69.41% y para el derecho 70.59%, lo que se considera bastante bueno, ya que en el trabajo presentando por Cruz (2018) se obtuvo una eficiencia del 48.24% y 67.05% para clasificar los pensamientos a la izquierda y derecha, respectivamente, indicando que esta nueva metodología es capaz de discernir entre esos dos pensamientos de forma más eficiente que el

trabajo previo. Adicionalmente, es importante mencionar que este nuevo método es de baja carga computacional, ya que los nodos seleccionados en la TWP pueden ser llevado a un filtro y el algoritmo seleccionado es solamente la diferencia de los puntos que conforman la señal.

Dirección General de Bibliotecas de la UAQ

Dirección General de Bibliotecas de la UAQ

CAPÍTULO 5

5.1 Conclusiones

Siguiendo la metodología propuesta se obtuvo un buen resultado acorde a los objetivos, al final se obtuvo una eficiencia total del 74.51% en la matriz de confusión, lo cual permite diferenciar de manera clara el estado mental de reposo de los otros dos estados mentales ya que de 85 muestras de entrada confunde solo 14 muestras con el estado mental de izquierda, dando un 83.53% de eficiencia. Y entre los estados mentales izquierda y derecha, a pesar de que hay menor porcentaje de eficiencia (69.41% y 70.59% respectivamente), aún es un porcentaje significativo, ya que de las 85 muestras en la entrada en el caso de la izquierda solo confunde con la derecha 26 muestras y para el estado mental derecha solo confunde con izquierda 25 muestras. Estos porcentajes permiten el control de un actuador para realizar la acción deseada de acuerdo a la salida obtenida.

Sin embargo, como no se logró una eficiencia del 100% y aún existe cierta confusión en la clasificación de las salidas, con el fin de proteger el sistema, cuando una salida es igual a la anterior el actuador, que en este caso es la pinza del brazo, no se moverá y quedará como en el caso anterior.

5.2 Prospectivas

Como trabajo futuro se puede mejorar la metodología aplicando otras técnicas de procesamiento que permitan una mejor extracción de características, así mismo se pueden plantear otros algoritmos de clasificación, para obtener un porcentaje de eficiencia mayor.

Siguiendo el planteamiento de problema de la presente tesis, una mejora que se puede hacer es la realización de un sistema completo, lo cual consiste en un software propio, con el cual se logre la toma de las señales EEG y se adquiera una base de datos más grande.

Como proyecto a largo plazo, otra mejora para este trabajo es lograr una adquisición de señales y que en tiempo real se logre el movimiento de un actuador.

Referencias Bibliográficas.

Adeli H., Ghosh-Dastidar S., & Dadmehr N., (2007). A wavelet-chaos methodology for analysis of EEGs and EEG subbands to detect seizure and epilepsy. *IEEE Transactions on Biomedical Engineering*, 54, pp. 205-211.

Amezquita Sanchez J. P., Chavez Alegria O., Valtierra Rodrigue, M., Cruz Abeyro J. A. L., Millan Almaraz J. R., & Dominguez Gonzalez A., (2017). Detection of ULF geomagnetic anomalies associated to seismic activity using EMD method and fractal dimension theory. *IEEE Latin America Transactions*, 15, pp. 197–205.

Amezquita Sanchez J. P., & Adeli, H., (2016). Signal processing techniques for vibration-based health monitoring of smart structures. *Archives of Computational Methods in Engineering*, 23, pp. 1-15.

Arango J. E., Mazo J. & Palacio., (2013). Sistema para rehabilitación del síndrome del miembro fantasma utilizando interfaz cerebro-computador y realidad aumentada. *Revista Ibérica de Sistemas e Tecnologías de Informação*, 11, pp. 93-106.

Arboleda C., García E., Posada A., & Torres R., (2009). Diseño y construcción de un prototipo de interfaz cerebro-computador para facilitar la comunicación de personas con discapacidad motora. *Revista EIA*, 11, pp. 105-115.

Arduino, (2019), ¿QUÉ ES ARDUINO? Consultado Marzo 27, 2019. Recuperado de: <http://arduino.cl/que-es-arduino/>

Bermúdez A., (2013). Técnicas de procesamiento de EEG para detección de eventos. Tesis de Maestría, Universidad Nacional de la Plata, Argentina.

Bermúdez G., García P. J., Brizion D., & Roca J., (2013). Adquisición, procesamiento y clasificación de señales EEG para el diseño de sistemas BCI basados en imaginación de movimiento. *VI Jornada de introducción a la investigación de la UPCT*, 6, pp. 10-12.

Corona Ramírez L., (2014), Sensores y actuadores, aplicaciones con Arduino- México D.F., México, Grupo Editorial Patria.

Cortés J. A., Cano H. B., & Chaves J. A., (2007). Del análisis de Fourier a las wavelets - transformada continua wavelet (CWT). *Scientia et Technica*, 5, pp. 133-138.

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

De la Torre Abaitua Javier de la Torre (2012). Procesado de señales EEG para un interfaz cerebro-máquina (BCI). Tesis Maestría, Universidad Carlos III de Madrid.

Dorador J. M., Ríos P., Flores I., & Juárez A., (2004). Robótica y prótesis inteligentes. *Revista Digital Universitaria*, 6, pp. 1-15.

Esqueda Elizondo José Jaime., (2002). MATLAB e interfaces gráficas. CONATEC Instituto tecnológico de ciudad madero

García F. V., García M. A., & Hernández K., (2004). Diseño de prótesis mioeléctrica. Tesis Licenciatura. Instituto Politécnico Nacional.

Gigola S., Ortiz F., D'Attellis C.E., Silva W., & Kochen S., (2004). Prediction of epileptic seizures using accumulated energy in a multiresolution framework. *Journ. of Neurosc. Meth.*, 138, pp. 107–111.

Gokhale M. Y., & Daljeet Kaur Khanduja., (2010). Time domain signal analysis using wavelet packet decomposition approach. *International Journal of Communications, Network and System Sciences*, 3, pp. 321–329.

González S. J., (2014). Técnicas de toma de datos y análisis de electroencefalografía. Universidad de Sevilla.

- Guevara, M.A., Sanz-Martín, A., Corsi-Cabrera, M., Amezcua-Gutiérrez, C., & Hernández-González, M., (2010). CHECASSEN: Programa para revisar señales EEG fuera de línea. *Revista mexicana de Ingeniería Biomédica*, 31, pp.135-141.
- Higuchi, T., (1988). Approach to an irregular time series on the basis of the fractal theory. *Japan: Geophysics Research Laboratory*, 31, pp. 277-283.
- INEGI, 2014. Instituto Nacional de Estadística y Geografía., (2014). Encuesta Nacional de la Dinámica Demográfica, 2014
- Izaurieta F., Saavedra C., (2000). Redes neuronales artificiales. Departamento de física, Universidad de Concepción, Concepción Chile.
- Katz, M. (1988). Fractals and the analysis of waveforms, *Computers in Biology and Medicine*, 18, pp. 145-156.
- Lopez-Caracheo F., Bazaldúa-Camacho, A., Perez-Ramirez C., Valtierra-Rodriguez M & Amezcua-Sanchez J. P., (2018). Fractal dimension-based methodology for sudden cardiac death prediction. *IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC 2018)*. Ixtapa, Mexico.
- Lopez-Ramirez, M., Ledesma-Carrillo, L., Cabal-Yeppez, E., Rodriguez-Donate, C., Miranda-Vidales, H., & Garcia-Perez, A. (2016). EMD-based feature extraction for power quality disturbance classification using moments. *Energies*, 9, pp. 565.
- Matich, D. J., (2001). Redes neuronales: conceptos básicos y aplicaciones. Universidad Tecnológica Nacional – Facultad Regional Rosario Departamento de Ingeniería Química Grupo de Investigación Aplicada a la Ingeniería Química (GIAIQ).
- Mendoza L. E., Peña J., Muñoz-Bedoya L., A. & Velandia-Villamizar H. J., (2013). Procesamiento de señales provenientes del habla subvocal usando wavelet packet y redes neuronales. *Tecnológicas*, pp. 655-66.

- Mendoza P., Montoro C., Guerra E., Almanza D., Rostro H., Romero R., & Ibarra M., (2016). Quaternion-based signal analysis for motor imagery classification from electroencephalographic signals. *Sensors*, 6, pp. 330-336.
- Moreno-Gomez, A., Amezcua-Sanchez, J., Valtierra-Rodriguez, M., Perez Ramirez, C., Dominguez-Gonzalez, A., & Chavez-Alegria, O. (2018). EMD-Shannon entropy-based methodology to detect incipient damages in a truss structure. *Applied Sciences*, 8, pp. 2020-2068.
- Negrete J., Gutiérrez J., Flores T., Cariño R., & 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, pp. 111-121.
- Orhan U., Hekim M., Ozer M. (2011). EEG signals classification using the k-means clustering and a multilayer perceptron neural network model. *Expert Systems with Applications*, 38, pp.13475–13481.
- Pfurtscheller G., Müller-Putz G., Pfurtscheller J., & Rupp R. (2005). EEG-Based asynchronous bci controls functional electrical stimulation in a tetraplegic patient. *EURASIP Journal on Applied Signal Processing*, 19, pp. 3152-3155.
- Rafiee, J., Rafiee, M. A., Prause, N., & Schoen, M. P. (2011). Wavelet basis functions in biomedical signal processing. *Expert systems with Applications*, 38, pp. 6190-6201.
- Ramos-Argüelles F., Morales G., Egozcue S., Pabón R.M., Alonso M.T., (2009). Técnicas básicas de electroencefalografía: principios y aplicaciones clínicas. *Anales del sistema sanitario de Navarra*, 32, pp. 69-82.
- Santillán M. L., DGDC-UNAM., (2014). Innovación en el diseño de prótesis inteligentes.http://ciencia.unam.mx/leer/404/innovacion_en_el_diseno_de_protesis_inteligentes

Tapan Gandhi, Bijay Ketan Panigrahi, & Sneha Anand. (2011). A comparative study of wavelet families for EEG signal classification. *Neurocomputing.*, 74, pp. 3051-3057.

UPM. (2019). Universidad politécnica de Madrid departamento de electrónica, automática e informática industrial. Capítulo 12: Introducción al procesamiento digital de señales. <http://www.elai.upm.es/webantigua/spain/Publicaciones/pub99/intropds.pdf>

Wang, B. (2005). Detection of structural damage using fractal dimension technique. *Journal of Vibration and Shock*, 24, 87-88.

Wolpaw J.R., Birbaumer N., Heetderks W.J., McFarland D.J., Peckham P.H., Schalk G., Donchin E., Quatrano L.A., Robinson C.J., & Vaughan T.M., (2000). Brain-computer interface technology: a review of the first international meeting. *IEEE Transactions on Rehabilitation Engineering*, 8, pp. 164–173.

Dirección General de Bibliotecas de la UAQ

Anexos




Figura A.1. Técnica BCD. Sensor 1 nodo 1. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.2. Técnica BCD. Sensor 1 nodo 2. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.3. Técnica BCD. Sensor 1 nodo 3. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.4. Técnica BCD. Sensor 1 nodo 4. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.5. Técnica BCD. Sensor 1 nodo 5. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.6. Técnica BCD. Sensor 1 nodo 6. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.7. Técnica BCD. Sensor 1 nodo 7. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.8. Técnica BCD. Sensor 1 nodo 8. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.9. Técnica BCD. Sensor 1 nodo 9. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.10. Técnica BCD. Sensor 1 nodo 10. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.11. Técnica BCD. Sensor 1 nodo 11. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.12. Técnica BCD. Sensor 1 nodo 12. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.13. Técnica BCD. Sensor 1 nodo 13. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.14. Técnica BCD. Sensor 1 nodo 14. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.15. Técnica BCD. Sensor 1 nodo 15. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.16. Técnica BCD. Sensor 1 nodo 16. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.17. Técnica BCD. Sensor 1 nodo 17. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.18. Técnica BCD. Sensor 1 nodo 18. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.19. Técnica BCD. Sensor 1 nodo 19. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.20. Técnica BCD. Sensor 1 nodo 20. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.21. Técnica BCD. Sensor 1 nodo 21. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.22. Técnica BCD. Sensor 1 nodo 22. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.23. Técnica BCD. Sensor 1 nodo 23. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.24. Técnica BCD. Sensor 1 nodo 24. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.25. Técnica BCD. Sensor 1 nodo 25. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.26. Técnica BCD. Sensor 1 nodo 26. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.27. Técnica BCD. Sensor 1 nodo 27. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.28. Técnica BCD. Sensor 1 nodo 28. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.29. Técnica BCD. Sensor 1 nodo 29. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.30. Técnica BCD. Sensor 1 nodo 30. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.31. Técnica BCD. Sensor 31 nodo 1. 1: Reposo, 2: Izquierda y 3: Derecha.

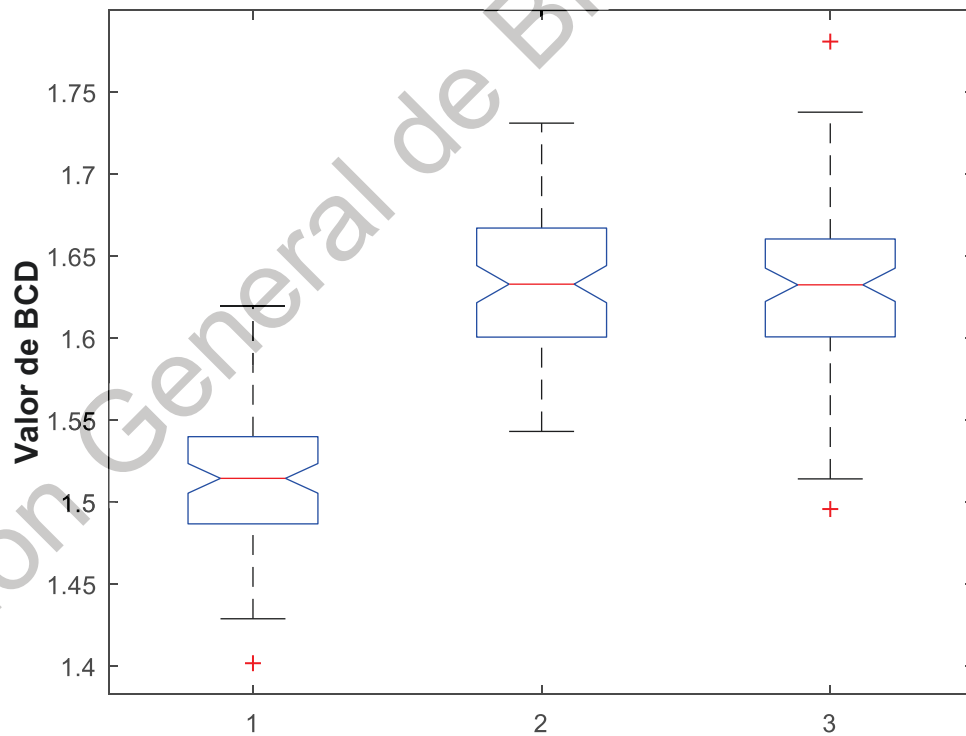


Figura A.32. Técnica BCD. Sensor 32 nodo 1. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.33. Técnica HFD. Sensor 1 nodo 1. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.34. Técnica HFD. Sensor 1 nodo 2. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.35. Técnica HFD. Sensor 1 nodo 3. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.36. Técnica HFD. Sensor 1 nodo 4. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.37. Técnica HFD. Sensor 1 nodo 5. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.38. Técnica HFD. Sensor 1 nodo 6. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.39. Técnica HFD. Sensor 1 nodo 7. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.40. Técnica HFD. Sensor 1 nodo 8. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.41. Técnica HFD. Sensor 1 nodo 9. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.42. Técnica HFD. Sensor 1 nodo 10. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.43. Técnica HFD. Sensor 1 nodo 11. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.44. Técnica HFD. Sensor 1 nodo 12. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.45. Técnica HFD. Sensor 1 nodo 13. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.46. Técnica HFD. Sensor 1 nodo 14. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.47. Técnica HFD. Sensor 1 nodo 15. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.48. Técnica HFD. Sensor 1 nodo 16. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.49. Técnica HFD. Sensor 1 nodo 17. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.50. Técnica HFD. Sensor 1 nodo 18. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.51. Técnica HFD. Sensor 1 nodo 19. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.52. Técnica HFD. Sensor 1 nodo 20. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.53. Técnica HFD. Sensor 1 nodo 21. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.54. Técnica HFD. Sensor 1 nodo 22. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.55. Técnica HFD. Sensor 1 nodo 23. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.56. Técnica HFD. Sensor 1 nodo 24. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.57. Técnica HFD. Sensor 1 nodo 25. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.58. Técnica HFD. Sensor 1 nodo 26. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.59. Técnica HFD. Sensor 1 nodo 27. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.60. Técnica HFD. Sensor 1 nodo 28. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.61. Técnica HFD. Sensor 1 nodo 29. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.62. Técnica HFD. Sensor 1 nodo 30. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.63. Técnica HFD. Sensor 1 nodo 31. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.64. Técnica HFD. Sensor 1 nodo 32. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.65. Técnica katz. Sensor 1 nodo 1. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.66. Técnica katz. Sensor 1 nodo 2. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.67. Técnica katz. Sensor 1 nodo 3. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.68. Técnica katz. Sensor 1 nodo 4. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.69. Técnica katz. Sensor 1 nodo 5. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.70. Técnica katz. Sensor 1 nodo 6. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.71. Técnica katz. Sensor 1 nodo 7. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.72. Técnica katz. Sensor 1 nodo 8. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.73. Técnica katz. Sensor 1 nodo 9. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.74. Técnica katz. Sensor 1 nodo 10. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.75. Técnica katz. Sensor 1 nodo 11. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.76. Técnica katz. Sensor 1 nodo 12. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.77. Técnica katz. Sensor 1 nodo 13. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.78. Técnica katz. Sensor 1 nodo 14. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.79. Técnica katz. Sensor 1 nodo 15. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.80. Técnica katz. Sensor 1 nodo 16. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.81. Técnica katz. Sensor 1 nodo 17. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.82. Técnica katz. Sensor 1 nodo 18. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.83. Técnica katz. Sensor 1 nodo 19. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.84. Técnica katz. Sensor 1 nodo 20. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.85. Técnica katz. Sensor 1 nodo 21. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.86. Técnica katz. Sensor 1 nodo 22. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.87. Técnica katz. Sensor 1 nodo 23. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.88. Técnica katz. Sensor 1 nodo 24. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.89. Técnica katz. Sensor 1 nodo 25. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.90. Técnica katz. Sensor 1 nodo 26. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.91. Técnica katz. Sensor 1 nodo 27. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.92. Técnica katz. Sensor 1 nodo 28. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.93. Técnica katz. Sensor 1 nodo 29. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.94. Técnica katz. Sensor 1 nodo 30. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.95. Técnica katz. Sensor 1 nodo 31. 1: Reposo, 2: Izquierda y 3: Derecha.




Figura A.96. Técnica katz. Sensor 1 nodo 32. 1: Reposo, 2: Izquierda y 3: Derecha.