



Universidad Autónoma de Querétaro
Facultad de Ingeniería
Ingeniería Biomédica



**Metodología basada en la transformada wavelet y los
parámetros de Hjorth para la clasificación de Imaginación
motora usando señales electroencefalográficas**

TESIS

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

Presenta:

Carlos Andrés Ruiz Vázquez

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
CAMPUS AEROPUERTO



**METODOLOGÍA BASADA EN LA TRANSFORMADA WAVELET Y LOS PARÁMETROS
DE HJORTH PARA LA CLASIFICACIÓN DE IMAGINACIÓN MOTORA USANDO
SEÑALES ELECTROENCEFALOGRÁFICAS**

T E S I S

Como parte de los requisitos para obtener el título de

INGENIERO BIOMÉDICO

Línea Terminal

BIOSEÑALES Y BIOINSTRUMENTACIÓN

Presenta

CARLOS ANDRÉS RUIZ VÁZQUEZ

Dirigido por:

**DR. JUAN PABLO AMÉZQUITA SÁNCHEZ
DR. CARLOS ANDRÉS PÉREZ RAMÍREZ**

SINODALES:

DR. JUAN PABLO AMÉZQUITA SÁNCHEZ (11508)
Presidente

DR. CARLOS ANDRÉS PÉREZ RAMÍREZ (14209)
Secretario

DR. MARTÍN VALTIERRA RODRÍGUEZ (11869)
Vocal

ING. JOSÉ DE JESÚS SANTANA RAMÍREZ (14831)
Suplente

Santiago de Querétaro, Qro., Julio 2019

RESUMEN

El vertiginoso crecimiento de la sociedad moderna demanda nuevas soluciones y servicios para la conservación y recuperación de la calidad de vida de los individuos afectados por los altos índices de desgaste físico y mental que la misma sociedad cosmopolita ha provocado en su desarrollo. La capacidad de moverse libremente y realizar un trabajo es un factor que se ha visto afectado por los padecimientos neurodegenerativos o amputaciones, al limitar la calidad de vida y afectar en su desarrollo profesional. Una forma de contrarrestar esta situación es apoyando al estudio de la imaginación motora también conocida como imaginación no hablada, es el pensar en mover el cuerpo o pensar realizar una actividad sin ejecutarla. La eficiente clasificación de los diferentes estados mentales registrados mediante señales de electroencefalografía (EEG), es un pilar fundamental para el desarrollo de interfaces cerebro-computadora (BCI, Brain Computer Interface, por sus siglas en inglés). Dicha tarea posee un alto grado de complejidad, dada la naturaleza de la señal de EEG y a la extrema cantidad de ruido. Por lo tanto, para abordar dichos inconvenientes, el presente trabajo se basa en la transformada wavelet de paquetes combinada con los parámetros de Hjorths, actividad, movilidad y complejidad, y redes neuronales para el análisis de señales EEG con el fin de poder asociar estas características a los diferentes pensamientos estudiados en esta tesis: reposo, derecha e izquierda.

Palabras clave: Procesamiento de señales EEG, imaginación motora, señales EEG, interfaces cerebro-computadora, parámetros de Hjorth, red neuronal, ANOVA.

DEDICATORIA

Esta tesis va dedicada a mi mamá, Yolanda Vázquez Ibarra, quien siempre me motivó a ser un hombre honrado, por su cariño y amor incondicional, a tener el coraje en los momentos más oscuros para salir adelante, y quien es mi ejemplo a seguir, a mi papa, Antonio Ruiz Robles, quien siempre me apoyó en cualquier proyecto y reto que se me presentara, por todo su conocimiento, principios y hábitos que me han hecho el hombre que soy ahora; a mis hermanos Luis Antonio y María Fernanda, que nunca dejaron de hacerme reír e impulsarme a ser mejor.

A mis padrinos, Carlos Corona y Erika Ruiz, quienes siempre me apoyaron incondicionalmente y vieron por en todo momento

A mi tío Antonio Carbajal, quien me cuidó y vio por mí en todo momento. Por su apoyo incondicional y su incomparable amistad

A mi tío Leonel Vázquez, quien siempre me brindó la oportunidad de trabajar con él y me otorgo mi primer trabajo.

AGRADECIMIENTOS

Agradezco principalmente a la vida y a la salud, por permitirme concluir esta gran etapa de mi vida y permitirme iniciarme en el ámbito laboral.

A mi papá, Antonio, quien nunca escatimó en cariño y recursos para formar la familia que hoy en día tiene. Todo mi éxito también es parte del tuyo, papá. Gracias por todo, papá.

A mi mamá, Yolanda, que nunca dejaste de sonreír al ver a tus hijos y el éxito que estos cosechaban a diario. Gracias por siempre corregirme y nunca dejar de exigirme a diario. Gracias, mamá.

A mis hermanos, Luis Antonio y María Fernanda, gracias por siempre impulsarme a ser mejor, sin olvidar jamás el divertirme y disfrutar la vida. Gracias, hermanos.

A todos mis familiares, no quisiera omitir a alguno, quienes me brindaron palabras de aliento para llegar a la meta.

A mis amigos Daniel Alejandro Morales y Jorge Luis González, con quienes compartí experiencias que nunca voy a olvidar, y aprendí mucho sobre la paciencia y humildad.

A mi Alma Mater, la Universidad Autónoma de Querétaro, por, como dice su lema, educarme en la verdad y en el honor.

A mis docentes, de los que me llevo experiencias muy gratas, tanto dentro como fuera del aula. En especial quiero mencionar a mi director de tesis, el Dr. Juan Pablo Amézquita Sánchez, por su valiosa orientación en la culminación de este proyecto y por su invaluable amistad; al Dr. Carlos Andrés Pérez Ramírez, por siempre ser un gran amigo y siempre explicarme las dudas que me surgían, a pesar de lo abundantes que eran; al Dr. Martín Valtierra Rodríguez, por sus valiosos consejos y por impartirme una de las mejores clases que he tenido.

ÍNDICE GENERAL

RESUMEN	iii
DEDICATORIA	iv
AGRADECIMIENTOS	v
ÍNDICE GENERAL	vi
ÍNDICE DE FIGURAS	viii
ÍNDICE DE TABLAS	xii
1. CAPÍTULO I: Introducción	1
1.1. Introducción.....	2
1.2. Antecedentes.....	4
1.3. Descripción del Problema.....	7
1.4. Justificación.....	9
1.5. Hipótesis y Objetivos.....	11
1.5.1. Hipótesis.....	11
1.5.2. Objetivo General.....	11
1.5.3. Objetivos Particulares.....	11
1.6. Planteamiento General.....	12
2. CAPÍTULO II: Revisión de Literatura	14
2.1. Revisión de Literatura.....	15
2.2. Señales EEG.....	15
2.2.1. Sensores para medición de señales EEG	17
2.3. MATLAB.....	18
2.4. Arduino.....	20
2.5. Procesamiento Digital de Señales.	21
2.5.1. Transformada Wavelet de Paquetes.....	22
2.5.2. Parámetros de Hjorth.....	23
2.5.2.1. Actividad.....	24
2.5.2.2. Movilidad.....	24
2.5.2.3. Complejidad.....	24

2.5.3. ANOVA.....	25
2.5.4. Red Neuronal Artificial.....	25
3. CAPÍTULO III: Metodología.....	29
3.1. Metodología Propuesta.....	30
3.2. Diadema EMOTIV EPOC+. Sistema de Adquisición de Señales EEG.....	33
3.3. Material humano.....	34
3.4. Actuador.....	35
3.5. Arduino Mega.....	36
4. CAPÍTULO IV: Resultados.....	39
4.1. Puesta de Experimento.....	40
4.2. Resultados.....	41
4.3. Discusión de Resultados.....	63
5. CAPÍTULO V: Conclusiones y Prospectivas.....	66
5.1. Conclusiones.....	67
5.2. Prospectivas.....	68
6. REFERENCIAS.....	69
6.1. Referencias Bibliográficas.....	69
7. Anexos.....	74
Anexo 1 Gráficas de ANOVAS de los Parámetros de Hjorth.....	75

ÍNDICE DE FIGURAS

Figura 1.1. Planteamiento General del Problema.....	11
Figura 2.1. Tipos de electrodos a) <i>Electrodo de tipo invasivo</i> y b) <i>electrodo de tipo no invasivo</i>	18
Figura 2.2. Ventana Matlab R2018a®.....	20
Figura 2.3. Script de la conexión serial del Arduino programada desde Matlab....	21
Figura 2.4. Descomposición de una señal empleando la TWP.	22
Figura 2.5. Función de activación: signo, semilineal y sigmoide.....	26
Figura 2.6. Estructura de una neurona artificial.....	27
Figura 2.7. Perceptrón multicapa.....	28
Figura 3.1. Metodología Propuesta.	30
Figura 3.2. Diadema EMOTIV EPOC+ y ubicación de los sensores SI 10-20.....	33
Figura 3.3. Ubicación de los electrodos CMS / DRL respectivamente; vista lateral derecha y vista lateral izquierda	34
Figura 3.4 Brazo robótico STEREN modelo K-680	36
Figura 3.5. Arduino Mega.....	37
Figura 3.6. Arduino IDE y configuración de Arduino	38
Figura 4.1. Puesta de Experimento: Adquisición de datos	40
Figura 4.2. Puesta de experimento: Movimiento actuador: (a) Computadora, (b) Microcontrolador Arduino Mega (denotado por el cuadro de color verde), (c) Puente H L298N (denotado por el cuadro de color amarillo) y (d) Actuador brazo robótico.....	41
Figura 4.3. Nodo 1, banda de frecuencia de 0 a 2Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	42
Figura 4.4 Nodo 2, banda de frecuencia de 2 a 4Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	43
Figura 4.5. Nodo 3, banda de frecuencia de 4 a 6Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	43
Figura 4.6. Nodo 4, banda de frecuencia de 6 a 8Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	44

Figura 4.7. Nodo 5, banda de frecuencia de 8 a 10Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	44
Figura 4.8. Nodo 6, banda de frecuencia de 10 a 12Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	45
Figura 4.9. Nodo 7, banda de frecuencia de 12 a 14Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	45
Figura 4.10. Nodo 8, banda de frecuencia de 14 a 16Hz, (a) Reposo, (b) Izquierda y (c) Derecha	46
Figura 4.11. Nodo 9, banda de frecuencia de 16 a 18Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	46
Figura 4.12. Nodo 10, banda de frecuencia de 18 a 20Hz, (a) Reposo, (b) Izquierda y (c) Derecha	47
Figura 4.13. Nodo 11, banda de frecuencia de 20 a 22Hz, (a) Reposo, (b) Izquierda y (c) Derecha	47
Figura 4.14. Nodo 12, banda de frecuencia de 22 a 24Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	48
Figura 4.15. Nodo 13, banda de frecuencia de 24 a 26Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	48
Figura 4.16. Nodo 14, banda de frecuencia de 26 a 28Hz, (a) Reposo, (b) Izquierda y (c) Derecha	49
Figura 4.17. Nodo 15, banda de frecuencia de 28 a 30Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	49
Figura 4.18. Nodo 16, banda de frecuencia de 30 a 32Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	50
Figura 4.19. Nodo 17, banda de frecuencia de 32 a 34Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	50
Figura 4.20. Nodo 18, banda de frecuencia de 34 a 36Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	51
Figura 4.21. Nodo 19, banda de frecuencia de 36 a 38Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	51

Figura 4.22. Nodo 20, banda de frecuencia de 38 a 40Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	52
Figura 4.23. Nodo 21, banda de frecuencia de 40 a 42Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	52
Figura 4.24. Nodo 22, banda de frecuencia de 42 a 44Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	53
Figura 4.25. Nodo 23, banda de frecuencia de 44 a 46Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	53
Figura 4.26. Nodo 24, banda de frecuencia de 46 a 48Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	54
Figura 4.27. Nodo 25, banda de frecuencia de 48 a 50Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	54
Figura 4.28. Nodo 26, banda de frecuencia de 50 a 52Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	55
Figura 4.29. Nodo 27, banda de frecuencia de 52 a 54Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	55
Figura 4.30. Nodo 28, banda de frecuencia de 54 a 56Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	56
Figura 4.31. Nodo 29, banda de frecuencia de 56 a 58Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	56
Figura 4.32. Nodo 30, banda de frecuencia de 58 a 60Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	57
Figura 4.33. Nodo 31, banda de frecuencia de 60 a 62Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	57
Figura 4.34. Nodo 32, banda de frecuencia de 62 a 64Hz, (a) Reposo, (b) Izquierda y (c) Derecha.....	58
Figura 4.35. Sensor AF4 nodo 31. 1: Reposo, 2: Izquierda y 3: Derecha.	59
Figura 4.36. Sensor AF4 nodo 2. 1: Reposo, 2: Izquierda y 3: Derecha.	59
Figura 4.37. Sensor F4 nodo 16. 1: Reposo, 2: Izquierda y 3: Derecha.....	60
Figura 4.38. Sensor O1 nodo 7. 1: Reposo, 2: Izquierda y 3: Derecha.	60
Figura 4.39. Sensor P7 nodo 21. 1: Reposo, 2: Izquierda y 3: Derecha	61

Figura 4.40 Comportamiento de la tenaza (a) reposo, (b) apertura y (c) cerrado
..... 63

ÍNDICE DE TABLAS

Tabla 3.1 Especificaciones técnicas del Arduino Mega.....	37
Tabla 4.1 Resultados de ANOVA para los sensores y nodos más discriminativos	61
Tabla 4.2. Matriz de confusión	65

CAPÍTULO I

Introducción

1.1 Introducción.

Actualmente, las interfaces humano-computadora (HCI, Human Computer Interfaces, por sus siglas en ingles), juegan un papel importante en la ejecución de tareas en la vida cotidiana del ser humano, tales como el teclado, mouse, joystick, y las pantallas táctiles, las cuales son un referente de herramientas con un grado alto de interacción con el humano promedio. El uso de este tipo de interfaces provee un control superior al usuario sobre una máquina; sin embargo, existen situaciones en que estas interfaces no son viables, especialmente cuando se trata de personas incapaces de generar los movimientos musculares necesarios para realizar la tarea o personas con limitaciones resultado de un traumatismo a nivel medular (Lebedev & Nicolelis, 2006). Por lo tanto, en años recientes, el desarrollo y la integración de las tecnologías de las interfaces cerebro-computadora (BCI, Brain Computer Interface, por sus siglas en inglés), han proporcionado una herramienta para superar esta dificultad, sin embargo, la investigación y la implementación de dichas tecnologías no es tan extensa y accesible en nuestro país. Actualmente el desarrollo de las investigaciones en torno a las BCI en México apunta a tener características accesibles y tener un costo-beneficio adecuado. Para poder tener dichas características es necesario contar con las metodologías adecuadas para el software y el hardware a implementar en los pacientes. Una alta complejidad en los algoritmos de clasificación propondría componentes mucho más costosos y esto elevaría el costo del producto final (Philip, 2006).

La viabilidad de la implementación de nuevas herramientas las cuales proporcionen o recuperen una capacidad pérdida supondría un incremento en el nivel de vida de las personas afectadas, en este caso pacientes con problemas motrices. El lograr un equilibrio entre el costo-beneficio (supóngase tanto económico como a nivel práctico) y los beneficios que se adquieren al recurrir a dichas tecnologías debe ser ampliamente considerado dado el estado fisiológico del paciente. El desarrollo integral del paciente posterior al uso de una BCI conlleva a una reintegración a la sociedad en cuestión. El ritmo tan acelerado en la cual se ve inmiscuida la sociedad hoy en día es un generador de estrés, lo cual afecta de manera directa la calidad de vida que gozan las personas. Esta tendencia provoca

que se requieran mayores inversiones de capital en el desarrollo de tecnología para satisfacer las necesidades y mantener una calidad de vida apropiada a la época. Todo esto debe ser con un carácter integral, sin descuidar el medio ambiente y el sentido humanista. Las exigencias de la sociedad para saciar necesidades de grupos aislados son cada día más latentes, considerando el hecho de que se prevé elevar la media de vida en conjunto con los niveles de calidad de vida de la sociedad; enfermedades degenerativas o amputaciones son algunas de las principales afecciones de carácter irreparable, siendo una de las principales áreas por combatir proponiendo alternativas para reducir la brecha de discapacidad del individuo.

El desarrollo de una sociedad capitalista como en la que se ve inmiscuida la sociedad hoy en día tiene una alta exigencia tanto física como intelectual, la eficiencia, el tiempo y los recursos son factores cardinales para la realización del trabajo y el desarrollo de herramientas. Sin embargo, el incremento en la cantidad de individuos con padecimientos neurodegenerativos, lesiones medulares o amputaciones genera una demanda en el uso de prótesis; se estima que entre 250,000 y 500,000 personas sufren cada año en todo el mundo de lesiones medulares (WHO, 2013), provocando la creación de un área desatendida.

Actualmente, el auge de las prótesis inteligentes demanda un uso mayor de sensores, actuadores y de materiales inteligentes (Dorador-González et al. 2004). El analizar la actividad cerebral mediante el uso de señales de electroencefalografía proporcionan un nuevo canal de control para el uso de una prótesis inteligente, sin embargo, esto conlleva a superar obstáculos dada la naturaleza de la señal. La capacidad de recuperar la independencia motriz resulta ser un elemento clave para el desarrollo y crecimiento a nivel social como personal de cualquier individuo. Por estas razones, la gran trascendencia de las investigaciones encaminadas al diseño de interfaces hombre-computadora (HCI) ha sido notable y sobresaliente para sentar precedentes de la aplicación de estas interfaces a las prótesis inteligentes, como bien lo menciona Farry et al. (1996). Este medio de comunicación auxilia a personas con discapacidad para realizar actividades motoras, las cuales en un

momento eran imposibles de realizar, o bien, sirve para controlar herramientas con un enfoque diferente.

Comúnmente, las bioseñales o señales provenientes del cuerpo humano son de baja amplitud y estas están inmiscuidas en mucho ruido principalmente la obtenidas del cerebro, lo que propone una serie de condiciones adversas de resolver mediante herramientas convencionales. Por ello, para tratar con estos inconvenientes, se es necesario el uso de algoritmos eficientes de procesamiento de este tipo de señales que permita verificar patrones de movimiento, que puedan ser, clasificados para una futura vinculación con el movimiento de una prótesis, esto con el fin de mejorar la calidad de vida de los pacientes. La complejidad de diseñar una BCI que cumpla con las necesidades del paciente recae en los obstáculos a los cuales se enfrenta el equipo, dada la naturaleza de las señales de EEG, al ser estas señales de poca frecuencia y amplitud y al estar inmiscuidas en demasiado ruido; todo esto requiere de hardware y software especializado, y de algoritmos complejos.

En el presente trabajo de tesis se presenta una metodología basadas en el procesamiento avanzado de señales, específicamente de señales EEG para la estimación de patrones procedentes del pensamiento o imaginación motora que sea aplicable para el movimiento de actuadores tales como brazos robóticos.

1.2 Antecedentes.

En años recientes, múltiples investigadores han incursionado en el área del análisis de señales EEG para la identificación de patrones provenientes de la imaginación motora. Por ejemplo, a nivel internacional, Neuper et al. (2005) combinó las técnicas de procesamiento: parámetros auto regresivos adaptativos, patrones espaciales comunes con redes neuronales para la clasificación del movimiento de imaginaciones o preparaciones en 2-4 clases (por ejemplo, dedo índice izquierdo/derecho, pies, lengua). Los resultados obtenidos muestran que una eficiencia del 98%, 96% y 75% para tres sujetos es obtenida, respectivamente. Brunner et al. (2007), proponen una metodología basada en filtros espaciales, análisis de componentes independientes, patrones espaciales comunes y un

análisis de discriminantes lineales de Fisher para el análisis de imaginación motora relacionada a las extremidades superiores, lengua y pies. Los autores reportan que con la metodología propuesta se obtuvo una eficiencia del 80% para la correcta identificación de los movimientos. Por otra parte, Iturralde y Patrone (2012) presentan una metodología basada en el análisis de componentes principales, análisis de energía y una clasificación mediante redes neuronales de tipo perceptrón multicapa, dando una eficiencia del 72.5% en la identificación y clasificación de los patrones. Salgado y López (2017) emplean una caracterización mediante el uso de la transformada wavelet de paquetes, entropía, energía y máquinas de vector de soporte (SVM), análisis discriminante lineal (LDA) y clasificador KNN para la clasificación de los movimientos de la mano izquierda y derecha. De acuerdo a los resultados obtenidos se registró una eficiencia del 81.11% para el clasificador SVM, 79.11% para el clasificador LDA y 77.23% para clasificador KNN.

Recientemente, Baravalle et al. (2018) presentaron una metodología para la caracterización de la imaginación motriz, basada en la entropía de Shannon y la información medida de Fisher como características a analizar de las señales pertenecientes a la base de datos con el nombre de "EEG Motor Movement/Imagery Dataset" encontrada en el dominio Physionet (Schalk et al. 2004). Analizaron pruebas de imaginación motora correspondientes al hacer presión en las 4 extremidades con ojos cerrados de 109 pacientes. Obteniendo resultados favorables con la entropía y Fisher en el plano H X F al encontrar secuencias oscilantes y rítmicas, y delimitar los rangos de frecuencias Beta 1 [13-18], Beta 2 [18-31], Gamma 1 [31-41] y Gamma 2 [41-50] (todos estos en Hertz [Hz]) como los rangos de frecuencias más discriminantes en la imaginación motriz. Registrando altas tasas de actividad en la frontera entre el lóbulo parietal y frontal

Por otro lado, a nivel nacional Díaz-Blancas (2014) hace uso de la herramienta EEGLAB donde la transformada de Fourier y redes neuronales son empeladas para la extracción y clasificación de señales de EEG pertenecientes al parpadeo y el dolor muscular del brazo derecho ocasionado por un agente externo. Los resultados obtenidos muestran que una eficiencia del 96.8% es obtenida para

la clasificación de las señales de EEG adquiridas para cada tarea. Torres-García (2016) realiza una metodología para el análisis y la clasificación de electroencefalogramas (EEG) registrados durante el habla imaginada (arriba, abajo, izquierda, derecha y reposo). La extracción de características fue mediante la extracción de energías Wavelet (energía relativa, energía instantánea, energía Teager y energía jerárquica) y la implementación de la transformada discreta Wavelet (DWT). Para la clasificación propuso diversos clasificadores, tales como: Bosque aleatorio (Random Forest, RF), Sistema de inferencia difuso tipo Mamdani y Sistema de inferencia difuso (FIS). El sistema que mejor rendimiento proporciono fue el Sistema de inferencia difuso en su variante FIS3x3 (3 funciones de membresía para las variables error y número de canales) fue el más exitoso debido a que obtuvo el mejor compromiso entre el número de reglas y el rango de eficiencia más alto (70.94 ± 15.98 %). Carino y Cantillo (2016) proponen una metodología basada en filtros Laplacianos y mapas auto-organizados para la clasificación de la imaginación motriz de señales de EEG monitoreadas durante la imaginación de dos estados (derecha e izquierda) de la mano y reposo. Mediante el entrenamiento de los participantes con las tareas de imaginación de la mano y el reposo se diferenciaron las características espectrales. Los autores mencionan que una eficiencia del 80% es obtenida para la clasificación de los diferentes pensamientos.

A pesar de los buenos resultados reportados tanto a nivel internacional como a nivel nacional, la investigación de otros algoritmos de procesamiento y el desarrollo de metodologías innovadoras es necesaria con el fin de encontrar características dentro de las señales EEG que permitan incrementar la eficiencia de la clasificación del patrón, así como minimizar la cantidad de procesamiento empleado, ya que esto beneficiaría el poder implementar en línea la identificación o clasificación de patrones relacionados con el pensamiento o imaginación motora.

A nivel institucional, Sánchez y Rodríguez (2008) propone un diseño de BCI de arquitectura abierta para el análisis de potenciales enfocados a personas con problemas motrices, donde la transformada rápida de Fourier es empleada. Recientemente, Cruz-Ramírez (2018) propone una metodología basada en la

técnica de descomposición de modos empíricos de conjunto completo, teoría de fractales y redes neuronales para la clasificación de la imaginación motora de tres tareas: pensamiento a la derecha, izquierda y reposo, obteniendo una eficiencia de 71% de eficiencia para la identificación de los distintos pensamientos. Esta tesis de Cruz sienta las bases para investigaciones en torno a la clasificación de patrones en señales de EEG; sin embargo, es importante seguir investigando otras metodologías con el fin de incrementar la eficiencia de clasificación, reducir la cantidad de carga computacional, así como evaluar la eficiencia del método en mover un actuador, en este caso un brazo robótico comercial, complementando el trabajo de Cruz-Ramírez (2018), donde solamente es analizada la señal EEG.

1.3 Descripción del Problema.

Hoy en día, el uso de BCI, específicamente el de las BCI, es una propuesta revolucionaria que ha tomado un gran auge, dado que ayuda a reestablecer parcialmente la capacidad de un grupo de personas vulnerables para realizar tareas u operaciones que estaban perdidas para ellos, así como el incrementar en cierto grado su calidad de vida. El control preciso de una prótesis inteligente para un paciente cuadripléjico resultaría en un gran avance para el mismo, ya que se podría reincorporar a la sociedad en cierta medida.

Las bioseñales (señales provenientes del cuerpo humano) presentan diversos retos dada la naturaleza de la misma señal, como: baja amplitud, mucho ruido y naturaleza no estacionaria (señales variables a lo largo del tiempo). Por estas características dadas, investigadores a lo largo del mundo se han propuesto al estudio de estas, implementando desde la transformada de Fourier, transformadas Wavelet con diversos tipos de wavelet madres, analizando diversos indicadores como frecuencia, energías relativas, entropías, etc., hasta formas innovadoras de clasificación, como redes neuronales de tipo perceptrón multicapa y árbol de decisiones. Cabe destacar que cada método tiene su desventaja como su ventaja, por lo que hay un equilibrio entre las metodologías propuestas.

La transformada de Fourier representa un algoritmo eficiente para señales estacionarias (señales cuyas propiedades no varían a lo largo del tiempo), pero no tanto para las no estacionarias como las encontradas en sistemas BCI. La transformada wavelet de paquetes, por su parte, es un algoritmo en el dominio tiempo-frecuencia, implementable a señales no estacionarias, permite un análisis más preciso al tener un nivel de descomposición programable y proceder a un análisis más profundo mediante la descomposición de la señal en aproximaciones (filtro pasa baja) y detalles (filtro pasa altas), pero necesita una delimitación de parámetros muy rigurosa; un ejemplo es la elección de la wavelet madre que sea ad hoc al tipo de señal a analizar. Una mala elección del tipo de la ondoleta madre de la Wavelet podría conllevar en una mala caracterización de la señal o a obtener información apócrifa. Por otro lado, la Transformada MUSIC es más inmune al ruido; sin embargo, requiere un conocimiento a priori de la cantidad de frecuencias están contenidas en la señal, lo que en muchas acciones es imposible saberlo. Por otra parte, la carga computacional representa otra limitante, a pesar del gran desarrollo de la industria de las Graphic Processing Unit (GPU, por sus siglas en inglés), estas conllevan al uso de un computador y limitan el uso de los recursos al grado de implementar una mayor cantidad de tiempo en el procesamiento. La extracción del indicador como la frecuencia no representa ninguna tarea ardua, pero dada la naturaleza de las bioseñales que proporcionan información carente de sentido; el indicador de la energía relativa conlleva un número considerable de cálculos repetitivos para obtener la energía total y la energía en el j -ésimo nivel de descomposición, por lo que genera una gran carga computacional y sería un obstáculo para la implementación en un hardware embebido. Lo mismo sucede con la extracción de los indicadores de las entropías, el repetitivo cálculo de diversos coeficientes para la obtención de la entropía en diversos niveles conlleva una gran carga computacional. La idea principal es el elegir un indicador de baja carga computacional, que tenga un alto grado de eficiencia, se busca un indicador equilibrado y preciso. La extracción de los Parámetros de Hjorth resulta ser una tarea simple y ligera computacionalmente hablando. Al comparar la carga computacional y el número de procesos realizados para obtener los Parámetros de

Hjorth y alguno de los indicadores comentados previamente es apreciable que el cálculo de varianzas, desviaciones estándar y divisiones resulta ser más sencillo y con eficiencias similares que con el uso de otros indicadores.

De esta manera, es necesario o se requiere de un método de procesamiento de señales cerebrales eficiente que permita reducir carga computacional (tiempo de procesado), sin comprometer la eficacia del método en distinguir diferentes estados mentales y poder ser implementado por el movimiento de actuadores o prótesis en tiempo real. También es importante mencionar que la interacción de la metodología con la implementación de un actuador aún no ha sido explorada, el desarrollo de este trabajo podría conllevar diversos retos como la selección del microcontrolador adecuado y suficiente para dicha tarea, la selección del motor adecuado y el mecanismo de engranes ideal para su uso, satisfacer las necesidades de comunicación en línea y compatibilidad con el software de procesamiento, etc.

1.4 Justificación.

Situaciones adversas como lo son accidentes medulares, choques, amputaciones extremas limitan al paciente y lo sitúan en una posición adversa, al no tener una independencia motriz. El gran desarrollo de las BCI ha permitido la reincorporación en cierto grado de este tipo de pacientes mediante el uso de prótesis inteligentes. Por consiguiente, el desarrollo de la industria se ha enfocado en el control de las prótesis mediante señales de EEG por su alto grado de practicidad y que en muchos casos no se requiere de sistemas invasivos. Sin embargo, se requiere de un análisis avanzado para identificar patrones que permitan las distinciones entre los diferentes estados mentales del paciente, por lo que, el realizar una distinción o clasificación eficiente de los patrones en las señales de EEG y el discernir los canales que proporcionan información útil es vital, al conseguir esto permitiría:

1. Mejorar exponencialmente la practicidad de las prótesis inteligentes, al lograr que estas respondan exactamente a lo que piensa el paciente.
2. Manipular dispositivos externos que apoyen, complementen o sustituyan actividades humanas.
3. Atender a un grupo vulnerable de la sociedad, los cuales no tienen opciones viables para el uso de una prótesis.

Al día de hoy, se han propuesto metodologías desequilibradas en cuestión de carga computacional y eficiencia como las antes mencionadas en la sección de antecedentes. Técnicas que consumen una gran cantidad de recursos y que reportan una gran eficiencia, y viceversa. Al proponer nuevas metodologías para tareas de clasificación de imagen motriz se va trabajando un gran campo en desarrollo que va entorno al perfeccionamiento de las BCIs; el uso del hardware adecuado y la metodología correcta permitirían consumir una baja carga computacional y obtener una eficiencia equilibrada, esto para el accionamiento de actuadores en tiempo real. Por lo tanto, y con base a las razones antes mencionadas, la principal justificación de este trabajo versa en la generación de una metodología basada en los Parámetros de Hjorth que sea eficiente, genere una baja carga computacional y permita una comunicación armoniosa con el actuador. La implementación de una comunicación efectiva con el actuador conlleva al diseño de una BCI capaz de realizar los movimientos procesados por la metodología; en este caso se analizarán tres condiciones mentales (reposo, movimiento izquierda y movimiento a la derecha). El establecimiento de una BCI basada en la Transformada Wavelet de paquetes y los Parámetros de Hjorth sería una gran mejora con respecto a las diversas metodologías expuestas, al realizar las acciones de una BCI se puede comparar su utilidad y eficiencia en la vida cotidiana.

1.5 Hipótesis y Objetivos.

1.5.1 Hipótesis.

Mediante la implementación de una metodología basada en la Transformada Wavelet de paquetes, la extracción de características mediante los parámetros de Hjorth y Redes Neuronales es posible realizar un reconocimiento entre diferentes acciones motoras de manera automática, para la obtención del movimiento de un brazo robótico.

1.5.2 Objetivo General.

Proponer y desarrollar una metodología basada en la Transformada Wavelet de paquetes, los parámetros de Hjorth y redes neuronales para la clasificación automática del pensamiento o imaginación motora, específicamente pensamientos correspondientes a los movimientos de apertura y cerrado del efector final, así como caracterizar el reposo.

1.5.3 Objetivos Particulares.

1. Leer las señales electroencefalográficas (EEG) proporcionadas por el Dr. Mario Alberto Manzano Ibarra (Batres-Mendoza et al. 2016) mediante el uso del software MATLAB para su entendimiento y análisis.
2. Programar la transformada wavelet de paquetes haciendo uso del software MATLAB para procesar y descomponer la señal EEG en sus diferentes bandas de frecuencia.
3. Programar los parámetros de Hjorth (actividad, movilidad y complejidad) haciendo uso del software MATLAB para la identificación de características en la señal EEG.
4. Analizar las señales EEG proporcionadas por la Universidad de Guanajuato mediante la transformada wavelet de paquetes y los parámetros de Hjorth 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 una red neuronal de tipo perceptrón multicapa haciendo uso del software MATLAB para interpretar las características obtenidas en el objetivo 5 con el fin de clasificar los diferentes pensamientos o imaginación motora 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 implementándola a una tarjeta de desarrollo Arduino mediante el control desde Matlab para el control de un brazo robótico.

1.6 Planteamiento General.

El planteamiento general de desarrollo de este trabajo de tesis se basa en 4 etapas como se muestra en la Figura 1.1.

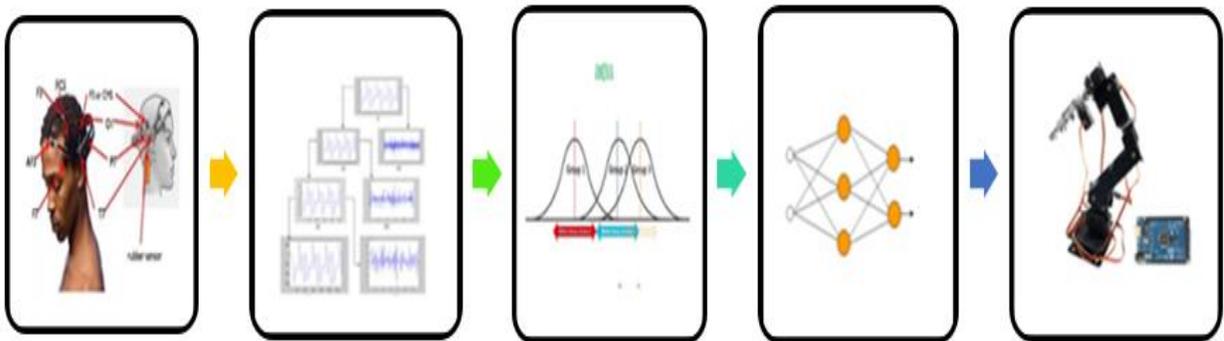


Figura 1.1 Planteamiento general del problema

1. **Señales ECG:** En esta primera etapa se requiere de la adquisición de señales de EEG mediante el hardware adecuado. El hardware propuesto es un casco lector de EEG de 14 canales. Es muy importante mencionar que las señales de ECG pertenecen a una base de datos proporcionada por del Dr. Mario Ibarra Manzano de la Universidad de Guanajuato. Estas señales

comprenden la imaginación motriz de 3 estados mentales izquierda, derecha y reposo

2. **Procesamiento de las señales y extracción de características:** En la segunda etapa, las técnicas de procesamiento transformada wavelet y los parámetros de Hjorth son aplicados a las señales EEG para la extracción de características que permitan clasificarlos estados mentales propuestos.
3. **Análisis estadístico:** En la tercera etapa, un análisis estadístico conocido como ANOVA (análisis de varianza) es empleado para determinar cuáles de las características calculadas son las que permiten una mayor discriminación entre los 3 estados mentales
4. **Clasificación de patrones:** En la cuarta etapa, las características más discriminantes estimadas en la etapa 3 son caracterizadas por una técnica de clasificación inteligente que permita reconocer el estado mental de forma automática con el fin de obtener una salida específica a un actuador.
5. **Actuador:** Finalmente, en esta etapa se realiza la conexión entre un microcontrolador Arduino y el software MATLAB, los actuadores del brazo robótico se conectan mediante puentes L298N al Arduino que posteriormente será controlado desde MATLAB y alimentado con los datos obtenidos en la etapa 4.

CAPÍTULO II

Revisión de Literatura

2.1 Revisión de Literatura.

En esta sección de la tesis se realiza la consulta bibliográfica y se exhiben los fundamentos teóricos que sustentan la aplicación de cada uno de los puntos de la metodología propuesta. Se hablan de los tipos de señales provenientes del encéfalo, de las técnicas computacionales para el tratamiento de dichas señales, de los algoritmos de clasificación, además de que se proporciona una breve reseña del software utilizado.

2.2 Señales EEG.

La electroencefalografía (EEG) es una técnica de monitoreo de carácter electrofisiológico que permite registrar la actividad eléctrica del cerebro que es producida por la actividad neuronal al interior del cerebro. Consiste en el uso de un arreglo de electrodos que están en contacto con el cuero cabelludo, aunque típicamente es una técnica no invasiva existe su variante invasiva (Babiloni et al. 2009). El EEG mide fluctuaciones de voltaje resultantes de la corriente iónica entre las conexiones neuronales del cerebro en un periodo de tiempo. Como cuestión diagnóstica se hace un enfoque especial en el contenido espectral del EEG, es decir catalogar las oscilaciones neuronales en tipos de ondas cerebrales.

De las señales electroencefalográficas medidas a partir de la actividad cerebral se obtiene la diferencia de potencial entre los electrodos y la frecuencia de dichas señales, entre otras características. Dicha actividad resulta muy compleja, ya que resultan ser señales estocásticas que presentan grandes variaciones dependiendo de la localización de los electrodos, del equipo usado para las mediciones y hasta del operario. La justificación a este problema recae en la infinidad de conexiones neuronales y a que la estructura craneal de los sujetos de prueba no es uniforme, además del variable estado mental del usuario y los movimientos involuntarios que pueda realizar (Babiloni et al. 2009).

De un electroencefalograma, los parámetros principales que se evalúan son (Adeli et al. 2002):

- Frecuencia o Longitud de Onda.

- Voltaje o Amplitud.
- Regularidad de la Forma de Onda.
- Regiones cerebrales e intervalos de tiempo en que ocurren anormalidades.

Las señales EEG contienen diversas frecuencias, quitando las frecuencias propias de otros sistemas del cuerpo humano como el musculoesquelético y el sistema cardiovascular, y la frecuencia del sistema de cableado eléctrico, las frecuencias que para fines clínicos o de estudio importan van de los 0.3 a los 30 Hz, intervalo constituido por diferentes bandas de frecuencia (Kellaway, 1990):

- *Delta (< 4 Hz)*: Banda con frecuencias muy bajas y a su vez las que poseen mayor amplitud. Estas frecuencias son obtenidas u observadas cuando el individuo está dormido; sin embargo, se observan también en estados de meditación. La producción del ritmo Delta, coincide con la regeneración y restauración del Sistema Nervioso Central.
- *Theta (4-8 Hz)*: Ondas predominantes cuando los sentidos están procesando información interna y el individuo se encuentra desconectado del mundo exterior, ensimismados. Se presentan también durante la meditación muy profunda. Se producen durante la transición entre vigilia y sueño.
- *Alfa (8-14 Hz)*: Tienen lugar en adultos sanos durante estados de escasa actividad cerebral, cuando hay relajación y los ojos están cerrados (zona occipital). Las ondas Alfa predominan cuando el Sistema Nervioso Central se encuentra en reposo, relajado pero despierto y atento. Esta frecuencia ayuda a la coordinación mental, la integración mente/cuerpo, la calma y la alerta.
- *Beta (14-30 Hz)*: Estas frecuencias ocurren/presentan en la región frontocentral del encéfalo, y se producen cuando el cerebro está despierto o en actividad mental intensa.
 - *Beta se puede subdividir en:*

Beta 1 (de 12-15 Hz): El individuo realiza una tarea fácil cognitivamente hablando.

Beta 2 (de 15-22 Hz): Cuando el Sistema Nervioso Central se encuentra comprometido en una tarea.

Beta 3 (de 22-30 Hz): Cuando el Sistema Nervio Central se encuentra concentrado en cogniciones altamente complejas, o integrando nuevas experiencias. Puede significar un estado de ansiedad o excitación como sería el caso de Individuos que padecen de un Trastorno de Ansiedad Generalizada

- *Gamma (>30 Hz):* No tiene importancia clínica, pero se asocia con la memoria y con estados que involucran emociones muy fuertes (agresividad o miedo, por mencionar algunas).

2.2.1 Sensores para medición de señales EEG

Actualmente, existen dos tipos de sensores para la medición de señales EEG: a) Invasivos y b) No Invasivos, mostrados en la Figura 2.1 Los primeros se adentran hasta la superficie de la corteza cerebral, obteniendo mejores señales del encéfalo; sin embargo, la principal desventaja con este tipo de sensores es que requieren de una operación quirúrgica para su instalación/implantación (electrocorticografía o ECoG). Por otro lado, los sensores no invasivos son más económicos y no requiere de una cirugía; por ello, este tipo de sensores son empleados en este trabajo de tesis. Sin embargo, el ocupar este tipo de sensor, las señales EEG están acompañadas de mucho ruido; lo cual es el resultado de la superposición de todas las señales de las neuronas del cerebro, así como del sistema de adquisición debido a que las señales adquiridas son de muy baja amplitud (no son tan específicos como el primer tipo de electrodos). (Vidal et al. 2014). Los sensores para la medición de señales EEG no invasivos son principalmente hechos de oro o plata con el objeto de una condición eficiente entre

el cerebro y el sistema de adquisición, además de tener una forma de copa con el objeto de obtener una mejor adhesión al cerebro.



Figura 2.1 Tipos de electrodos. a) Electrodo de tipo invasivo y b) electrodo de tipo no invasivo.

2.3 MATLAB

MATLAB es la abreviatura de MATrix LABoratory, el cual es un sistema de cómputo numérico que ofrece un entorno de desarrollo integrado con un lenguaje de programación propio (lenguaje M). Está disponible para las plataformas Unix, Windows, Mac OS X y GNU/Linux. El lenguaje M se trata de un lenguaje de alto nivel, con una organización de datos matricial; entre sus prestaciones básicas se hallan: la manipulación de matrices, la representación de datos y funciones, la implementación de algoritmos, la creación de interfaces de usuario (GUI) y la comunicación con programas en otros lenguajes y con otros dispositivos hardware. (Goering, 2014)

Matlab es un software muy usado en universidades y centros de investigación y desarrollo, ya que cuenta con muchas herramientas para el análisis de señales matriciales y vectoriales, las cuales son primordiales para la resolución de problemas de Ingeniería o de ciencias. Posee funciones integradas que facilitan a implementación, además de paquetes exclusivos de software programados en lenguaje M, denominados Toolbox. Dichos toolboxes son conjuntos de herramientas

diseñadas para ciertos campos de investigación, entre ellos destacan (Goering, 2014):

- Computo en paralelo.
- Control de sistemas.
- Procesamiento de señales y comunicaciones.
- Procesamiento de imagen y visión computacional.
- Finanzas computacionales.

La ventana o escritorio principal de MATLAB está conformada por otras sub-ventanas (ver Figura 2.2), entre las que se cuentan:

- *Current Folder* → Permite explorar los diversos directorios del computador para ejecutarlos de manera más cómoda.
- *Workspace* → Permite visualizar las diversas variables o estructuras que calculó el sistema, además de que permite trabajar con dichas variables arrastrándolas al Command Window.
- *Command Window* → Se realizan comandos o tareas y se ven los resultados de estas.
- *Editor* → Ésta es una de las partes más importantes de la ventana principal, ya que se puede ver, modificar y ejecutar el código de los ficheros.
- *Barra de Herramientas* → Ofrece una variedad de botones con opciones recurrentes para la modificación, ejecución, creación, organización de los archivos *.m* (*extensión de MATLAB*).

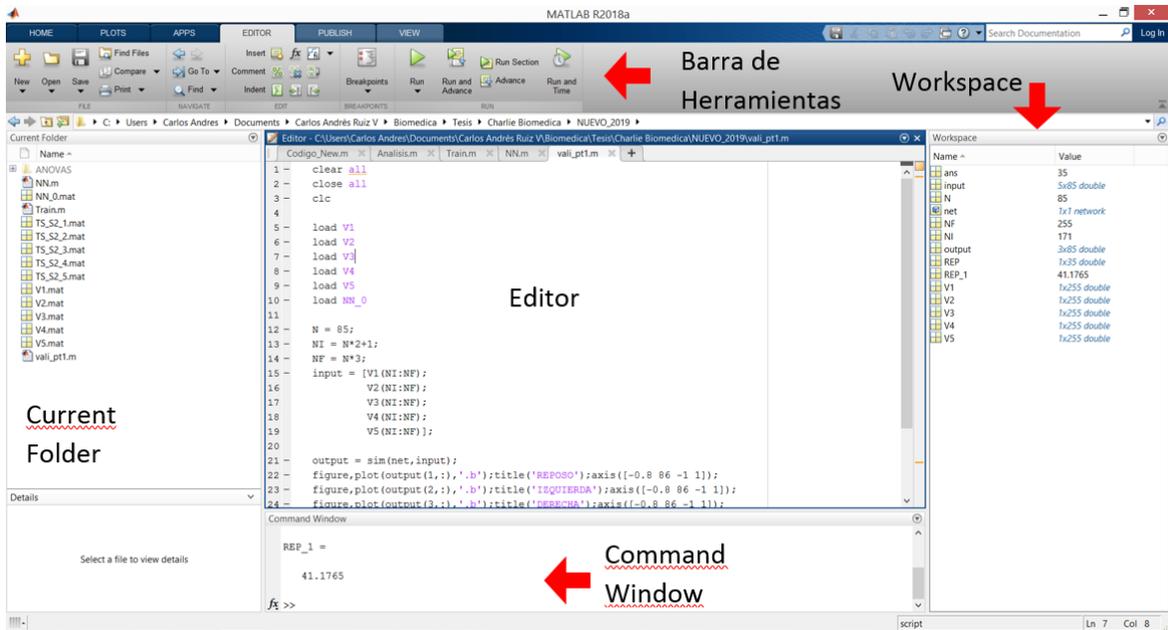
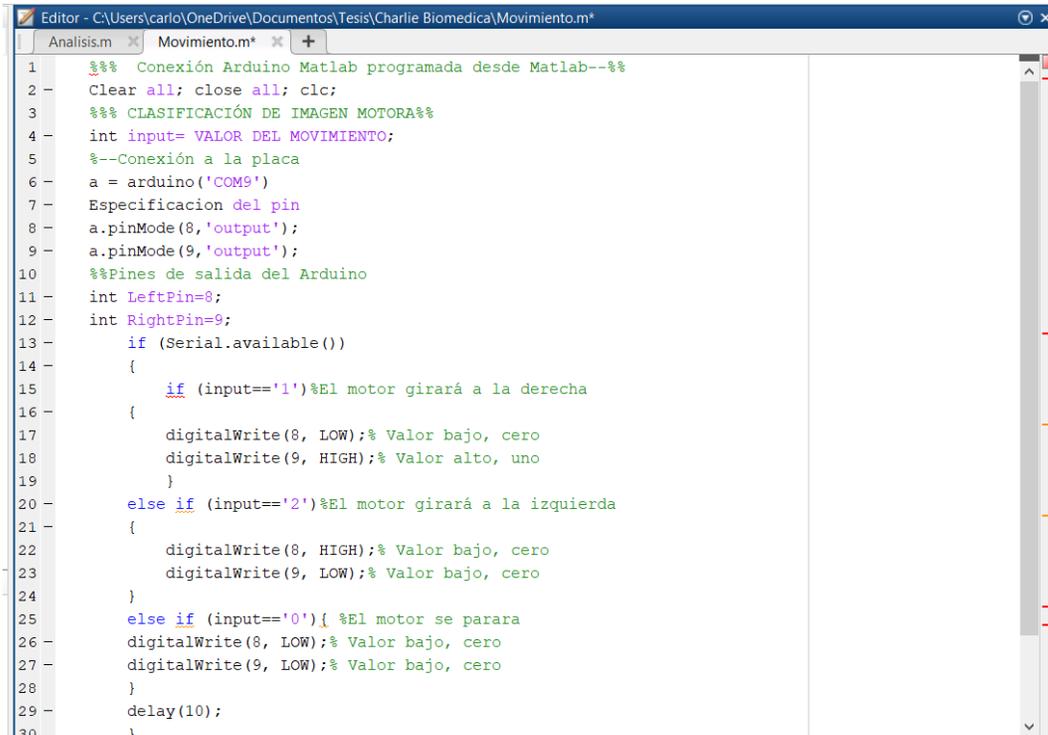


Figura 2.2 Ventana de Matlab.

2.4 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 los diferentes sensores y actuadores de una manera muy sencilla.

Arduino no es más que una PCB (Placa de Circuito Impreso o Printed Circuit Board definido en inglés) de superficie plana fabricada en un material no conductor, la cual costa de distintas capas de material conductor. Por lo tanto, Arduino implementa un determinado diseño de circuitería interna, de tal forma que 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, así como su programación a través de la plataforma/software MATLAB (ver Figura 2.3) (Lahart, 2009).

The image shows a screenshot of a MATLAB script editor window. The window title is "Editor - C:\Users\carlo\OneDrive\Documents\Tesis\Charlie Biomedica\Movimiento.m". The script content is as follows:

```
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 Especificacion 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 2.3. Script de la conexión serial del Arduino programada desde Matlab.

2.5 Procesamiento Digital de Señales.

El procesamiento digital de señales se refiere a la rama de la Ingeniería que se encarga de tratar, representar y transformar señales, con el fin de encontrar características dentro de ellas que sirvan para resolver un problema. Las amplitudes de las señales toman un número finito de valores, lo que permite que puedan ser procesadas por sistemas digitales, como Microprocesadores, Microcontroladores, Ordenadores, entre otros (Vignolo-Barchiesi, 2008)

Hay diversos métodos o técnicas digitales para el procesamiento de señales tales como la transformada de Fourier, técnicas de descomposición adaptivas; la transformada wavelet, entre otras, siendo la transformada wavelet la técnica más ocupada para la descomposición y análisis de señales no estacionarias (Ting et al. 2008), característica que presentan las señales EEG. Por esta razón, en este trabajo de tesis se aborda el análisis de señales EEG empleando la transformada wavelet de paquetes.

2.5.1 Transformada Wavelet de Paquetes

La transformada Wavelet de paquetes (TWP) es una técnica de procesamiento capaz de analizar señales con características estacionarias y no estacionarias (Xue et al., 2003), la cual permite descomponer una señal en tiempo en diferentes bandas de frecuencia de baja y alta frecuencia. A diferencia de la transformada wavelet discreta que descompone solamente las aproximaciones (filtro pasa-bajas) en una nueva aproximación en un nuevo detalle, la TWP descompone tanto las aproximaciones (filtro pasa-bajas) como los detalles (filtro pasa-altas) en una nueva aproximación y un nuevo detalle generando un mayor análisis de la señal, así como bandas de frecuencia uniformes, como se muestra en la Figura 2.4. La Figura 2.4 muestra un ejemplo de la descomposición de una señal empleando la TWP hasta el nivel tres, cada nivel lo conforman nodos que contienen los coeficientes de la descomposición, por ejemplo, el nodo (3,0) representa el primer nodo o primera banda de frecuencia de la descomposición en el tercer nivel. Cada nivel descompone la señal en 2^N bandas de frecuencia, donde N representa el nivel (Garcia-Perez et al. 2012) (Mallat, 1998).

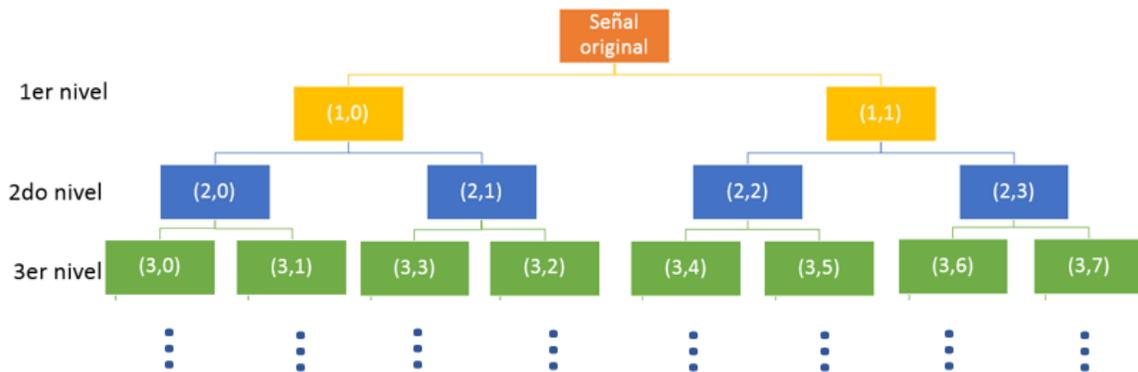


Figura 2.4. Descomposición de una señal empleando la TWP.

La TWP está definida por la Ecuación (2.1), donde j y k son números enteros que representan la escala y la traducción, respectivamente, y n representa el parámetro de modulación u oscilación.

$$W_{j,k}^n(t) = 2^{j/2} W^n(2^j t - k) \quad (2.1)$$

La TWP se obtiene a partir de dos ecuaciones recursivas (2.2) y (2.3), donde t es la variable del tiempo, $h(k)$ representa los coeficientes de los filtros pasa bajas, $g(k)$ representa los coeficientes de los filtros pasa altas y W^n la wavelet madre. Es muy importante mencionar que existen diferentes wavelets madre para descomponer la señal tales como Daubechies, Coiflets, Haar, Meyer, entre otras; sin embargo, la Daubechies 44 es la más recomendada para el análisis de señales biomédica, ya que permite una descomposición correcta de la información (Rafiee et al. 2011). Por lo tanto, esta wavelet madre es empleada en este trabajo de tesis.

$$W^{2n}(t) = \sqrt{2} \sum_{k=-\infty}^{\infty} h(k) W^n(2t - k) \quad (2.2)$$

$$W^{2n+1}(t) = \sqrt{2} \sum_{k=-\infty}^{\infty} g(k) W^n(2t - k) \quad (2.3)$$

2.5.2 Parámetros de Hjorth

Los parámetros de Hjorth (PH) son indicadores capaces de medir las propiedades estadísticas de una señal en tiempo (Hjorth, 1970), a través de tres medidas conocidas como actividad, movilidad y complejidad. Estos parámetros han encontrado buenos resultados en la extracción de características de señales EEG para la detección de propiedades de objetos físicos, así como detección de materiales / texturas de superficies, clasificación de modalidades de tacto (Kaboli et al. 2015), así como en el control de robots (Omrani et al. 2016), entre otras aplicaciones. Debido a sus buenos resultados en otras áreas, estos tres indicadores son investigados en este trabajo de tesis con el fin de ver su factibilidad para poder diferenciar entre los diferentes pensamientos.

2.5.2.1 Actividad

El PH llamado actividad representa la varianza de una señal en tiempo. Este parámetro es relacionado con el espectro de poder en el ámbito de frecuencia (Hjorth, 1970), y es calculado como:

$$Actividad = var[y(t)] \quad (2.4)$$

donde $y(t)$ es la señal a analizar.

2.5.2.2 Movilidad

El PH llamado movilidad representa la frecuencia media o la proporción de desviación estándar del espectro de poder (Hjorth, 1970). El está definido como la raíz cuadrada de varianza de la primera derivada de la señal $y(t)$ dividido por la varianza de la señal $y(t)$, como se muestra en la Ecuación (2.5):

$$Movilidad = \sqrt{\frac{var\left(\frac{dy(t)}{dt}\right)}{var(y(t))}} \quad (2.5)$$

2.5.2.3 Complejidad

El PH llamado complejidad representa el cambio en frecuencia de la señal. La complejidad compara la semejanza entre la señal analizad con una onda sinusoidal pura, donde el valor de complejidad converge a 1 si la señal es similar a la onda sinusoidal (Hjorth, 1970). El PH complejidad está dado por la Ecuación (2.6):

$$Complejidad = \frac{Movilidad\left(\frac{dy(t)}{dt}\right)}{Movilidad(y(t))} \quad (2.6)$$

2.5.3 ANOVA

El análisis de la varianza (ANOVA por sus siglas en inglés, ANalysis Of VAriance) permite determinar si diferentes tratamientos o las características seleccionadas de un conjunto de señales muestran diferencias

significativas o por el contrario puede suponerse que sus medias poblacionales no difieren. El análisis de la varianza permite superar las limitaciones de hacer contrastes bilaterales por parejas que son un mal método para determinar si un conjunto de variables con $n > 2$ difieren entre sí.

ANOVA estima dos parámetros:

1. Valor-P (probabilidad de que un conjunto contenga la misma información que otro conjunto),
2. Índice de Discriminación de Fisher o Valor-F. Ambos valores cuantifican la capacidad de la característica elegida para diferenciar entre los grupos de estudio.

El valor P toma valores en el rango [0-1], donde 0 indica alta capacidad de distinción, y 1, baja capacidad. Por su parte, el Valor-F adquiere altas y bajas magnitudes, que indican un alta y una baja tasa de separación, respectivamente. (Amézquita-Sánchez et al. 2016).

2.5.4 Red Neuronal Artificial.

Las redes neuronales artificiales (RNAs) son un modelo de clasificación computacional inspirado en el comportamiento observado en su homólogo biológico. Consiste en un gran conjunto de unidades, llamadas neuronas artificiales, conectadas entre sí para transmitirse señales, tal como una red neuronal este permite realizar una clasificación de patrones a través de la interacción entre diversas neuronas. Como unidad elemental en el sistema se ha de considerar a la neuronal, y se establece su capacidad de procesamiento entrelazado. (Schmidhuber, 2015)

Una RNA consta de los siguientes elementos o procesos:

- a) *Señales de Entrada.* Reciben información del ambiente exterior.
- b) *Pesos.* Cuando una neurona recibe L señales de entrada, los pesos se encargan de darle la importancia que merece a cada señal para la emisión

de la respectiva respuesta. Los pesos corresponden a la sinapsis entre las neuronas naturales.

c) *Regla de Propagación.* La regla de propagación suele ser una suma ponderada del producto escalar del vector de entrada y el vector de pesos. Cada neurona artificial j o nodo viene influenciado por las entradas y sus respectivos pesos (a ello se le llama *potencial postsináptico*) de la siguiente manera:

$$S_j = \sum_{i=0}^n w_{ji} a_i \quad (2.7)$$

donde w_{ij} es el factor de peso entre la neurona i y la neurona j ; j puede tomar valores de 1 a 52 con incrementos de 1; y a_i se refiere a las señales de entrada.

d) *Función de Activación o de Transferencia.* Proporciona el estado de activación de la neurona en función del estado anterior y del valor postsináptico. Existen diferentes tipos de funciones de activación mostradas en la Figura 2.5, siendo la función sigmoide la más recomendada para características de valor positivo y es representada por la Ecuación (2.8):

$$\alpha_j = \frac{1}{1 + \exp(-S_j)} \quad (2.8)$$

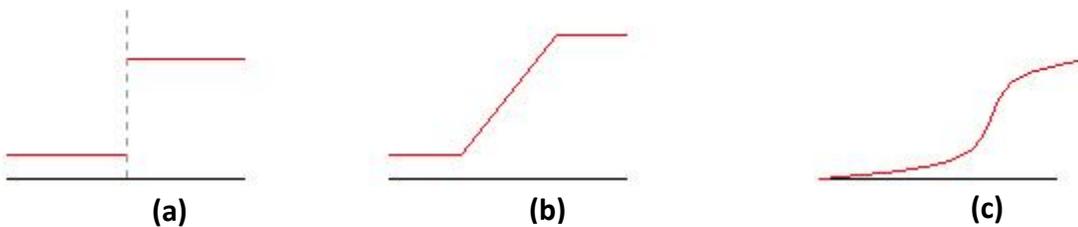


Figura 2.5. Función de activación (a) signo, (b) semilineal y (c) sigmoide.

e) *Salida.* Es única y depende del estado de activación actual de la neurona en cuestión, α_j . Generalmente, la salida de una neurona se relaciona con la función de activación gracias a la función de identidad; Como se muestra en la Ecuación (2.9) (ver Figura 2.6):

$$F(x) = x \quad \leftrightarrow \quad y_j = F(a_j) = a_j \quad (2.9)$$

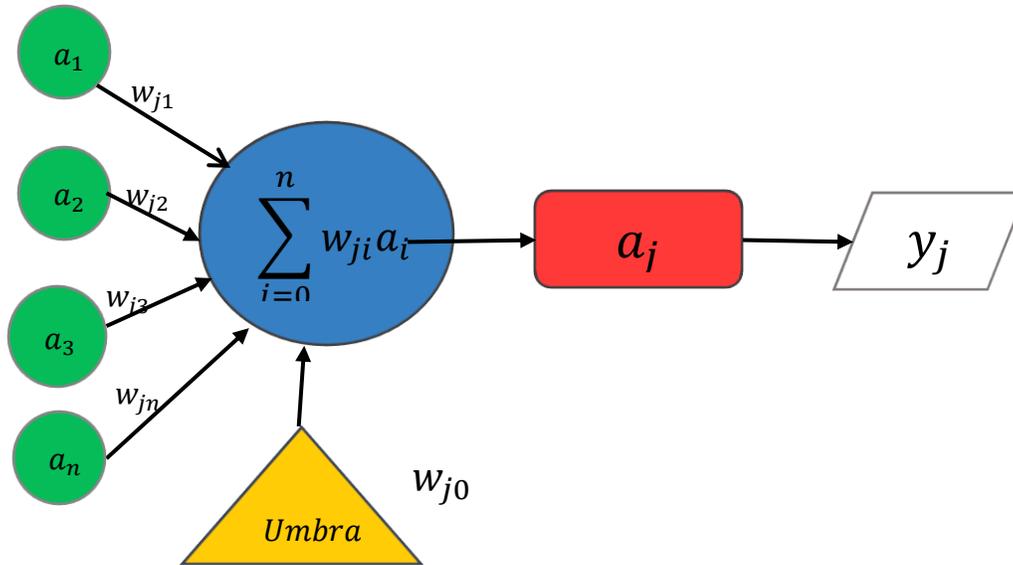


Figura 2.6. Estructura de una neurona artificial.

En el desarrollo de una red neuronal artificial se pueden distinguir dos etapas (Vourkas et al., 2000):

- a) *Fase de Entrenamiento.* Se ingresan las entradas y las correspondientes salidas, y se establecen los valores propios de los pesos con el fin de llegar a obtener los resultados buscados por el propio usuario.
- b) *Fase de Validación.* El objetivo es que la red se vuelva más robusta y pueda generalizar su aprendizaje y trabajar con nuestros casos. Esta fase es primordial para la robustez del sistema y evitar ciclados provocados por el aprendizaje obtenido en la fase de entrenamiento.

El Perceptrón Multicapa (del inglés Multi-layer Perceptron o MLP) es un tipo de Red Neuronal Artificial (RNN) muy popular, siendo este una mejora del Perceptrón Simple que puede resolver problemas que son no lineales. La arquitectura principal del MLP consta de 3 capas (ver Figura 2.7):

- una **capa de entrada**, neuronas que reciben las señales ingresadas al sistema a controlar o clasificar;
- una **capa oculta**, neuronas de transición, que transmiten las señales provenientes de capas previas a capas sucesivas;
- una **capa de salida**, neuronas que llevan a las salidas de la red u objetivos deseados.

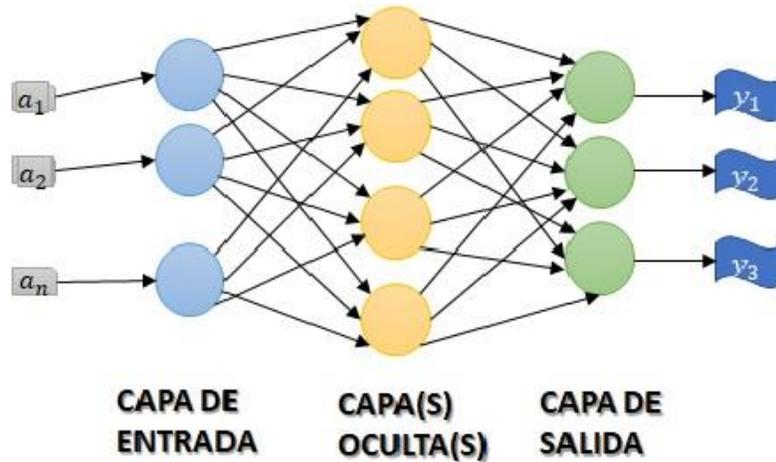


Figura 2.7. Perceptrón multicapa.

CAPÍTULO III

Metodología

3.1 Metodología propuesta

La metodología propuesta en este trabajo de tesis se basa en 6 etapas, las cuales son descritas a continuación (ver Figura 3.1):

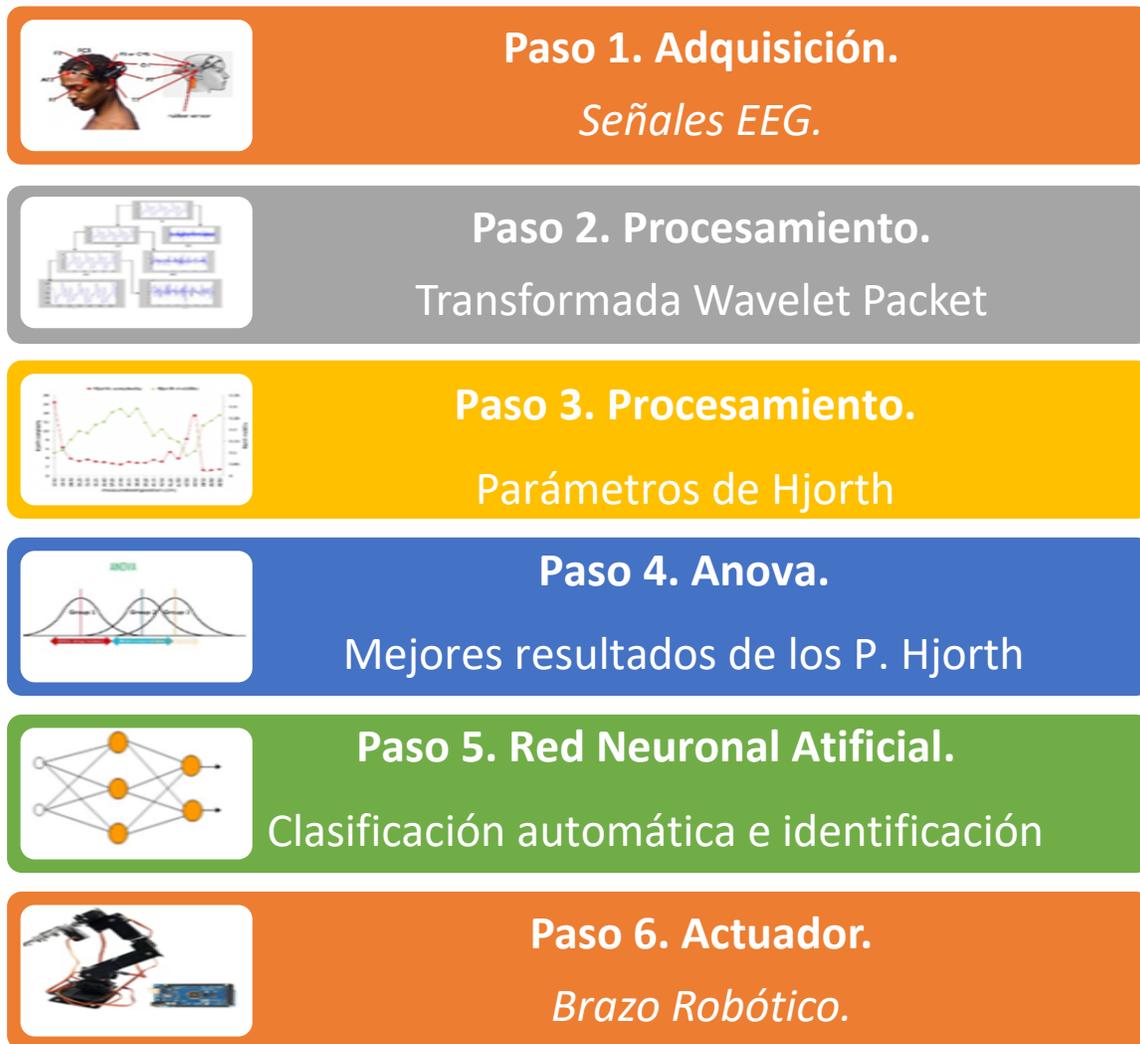


Figura 3.1. Metodología propuesta

- **Etapa 1: Señales EEG**

En este trabajo de tesis se está analizando la base de datos de señales de EEG de la Universidad de Guanajuato proporcionada por el Dr. Mario Alberto Ibarra Manzano. Dicha base de datos contiene información adquirida por medio del sistema de Emotiv-Epoc. El monitoreo se realizó a 10 participantes de varias

edades, tanto hombres como mujeres. El tiempo para cada prueba individual fue aproximadamente de 10 minutos consecutivos, durante las pruebas el participante se le indicaba por medio de una flecha lo que tenía que pensar izquierda, derecha y reposo. 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 pre-procesamiento y procesamiento computacional.

- **Etapa 2: Transformada Wavelet de Paquetes (TWP)**

Una vez leída las señales EEG, estas son pre-procesadas por la TWP. Esta técnica permite descomponer las señales EEG en diferentes bandas de frecuencias, permitiendo un análisis más detallado de las señales, con el fin de una identificación de patrones más certera.

- **Etapa 3: Parámetros de Hjorth (PH)**

Una vez descompuestas las señales EEG en diferentes bandas de frecuencia empleando la TWP, se procede a identificar características por medio de las PH (indicadores no lineales), los cuales miden la actividad, movilidad y la complejidad de las señales EEG. El dato de entrada para el cálculo de dichos parámetros reside en la señal de cada uno de los canales/sensores. La actividad representa la potencia de la señal, la varianza de una función de tiempo. Esto puede indicar la superficie del espectro de potencia en el dominio de la frecuencia. La movilidad representa la frecuencia media o la proporción de desviación estándar del espectro de potencia. La complejidad representa el cambio en la frecuencia. El parámetro compara la similitud de la señal con una onda sinusoidal pura, donde el valor converge a 1 si la señal es más similar. Es muy importante mencionar que el uso de los PH es con el

fin de identificar u obtener algún comportamiento o característica de los 3 estados mentales analizados.

- **Etapa 4: Análisis de varianza (ANOVA)**

Este paso consiste en un análisis estadístico llamado ANOVA, el cual está basado en la varianza de los datos de los PH calculados en la etapa previa. El análisis de ANOVA proporciona la capacidad de hacer una correcta selección de los valores más discriminantes a través de un valor de probabilidad llamado P, el cual varía entre 0 y 1, donde 0 significa que los diferentes conjuntos de valores no comparten información y 1 cuando los conjuntos de valores presentan la misma información.

- **Etapa 5: Red Neuronal (RNA)**

Posteriormente, una vez determinadas las características más discriminantes empleando el análisis de ANOVA, se procede a generar un clasificador de inteligencia artificial basado en RNA del tipo perceptrón multicapa, 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.

- **Etapa 6: Actuador**

Finalmente, una vez obtenida la clasificación de los estados mentales (izquierda, derecha y reposo) mediante la red neuronal de la etapa 5, se procede a implementarlo al control de un brazo robótico. Mediante el uso de un microcontrolador Arduino Mega 2560 se realiza la comunicación serial con Matlab, se programan las condiciones para cada uno de los movimientos del motor y se procede a caracterizar un motor de la pinza del brazo robótico estableciendo los valores para abrir y cerrar la pinza, para una vez clasificado el estado mental realizar

el movimiento de esta. La conexión del motor al Arduino se hace mediante el uso de puentes H de tipo L298N y una fuente de voltaje dual regulable de ± 12 V.

3.2 Diadema EMOTIV EPOC+. Sistema de Adquisición de Señales EEG

Con el fin de medir la actividad eléctrica producida por los participantes durante los diferentes pensamientos, reposo, izquierda y derecha, la diadema llamada EMOTIV EPOC+ es empleada para adquirir las señales. Este sistema es un dispositivo BCI, no invasivo, trabaja en tiempo real, y posee una frecuencia de muestreo de 128 Hz, por lo que adquiere 128 datos por segundo. La diadema EMOTIV EPOC+ está diseñada para medir la actividad eléctrica a través de 14 electrodos (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4 y dos referencias CMS/DRL en posiciones P3/P4 respectivamente) colocados según el sistema internacional 10–20 como se muestra en la Figura 3.2. dicho sistema también está equipado con un giroscopio.

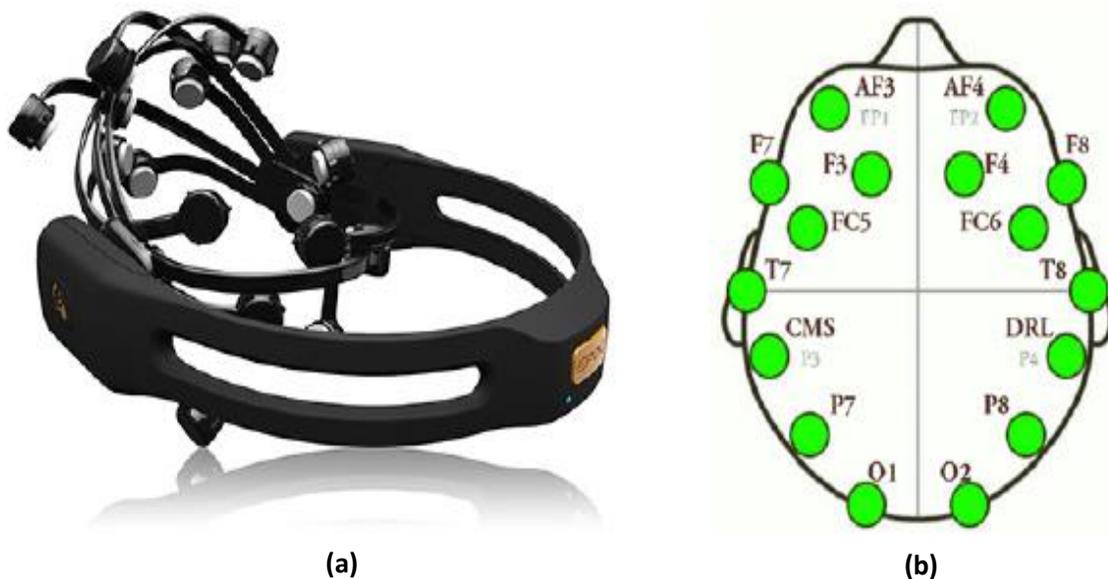


Figura 3.2. (a) Diadema Emotiv-Epoc y (b) ubicación de los sensores.

La Figura 3.3 muestra las vistas derecha e izquierda de la cabeza del usuario usando la diadema Emotiv Epoc+, la figura ilustra la posición correcta de los 14 electrodos alrededor de la cabeza del usuario, dichas posiciones están sometidas al sistema de posicionamiento internacional 10-20. Es vital hacer hincapié en la posición que llevan los electrodos de referencia CMS/DRL en posiciones P3/P4 respectivamente, la correcta conexión y contacto de dichos electrodos nos pueden proveer de una buena señal y disminución de ruido por parte de sistemas externos.

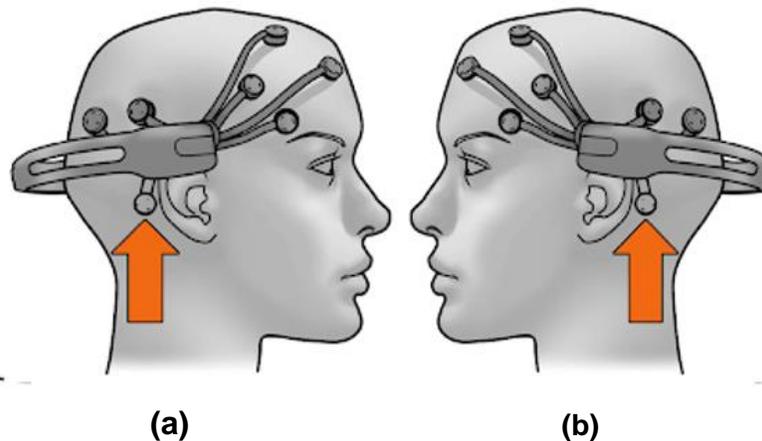


Figura 3.3. Ubicación de los electrodos CMS / DRL respectivamente; (a) vista lateral derecha y (b) vista lateral izquierda.

3.3 Material humano

Con el fin de obtener el recurso humano necesario para diferenciar entre los tres diferentes pensamientos (reposo, derecha e izquierda) se realizó una convocatoria al público en general con los requisitos siguientes:

- 1) Ser mayor de edad (18 años en adelante).
- 2) Haber dormido mínimo 6 horas antes de la realización del estudio.
- 3) No haber consumido sustancias alcohólicas o nocivas para la salud durante las 24 horas previas al examen.
- 4) No haber consumido cafeína o bebidas energizantes en las últimas 8 horas precedentes a la evaluación.
- 5) No sufrir epilepsia o cualquier otra enfermedad psiquiátrica.

- 6) No aplicarse productos de higiene/belleza para el cabello tales como gel, acondicionador, entre otros productos que impida o altere el contacto con el sistema de adquisición.

El número de personas que satisficieron las condiciones antes mencionadas fueron 10, 5 mujeres y 5 hombres.

Es importante aclarar que la base de datos fue proporcionada por el Dr. Mario Alberto Ibarra Manzano, y que lo expuesto previamente son las consideraciones generales con las que se eligió al material humano para generar la base de datos.

3.4 Actuador

Actuador es un dispositivo capaz de transformar energía hidráulica, neumática o eléctrica en la activación de un proceso con la finalidad de generar un efecto sobre un proceso automatizado. El actuador tiende a recibir una orden de un regulador o controlador, y en función a esta señal genera la orden para realizar la activación de un elemento final de control (Hernández et al. 2008).

La carrera de Ingeniería biomédica tiene el objetivo de proveer soluciones ingenieriles a problemas de la salud; por ejemplo, el movimiento de extremidades; por lo tanto, en este proyecto de tesis se emplea el brazo robótico de STEREN modelo k-680 (ver Figura 3.4). Este brazo robótico posee cinco motores de corriente directa que son los motores que se controlan los cinco grados de libertad del brazo. A continuación, se describen los ángulos máximos de cada grado de libertad:

- Abertura máxima de la tenaza: 1.77 pulgadas o 4.5 cm
- Movimiento vertical de la tenaza: 120°
- 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°



Figura 3.4. Brazo robótico STEREN modelo K-680.

Es muy importante clarificar, que en este trabajo de tesis se emplea la tenaza para asociarla a los tres distintos pensamientos analizados: reposo, derecha (apertura de la tenaza) e izquierda (cerrado de la tenaza).

3.5 Arduino Mega

Existen diferentes Arduino tales como uno, Leonardo, Due, Yun, Mega, entre otras, siendo la Arduino Mega la que más se adapta para el proyecto de tesis ya que cuenta con 54 entradas/salidas digitales (de las cuales 15 pueden ser usadas como salidas PWM), 16 entradas analógicas, 4 UARTs, un cristal de 16Mhz, conexión USB, jack para alimentación DC, conector ICSP, y un botón de reseteo como se muestra en la Figura 3.5. La placa Arduino mega se podría considerar la más apropiada para esta tesis por la flexibilidad que posee, al tener una gran cantidad de pines de entrada/salida nos proporciona la posibilidad de agregar actuadores más robustos o que consuman una mayor cantidad de pines. Al ser la tarjeta Arduino más comercial en México esta es accesible y en caso de tener falla con algunos pines no es necesario cambiar toda la placa como lo sería con otras placas que poseen menos pines. Una consideración sumamente importante es que es de las tarjetas Arduino más económicas y comerciales. La Tabla 3.1 muestra las especificaciones más importantes de la placa Arduino Mega y la Figura 3.6 muestra la plataforma de programación de la Arduino.

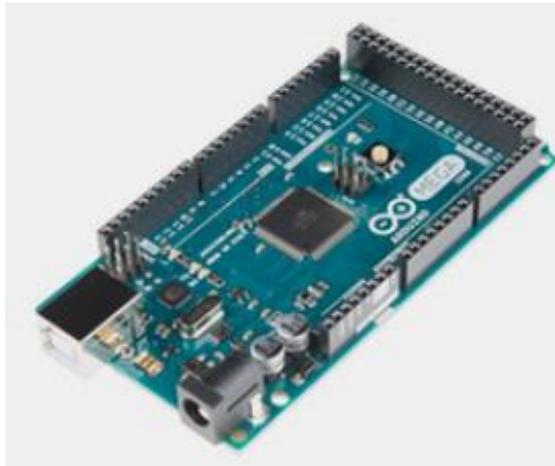


Figura 3.5. Arduino Mega

Tabla 3.1 Especificaciones técnicas del Arduino Mega

Microcontrolador	ATMega2560
Voltaje Operativo	5V
Voltaje de Entrada	7-12 V
Voltaje de Entrada(límites):	6-20V
Pines digitales de Entrada/Salida	54
Corriente DC por cada Pin Entrada/Salida:	40 mA
SRAM	8KB
EEPROM	4KB
Clock Speed	16 MHz
UART'S	4



```
sketch_jun11a Arduino 1.8.9
Archivo Editar Programa Herramientas Ayuda
sketch_jun11a $
#include <SoftwareSerial.h>

SoftwareSerial mySerial(0, 1); // RX, TX

void setup() {
  // Open serial communications and wait for port to
  Serial.begin(38400);
  while (!Serial) {
    ; // wait for serial port to connect. Needed
  }

  digitalWrite(13, HIGH);
  Serial.println("Hello Matlab!");

  // set the data rate for the SoftwareSerial port
  mySerial.begin(38400);
}

void loop() {
  while (mySerial.available()) {
    Serial.write(mySerial.read());
  }
  delay(500);

  while (Serial.available()) {
    mySerial.write(Serial.read());
  }
  delay(500);
}
31 Arduino/Genuino Mega or Mega 2560
```

Figura 3.6. Arduino IDE y configuración de Arduino.

CAPÍTULO IV

Resultados

4.1 Puesta de Experimento

Un diagrama de flujo del proceso para la adquisición de las señales EEG se muestra en la Figura 4.1. La obtención de las pruebas se realizó de forma individual. El sujeto ve en una pantalla señales o indicios, que implican ciertas tareas y se repiten siguiendo el mismo patrón. En forma más específica (y recordando que la frecuencia de muestreo es de 128 Hz): primero, aparece una cruz (duración de 5 s. o 640 datos), alusivo a un periodo de descanso o relajación; después, una flecha hacia la izquierda (duración de 10 s. o 1280 datos), que concierne a imaginar moverse hacia esa dirección; luego, un periodo de reposo o relajación de nuevo (duración de 5 s. o 640 datos); y finalmente, una flecha hacia la derecha (duración de 10 s. o 1280 datos), alusivo a imaginar moverse hacia esa otra dirección.

Lo anterior es un proceso cíclico, la duración del estudio tiene un tiempo promedio de 12 minutos. Una consideración de suma importancia es la acción que se realiza, se ha de tener siempre en cuenta que se trata de imaginar el movimiento sin efectuarlo, a esto se le reconoce como imaginación motora.

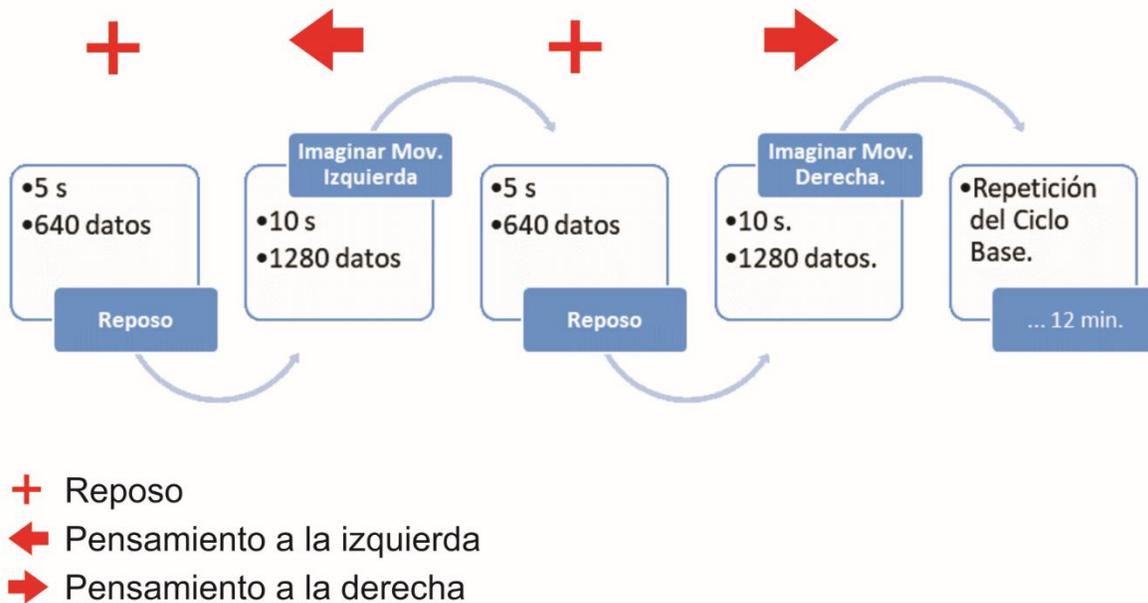


Figura 4.1. Puesta de Experimento: Adquisición de datos.

Por otro lado, la Figura 4.2 muestra la puesta de experimento para mover el actuador, donde primero la computadora después de procesar la información o

señal EEG manda la información a la tarjeta de desarrollo Arduino Mega y esta tarjeta manda la información a un puente H modelo L298N para controlar la apertura y cerrado de la tenaza del brazo robótico.

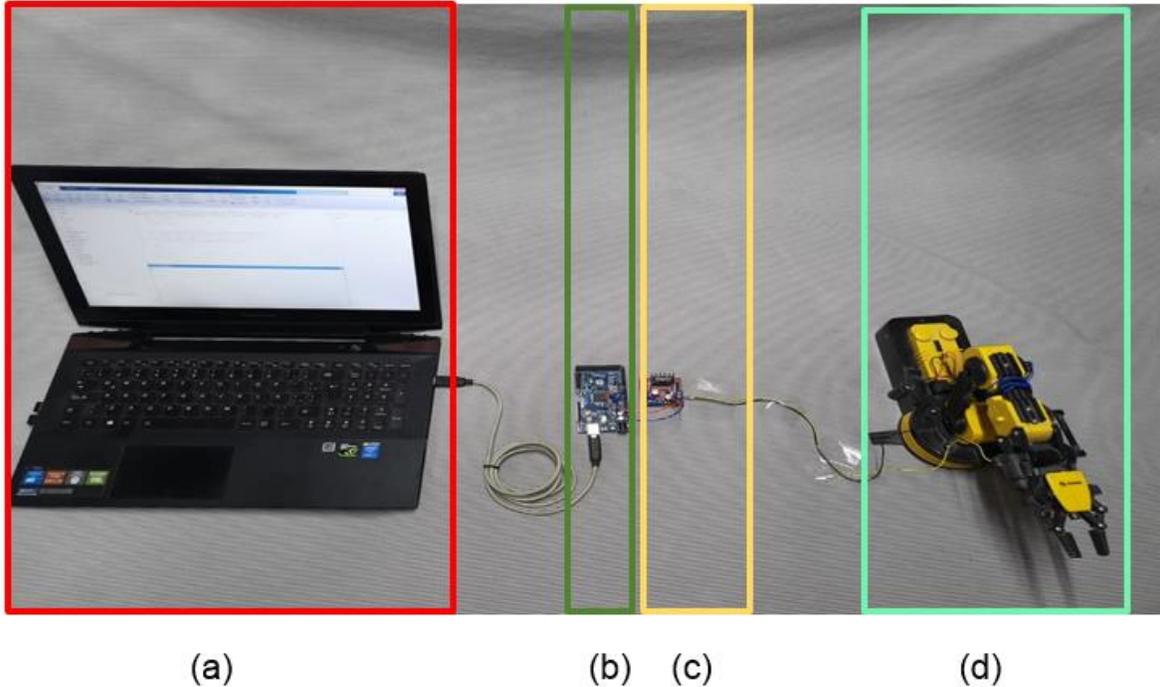


Figura 4.2. Puesta de experimento: Movimiento actuador: (a) Computadora, (b) Microcontrolador Arduino Mega (denotado por el cuadro de color verde), (c) Puente H L298N (denotado por el cuadro de color amarillo) y (d) Actuador brazo robótico.

4.2 Resultados

Siguiendo la metodología propuesta, las señales EEG proporcionadas por el Dr. Mario Alberto Ibarra Manzano de la Universidad de Guanajuato son analizadas a través de la TWP con el fin de dividirla en diversas bandas de frecuencia y así poder extraer diferentes características de las señales (las señales EEG de las primeras 5 personas son empleadas con el objeto de calibrar la metodología propuesta y el resto para validarla). La TWP fue aplicada desde un nivel 1 hasta un nivel 7, donde 254 bandas de frecuencia fueron analizadas, resultando que las bandas de frecuencia del nivel 5 permiten una mejor asociación con los diferentes

pensamientos y esto se debe a que un nivel bajo y alto presentan banda de frecuencia muy pequeñas y altas, respectivamente, limitando una correcta identificación de características que puedan ser asociadas al fenómeno estudiado.

La Figura 4.3 a la 4.34 muestran un ejemplo de una señal EEG descompuesta por la TWP en el nivel 5, donde 32 bandas de frecuencia o nodos son estimadas para los diferentes pensamientos o estados mentales analizados: reposo, izquierda y derecha. Basado en estas figuras, es importante mencionar que una identificación de características de forma visual no se puede dar y por esto es de vital importancia que se realice un procesamiento, en este caso los PH para identificar características que permitan ser asociadas al fenómeno estudiado

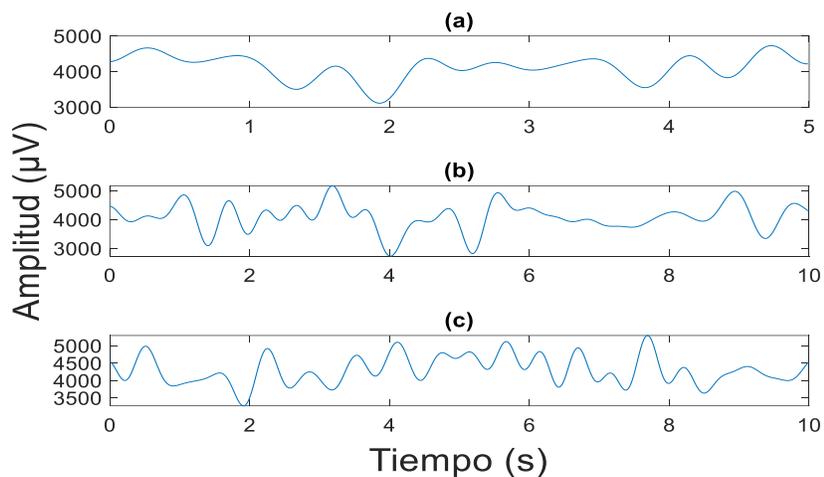


Figura 4.3. Nodo 1, banda de frecuencia de 0 a 2Hz, (a) Reposo, (b) Izquierda y (c) Derecha

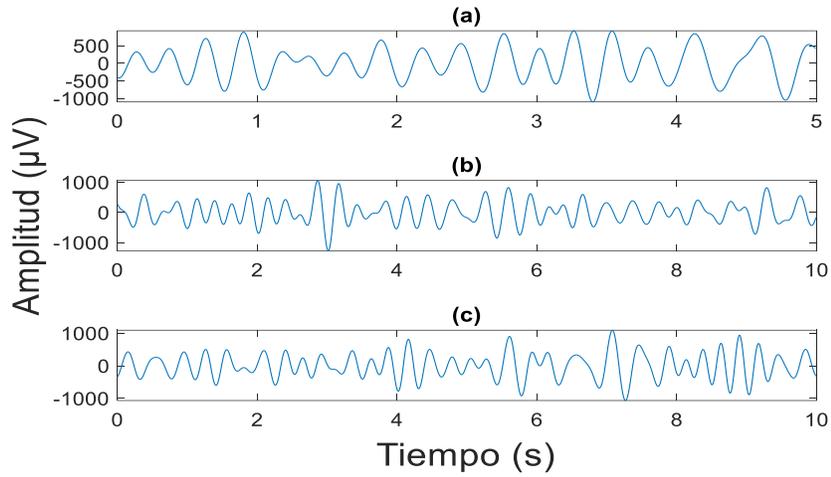


Figura 4.4 Nodo 2, banda de frecuencia de 2 a 4Hz, (a) Reposo, (b) Izquierda y (c) Derecha

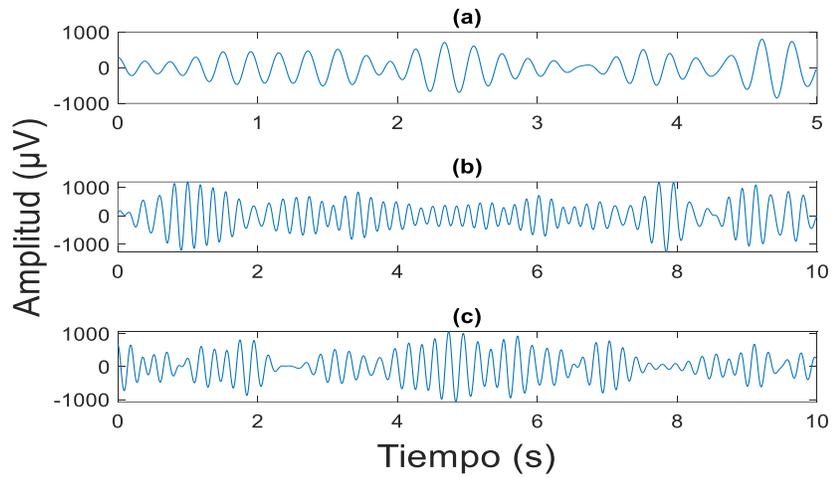


Figura 4.5. Nodo 3, banda de frecuencia de 4 a 6Hz, (a) Reposo, (b) Izquierda y (c) Derecha

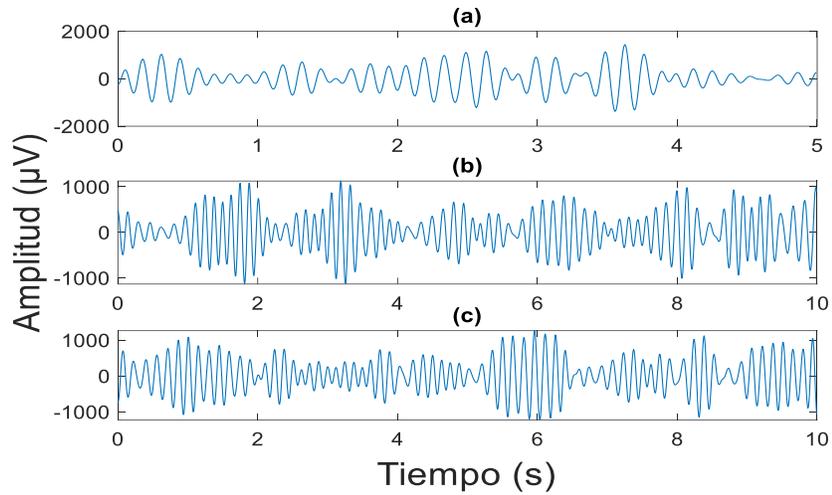


Figura 4.6. Nodo 4, banda de frecuencia de 6 a 8Hz, (a) Reposo, (b) Izquierda y (c) Derecha

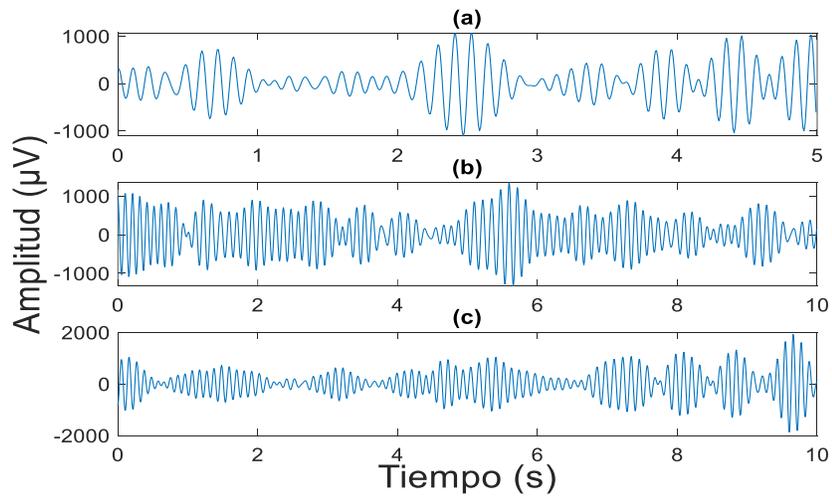


Figura 4.7. Nodo 5, banda de frecuencia de 8 a 10Hz, (a) Reposo, (b) Izquierda y (c) Derecha

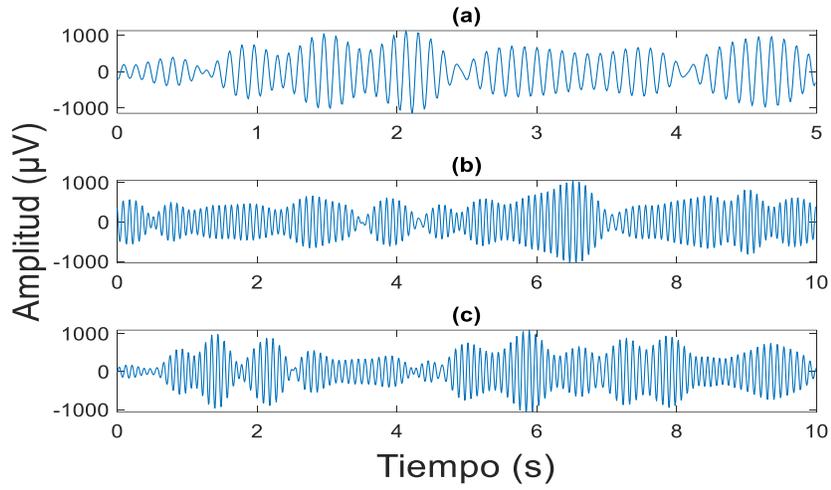


Figura 4.8. Nodo 6, banda de frecuencia de 10 a 12Hz, (a) Reposo, (b) Izquierda y (c) Derecha

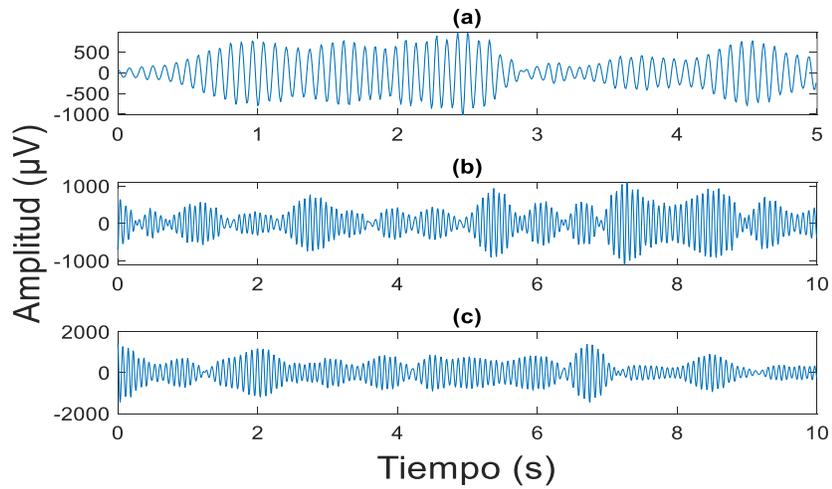


Figura 4.9. Nodo 7, banda de frecuencia de 12 a 14Hz, (a) Reposo, (b) Izquierda y (c) Derecha

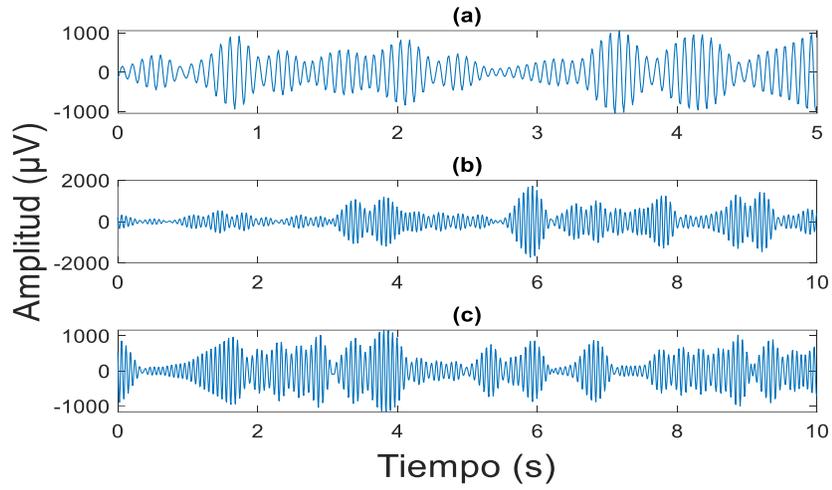


Figura 4.10. Nodo 8, banda de frecuencia de 14 a 16Hz, (a) Reposo, (b) Izquierda y (c) Derecha

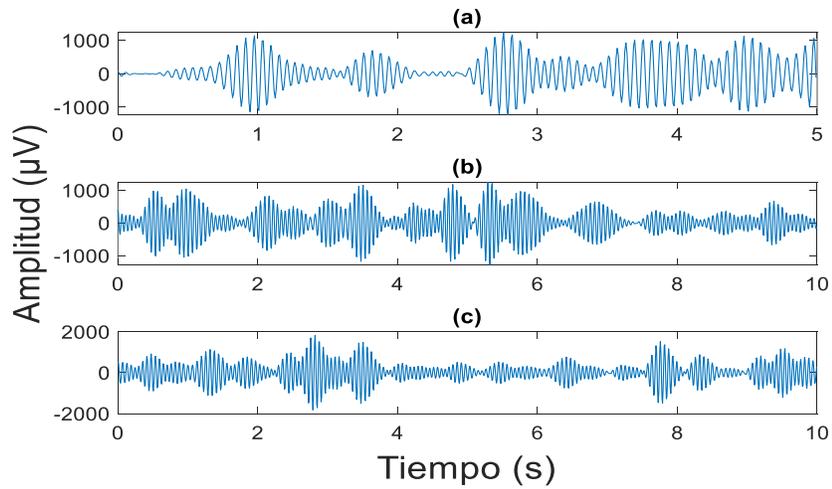


Figura 4.11 Nodo 9, banda de frecuencia de 16 a 18Hz, (a) Reposo, (b) Izquierda y (c) Derecha

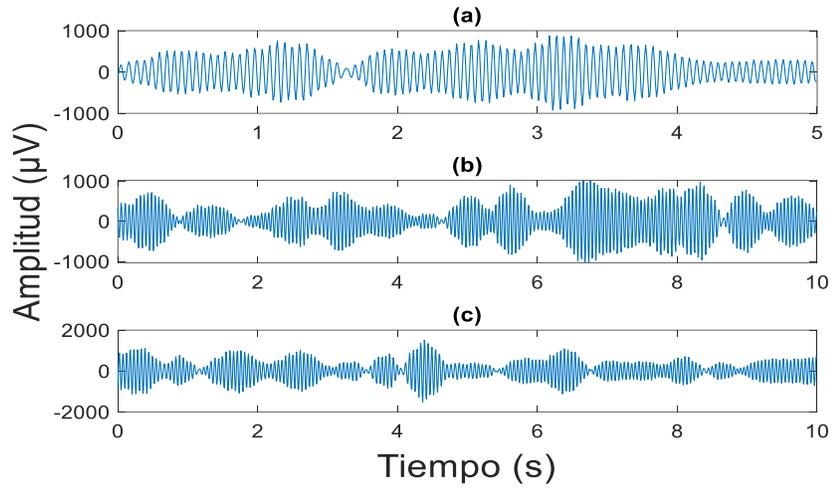


Figura 4.12. Nodo 10, banda de frecuencia de 18 a 20Hz, (a) Reposo, (b) Izquierda y (c) Derecha

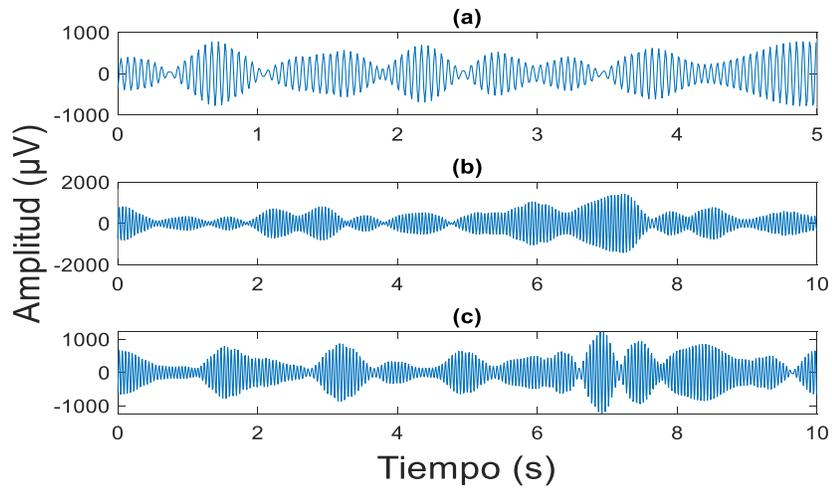


Figura 4.13. Nodo 11, banda de frecuencia de 20 a 22Hz, (a) Reposo, (b) Izquierda y (c) Derecha

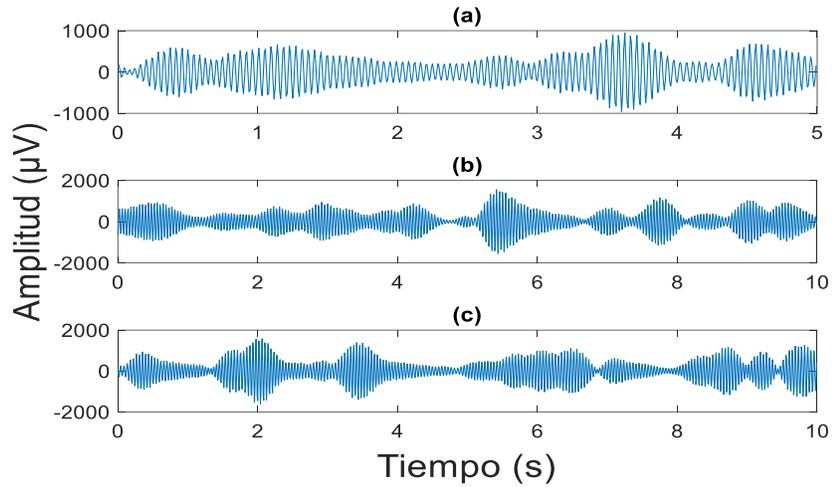


Figura 4.14. Nodo 12, banda de frecuencia de 22 a 24Hz, (a) Reposo, (b) Izquierda y (c) Derecha

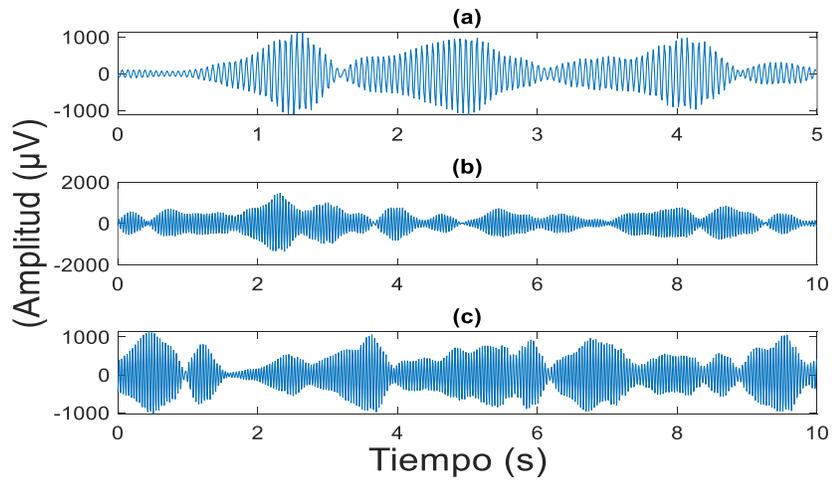


Figura 4.15. Nodo 13, banda de frecuencia de 24 a 26Hz, (a) Reposo, (b) Izquierda y (c) Derecha

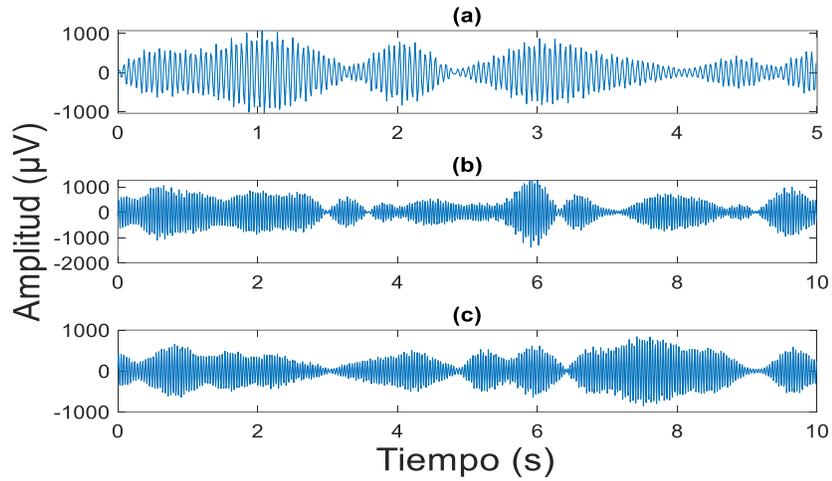


Figura 4.16. Nodo 14, banda de frecuencia de 26 a 28Hz, (a) Reposo, (b) Izquierda y (c) Derecha

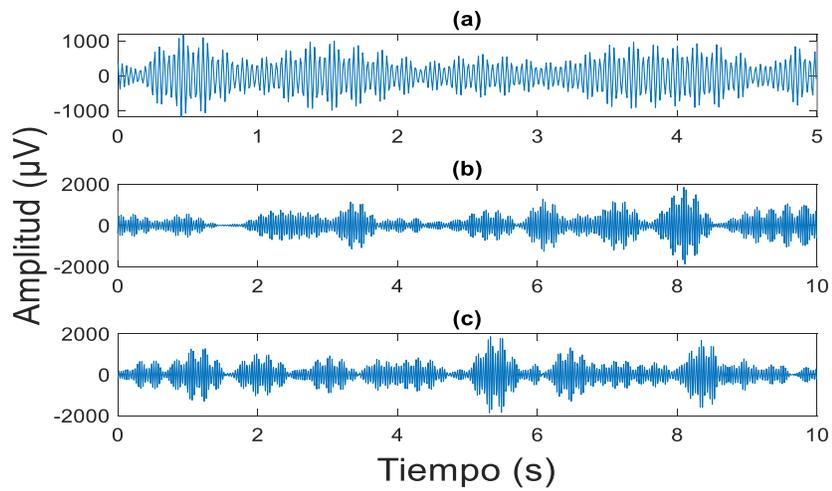


Figura 4.17. Nodo 15, banda de frecuencia de 28 a 30Hz, (a) Reposo, (b) Izquierda y (c) Derecha

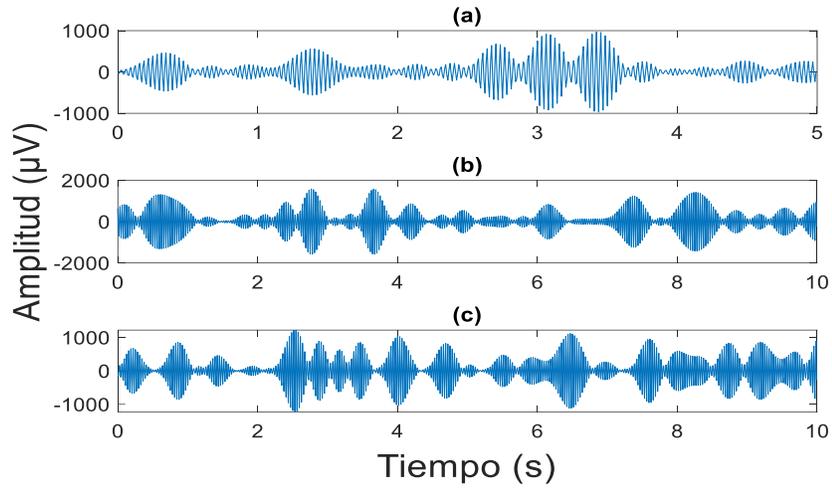


Figura 4.18. Nodo 16, banda de frecuencia de 30 a 32Hz, (a) Reposo, (b) Izquierda y (c) Derecha

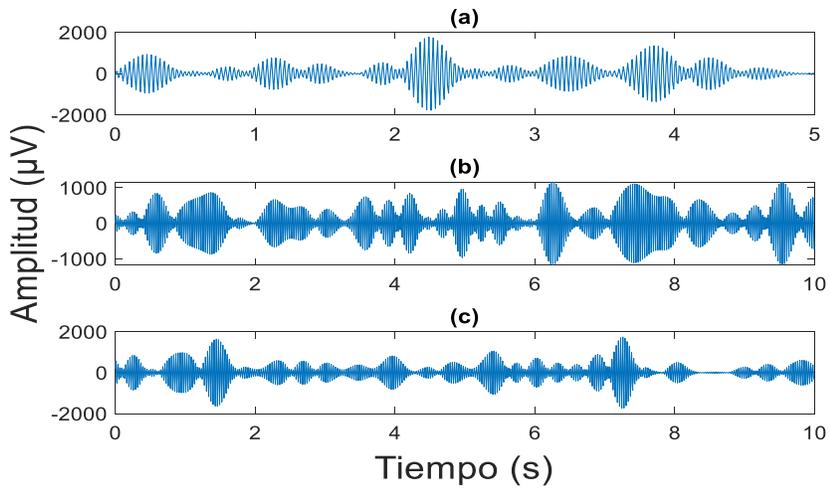


Figura 4.19. Nodo 17, banda de frecuencia de 32 a 34Hz, (a) Reposo, (b) Izquierda y (c) Derecha

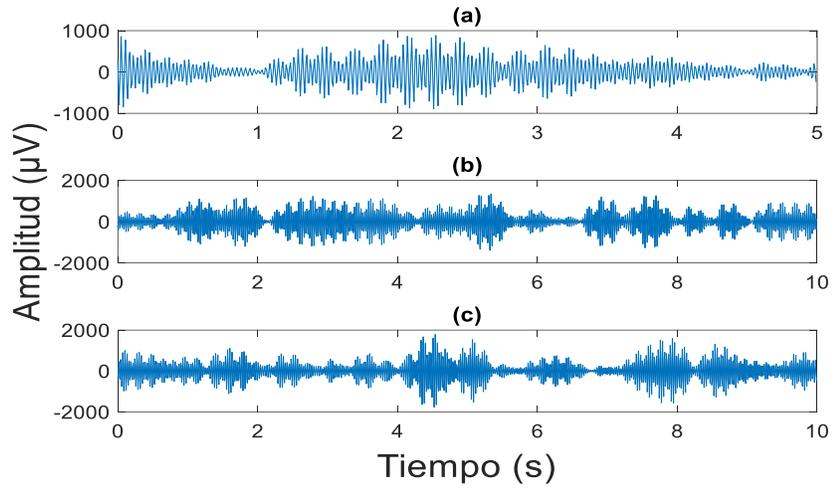


Figura 4.20. Nodo 18, banda de frecuencia de 34 a 36Hz, (a) Reposo, (b) Izquierda y (c) Derecha

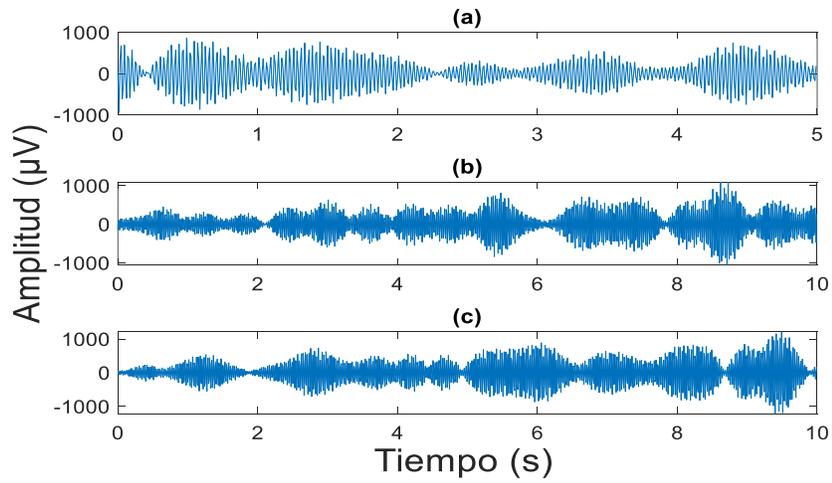


Figura 4.21. Nodo 19, banda de frecuencia de 36 a 38Hz, (a) Reposo, (b) Izquierda y (c) Derecha

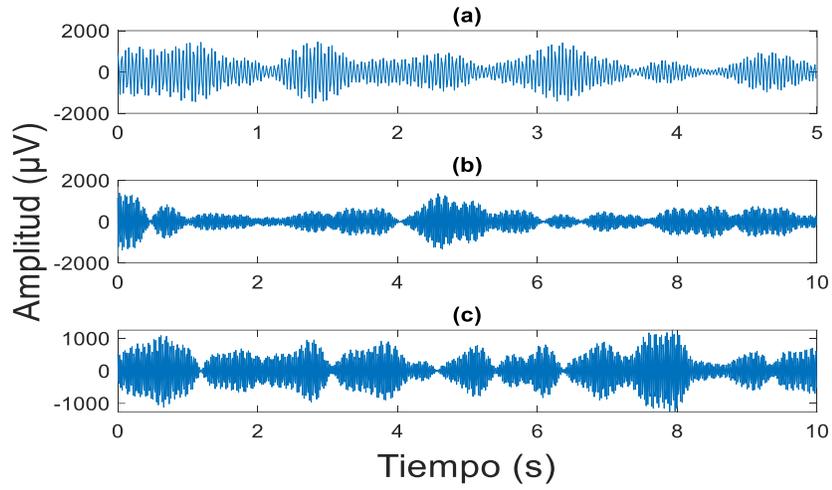


Figura 4.22. Nodo 20, banda de frecuencia de 38 a 40Hz, (a) Reposo, (b) Izquierda y (c) Derecha

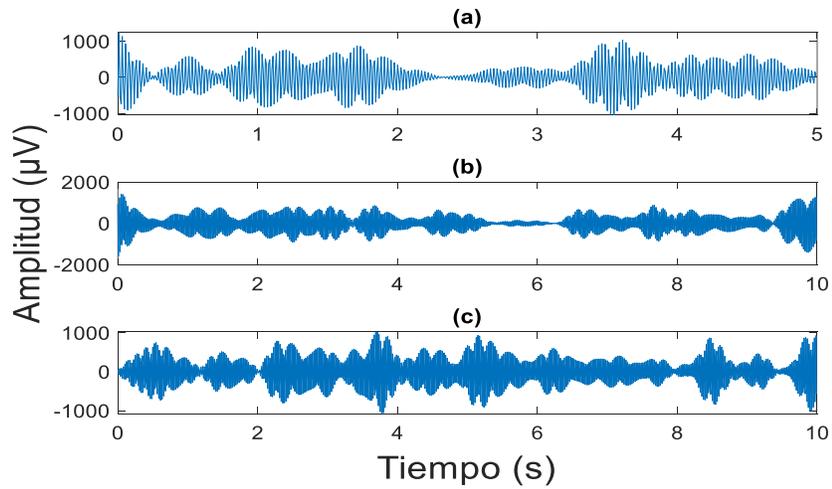


Figura 4.23. Nodo 21, banda de frecuencia de 40 a 42Hz, (a) Reposo, (b) Izquierda y (c) Derecha

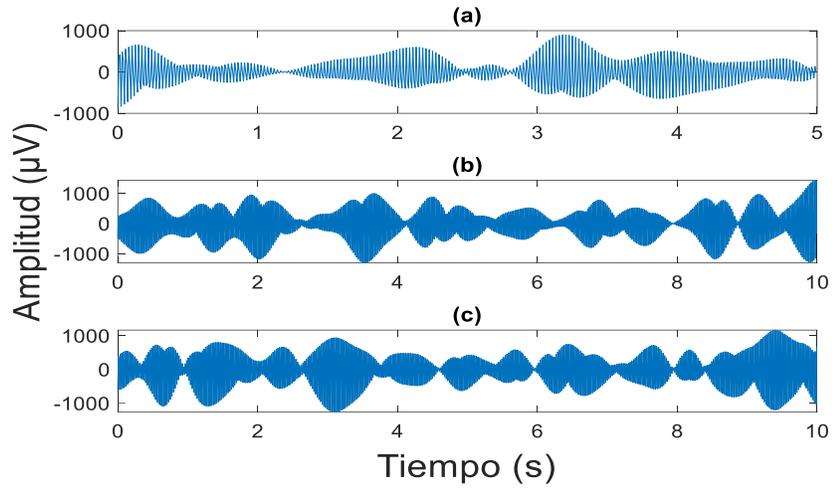


Figura 4.24. Nodo 22, banda de frecuencia de 42 a 44Hz, (a) Reposo, (b) Izquierda y (c) Derecha

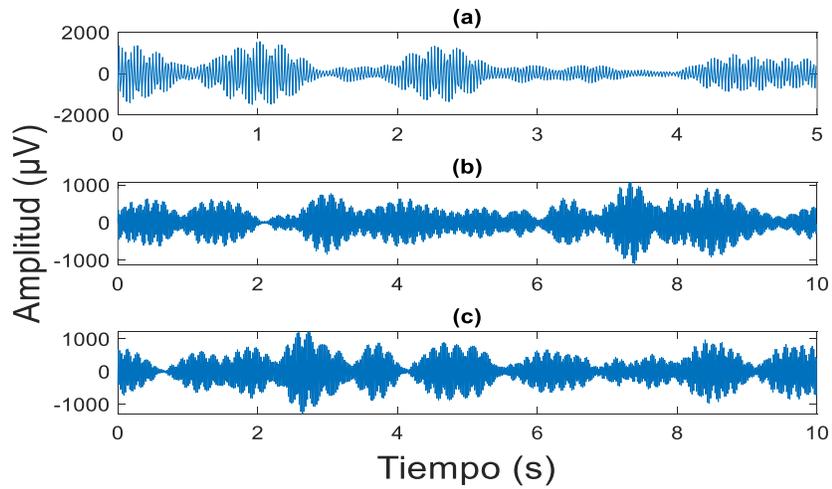


Figura 4.25. Nodo 23, banda de frecuencia de 44 a 46Hz, (a) Reposo, (b) Izquierda y (c) Derecha

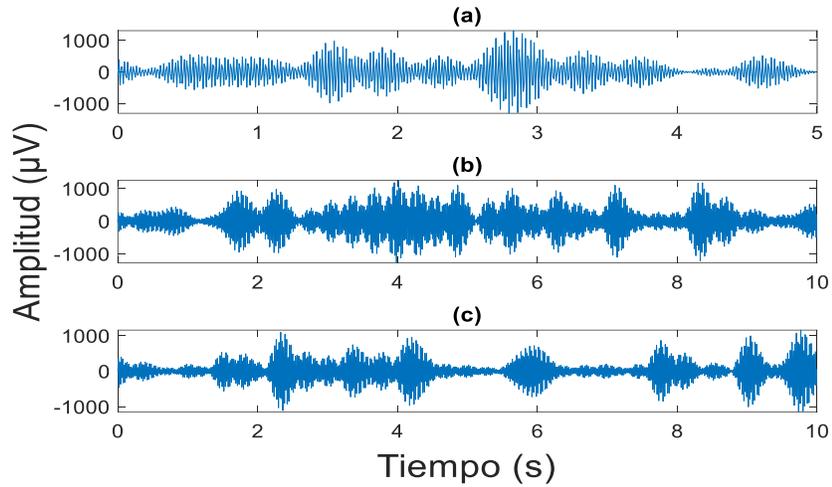


Figura 4.26. Nodo 24, banda de frecuencia de 46 a 48Hz, (a) Reposo, (b) Izquierda y (c) Derecha

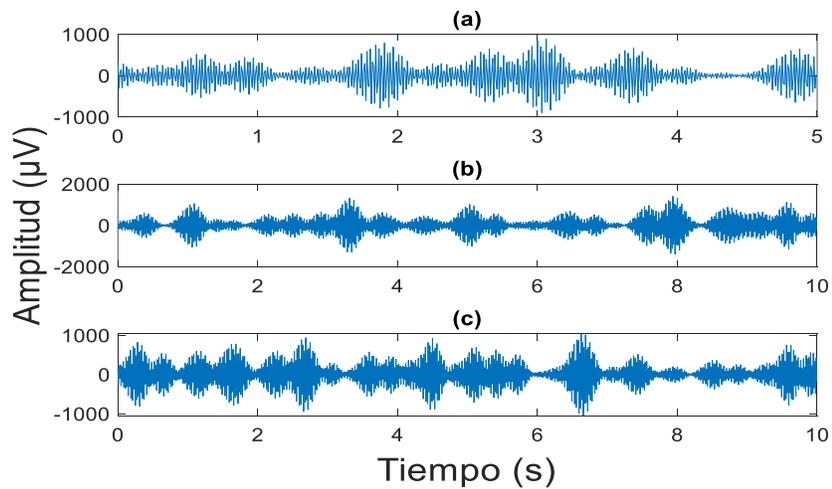


Figura 4.27. Nodo 25, banda de frecuencia de 48 a 50Hz, (a) Reposo, (b) Izquierda y (c) Derecha

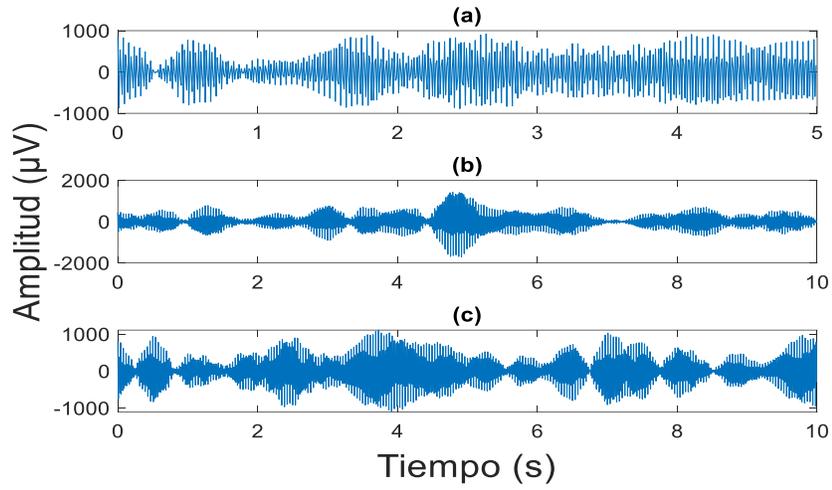


Figura 4.28. Nodo 26, banda de frecuencia de 50 a 52Hz, (a) Reposo, (b) Izquierda y (c) Derecha

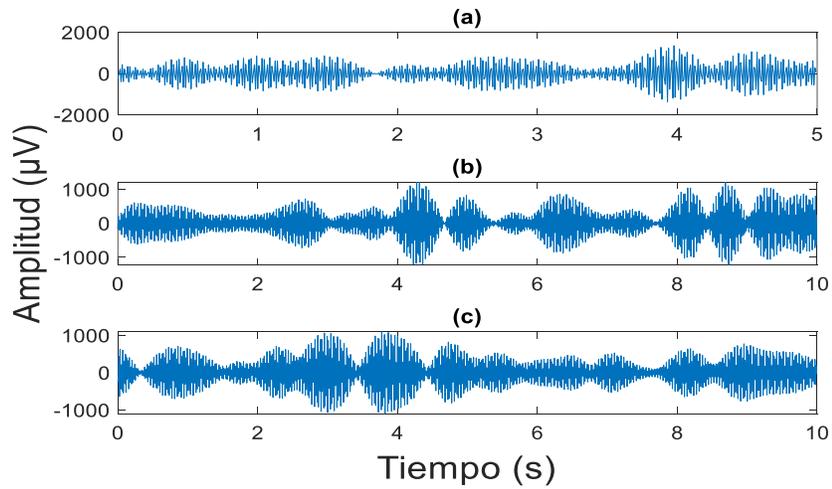


Figura 4.29. Nodo 27, banda de frecuencia de 52 a 54Hz, (a) Reposo, (b) Izquierda y (c) Derecha

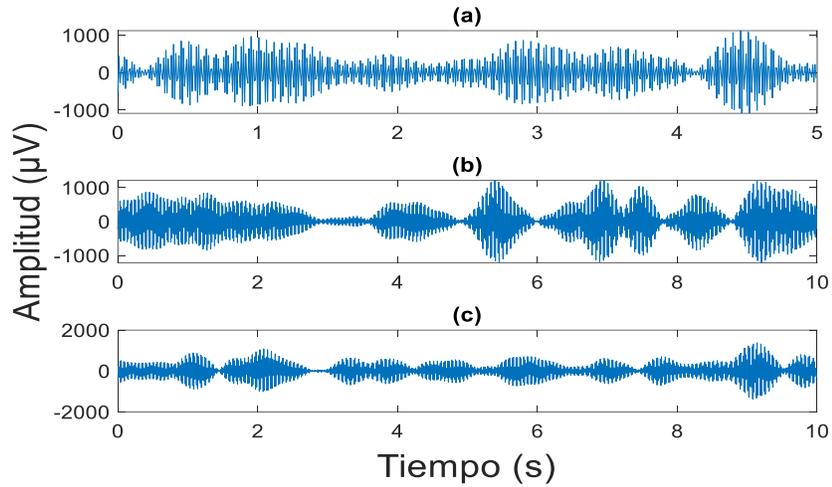


Figura 4.30. Nodo 28, banda de frecuencia de 54 a 56Hz, (a) Reposo, (b) Izquierda y (c) Derecha

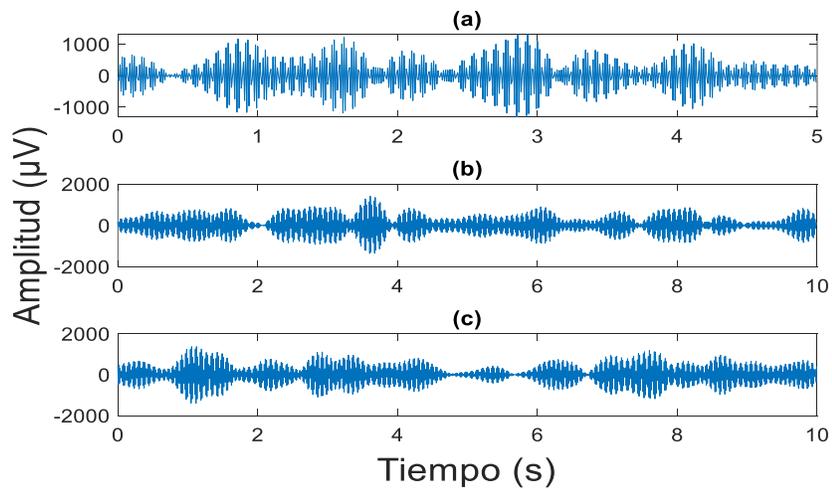


Figura 4.31. Nodo 29, banda de frecuencia de 56 a 58Hz, (a) Reposo, (b) Izquierda y (c) Derecha

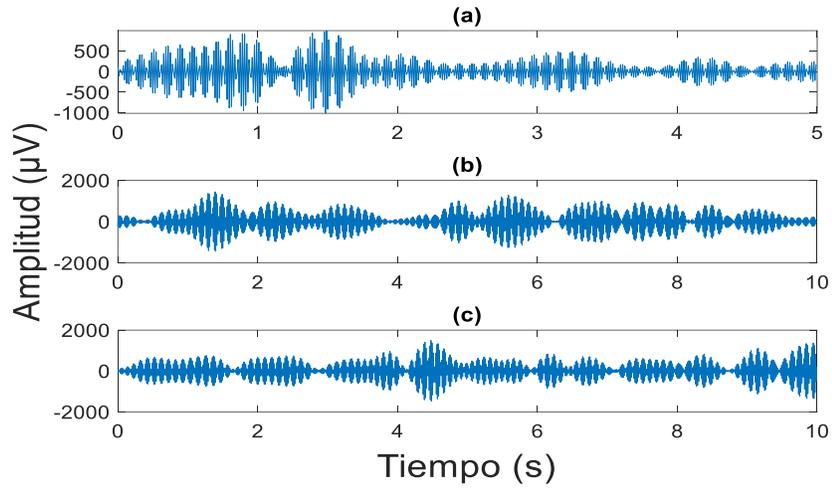


Figura 4.32. Nodo 30, banda de frecuencia de 58 a 60Hz, (a) Reposo, (b) Izquierda y (c) Derecha

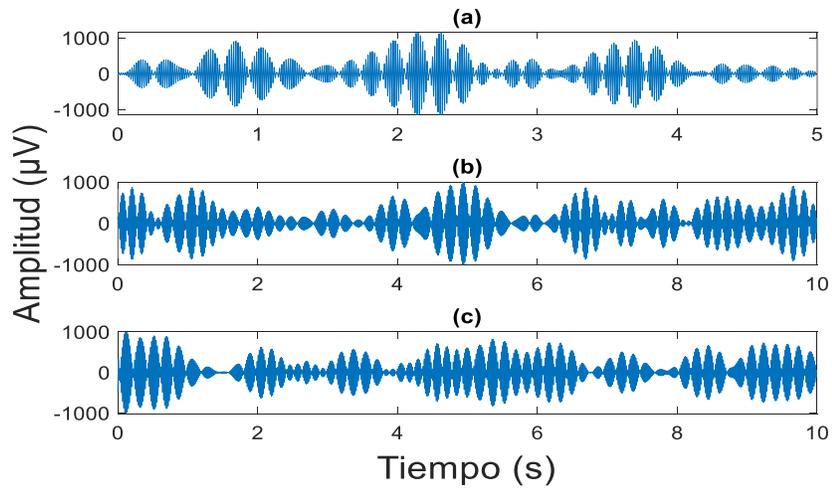


Figura 4.33. Nodo 31, banda de frecuencia de 60 a 62Hz, (a) Reposo, (b) Izquierda y (c) Derecha

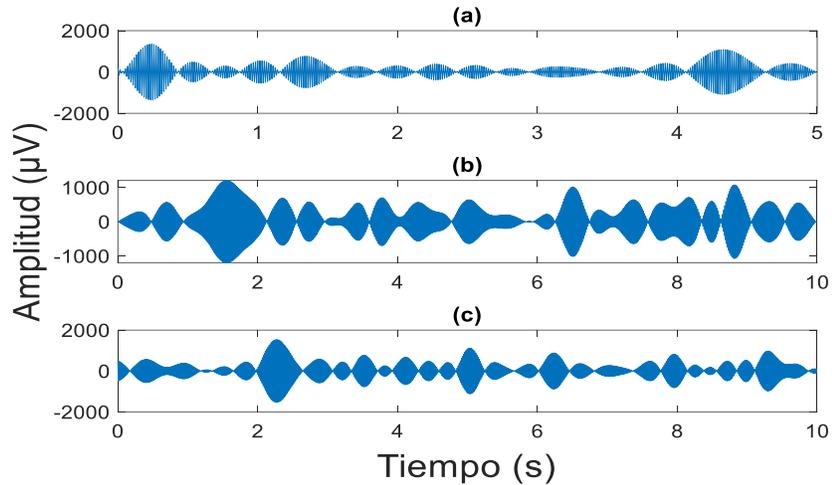


Figura 4.34. Nodo 32, banda de frecuencia de 62 a 64Hz, (a) Reposo, (b) Izquierda y (c) Derecha

Una vez que las señales EEG son descompuestas por la TWP, se aplican los PH: actividad, movilidad y complejidad, a cada una de las bandas de frecuencia con el fin de estimar características dentro de estas para poderlas asociar a los tres distintos pensamientos, resultando en 960 características analizando el nivel 5. Una vez calculadas las características para las diferentes bandas, estas son procesadas por medio de ANOVA con el fin de identificar cual o cuales y que nodos son las más discriminativos para ser relacionadas con el estado mental en cuestión. Basado en el análisis de ANOVA, se identificó que los sensores *AF4*, *F4*, *O1* y *P7* basados en la características actividad eran los más discriminantes. La Figura 4.35 a la 4.39 muestran la distribución de los datos para los sensores y nodos más discriminantes determinados por el análisis de ANOVA; en el Anexo 4.1 se pueden apreciar todos los resultados de las ANOVAS del Sensor *AF3* de los Parámetros de Hjorth de Actividad, Movilidad y Complejidad.

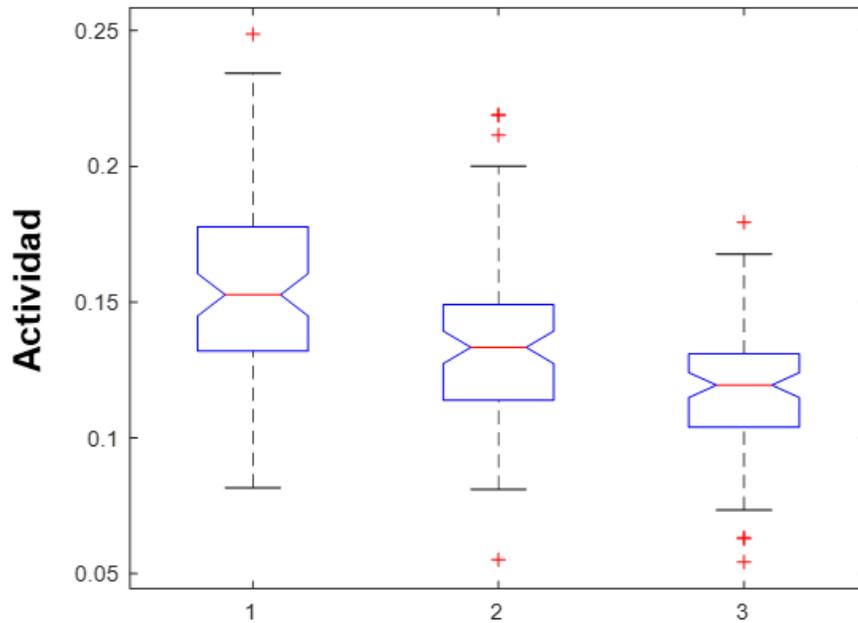


Figura 4.35. Sensor AF4 nodo 31. 1: Reposo, 2: Izquierda y 3: Derecha.

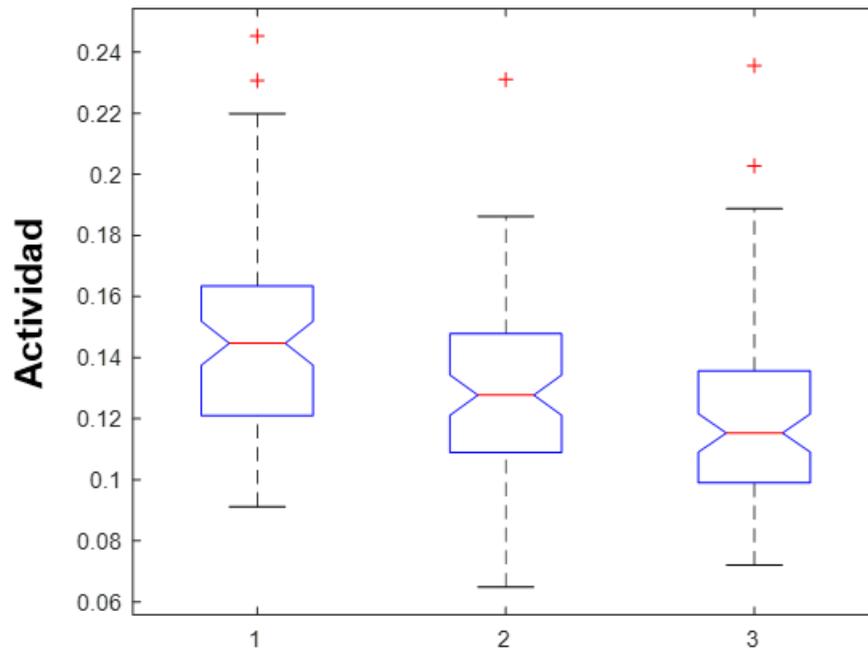


Figura 4.36. Sensor AF4 nodo 2. 1: Reposo, 2: Izquierda y 3: Derecha.

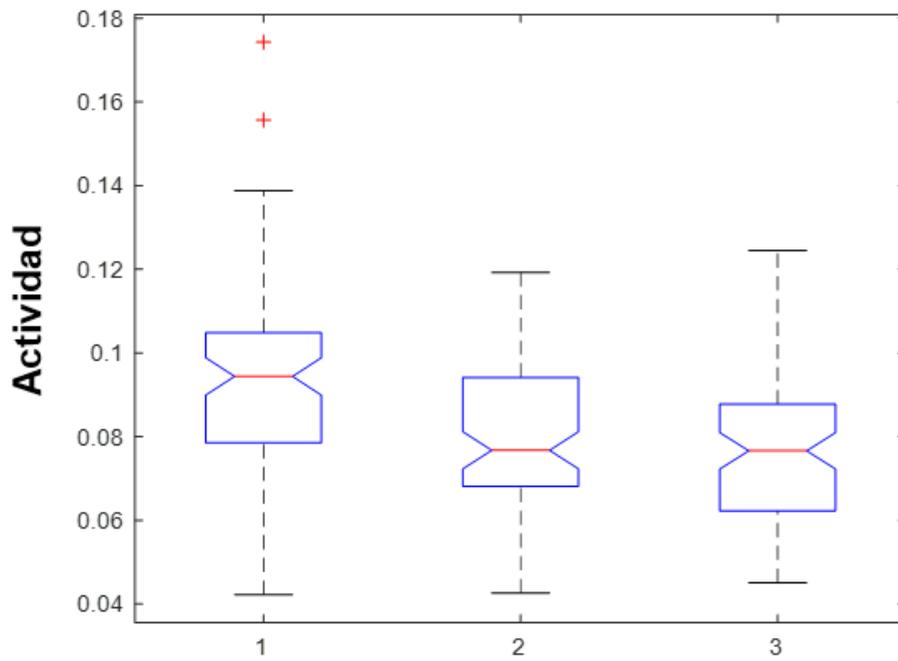


Figura 4.37. Sensor F4 nodo 16. 1: Reposo, 2: Izquierda y 3: Derecha.

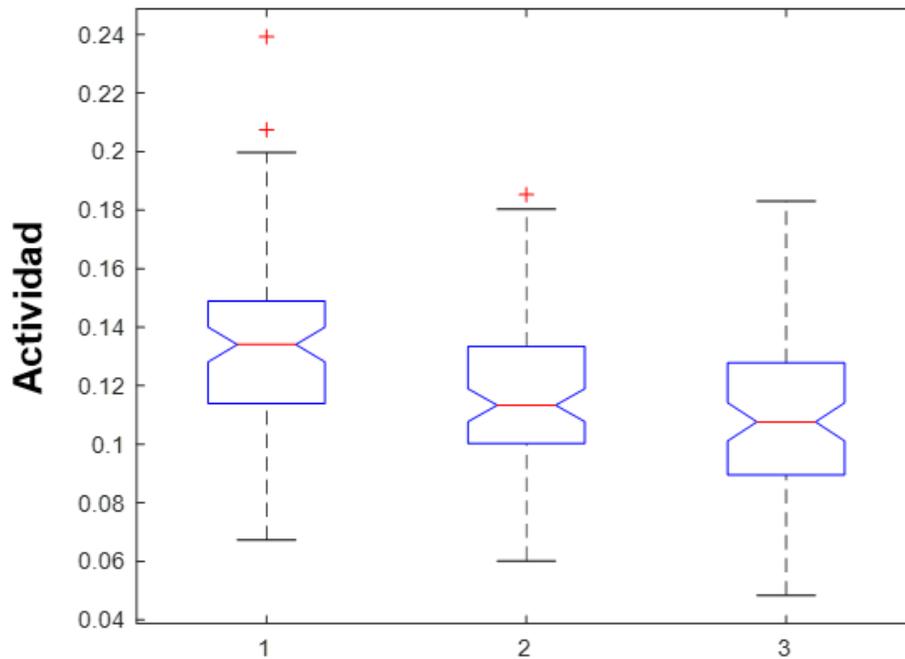


Figura 4.38. Sensor O1 nodo 7. 1: Reposo, 2: Izquierda y 3: Derecha.

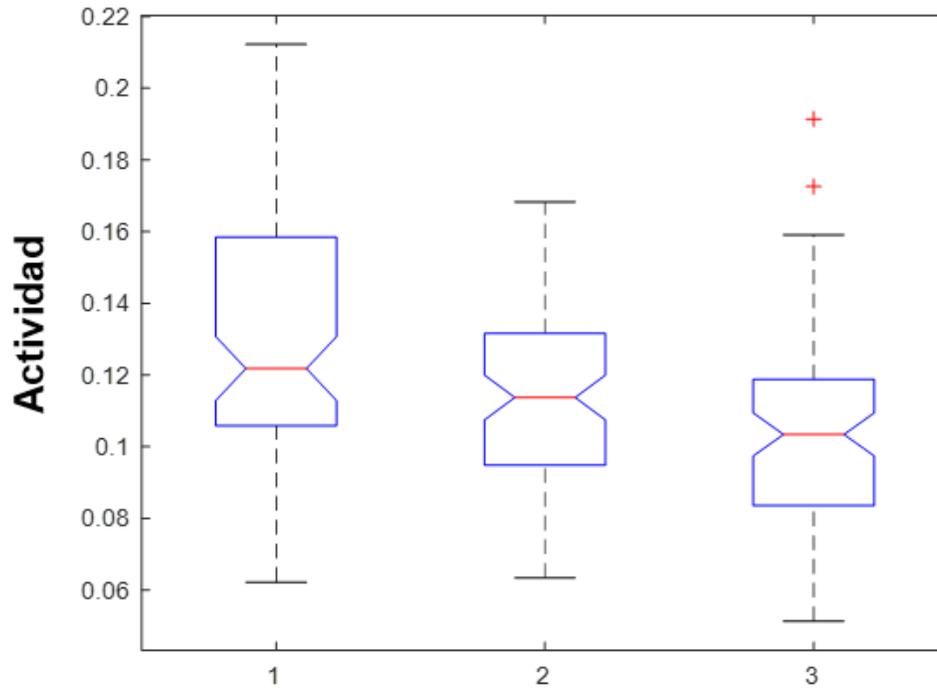


Figura 4.39. Sensor P7 nodo 21. 1: Reposo, 2: Izquierda y 3: Derecha.

Es importante clarificar que la selección del algoritmo actividad, sensores y nodos fueron en base al valor de P y F (valor-p < 1×10^{-10} y valor-F, 20, en promedio), los cuales son provistos por ANOVA y estos indican la probabilidad de que un conjunto de datos se parezca a otro conjunto. La Tabla 4.1 resume los valores de las características más discriminativas estimada, donde su valor de probabilidad, media y desviación estándar son provistos.

Tabla 4.1 Resultados de ANOVA para los sensores y nodos más discriminativos.

PROCEDENCIA DE INFORMACIÓN			REPOSO		IZQUIERDA		DERECHA		PARÁMETROS	
Caso	Sensor	Nodo	Media	Σ	Media	Σ	Media	σ	Valor-F	Valor-P
1	AF4	31	0.1579	0.1079	0.1406	0.0842	0.1206	0.0667	28.96	4.7E ⁻¹²
2	AF4	2	0.1555	0.0910	0.1255	0.0859	0.1304	0.0825	16.24	2.3E ⁻⁷
3	F4	16	0.0943	0.0664	0.0787	0.0574	0.0838	0.0559	18.88	2.2E ⁻⁸
4	O1	7	0.1459	0.1182	0.1217	0.0853	0.1178	0.0879	18.88	2.2E ⁻⁸
5	P7	21	0.1367	0.0949	0.1154	0.0851	0.1113	0.0735	13.42	2.9E ⁻⁶

Finalmente, una vez seleccionadas las características más discriminantes, estas son empleadas para entrenar una red neuronal con el fin de que diferencie entre los 3 pensamientos de forma automática. La red neuronal es configurada con las siguientes características: 5 entradas (número de características seleccionadas), 20 neuronas en la capa oculta y 3 salidas (número de pensamientos a clasificar). Para el diseño de la capa oculta se refirió a la literatura, donde la teoría indica que el número de neuronas en la capa oculta debe ser de mínimo el doble del número de neuronas en la capa de entrada. (López-Ramírez, et al. 2016). Para el estudio en cuestión, serían 10, no obstante, efectuando un análisis experimental exhaustivo, en el que se incrementaba poco a poco el número de ellas, se encontró que el valor óptimo era de 20. Para validar la eficiencia de la red neuronal, se prueba con la información pertenece a los sujetos 6 al 10, resultando una eficiencia de clasificación para estas 5 personas del 72.15%.

Una vez entrenada y validada la red neuronal, se procede a enviar la información proveniente de la salida de la red, donde 1-0-0 indica no hacer nada al efector final (esto es relacionado con reposo), 0-1-0 indica que la tenaza debe abrir (esto es relacionado con el pensamiento izquierdo) y finalmente, 0-0-1 indica que la tenaza debe cerrar (esto es relacionado con el pensamiento derecha), a la Arduino con el fin de que esta controle el puente H que manda la información al efector final. La Figura 4.40 muestra el comportamiento de la tenaza cuando se le manda la información correspondiente al pensamiento de 1, primero reposo, posteriormente apertura (izquierda) y cerrado (derecha). Es importante hacer hincapié las limitantes de realizar un movimiento, no se pueden realizar dos veces la misma acción de forma consecutiva a excepción del reposo. Al momento de realizar un movimiento consecutivo de la misma naturaleza este se convertirá en reposo. Por ejemplo, el paciente pensó dos veces derecha, es imposible que el brazo cierre dos veces, por lo tanto, el segundo pensamiento de derecha se ve convertido en reposo, lo mismo sucede con el estado de la izquierda.

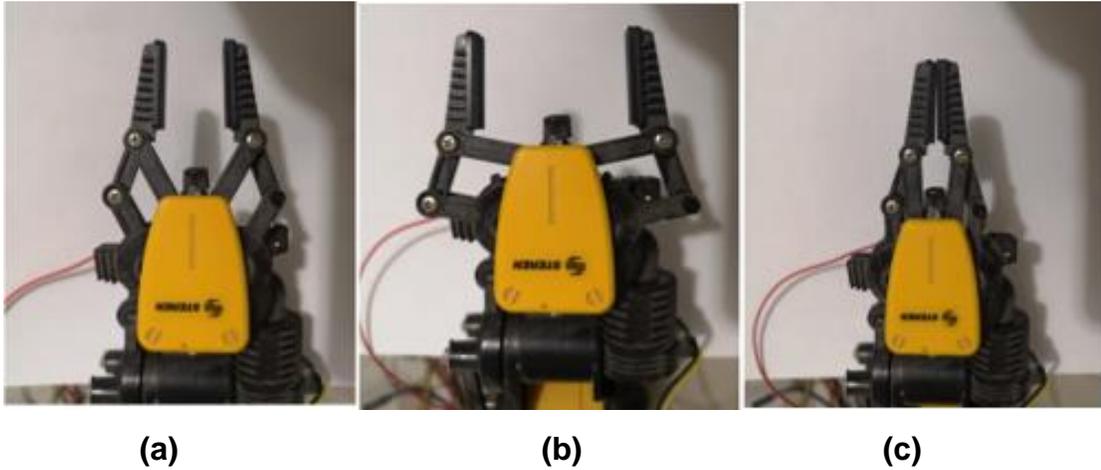


Figura 4.40 Comportamiento de la tenaza (a) reposo, (b) apertura y (c) cerrado.

Es muy importante clarificar que el método presenta una eficiencia del 72.15% eficiente. Por lo tanto, si la secuencia de datos llegara a afectar el funcionamiento del efector final, se opta por mandarle que no haga nada, es decir que este en reposo. Por ejemplo, si el método propuesta interpreta que la persona está pensando: primero reposo, seguido de cerrado, y finalmente cerrado, lo que indicaría que la tenaza debería cerrar 2 veces, lo que no es posible ya que el cerrado del efector final en el primer pensamiento llega a su tope, lo que no permite que se vuelva a cerrar, por lo que el sistema se protege y en ese caso lo deja en reposo y esto indica que siempre se está revisando/evaluando el ultimo pensamiento que se enviará al robot.

4.3 Discusión de Resultados

Los resultados estimados por la red neuronal artificial se pueden visualizar a través de una matriz de confusión. La matriz de confusión es un arreglo compuesto por entradas (datos a clasificar) y salidas (3 estados), que evalúa el desempeño de un algoritmo computacional, en este caso la red neuronal. En forma más puntual, es una matriz de confusión se muestran el número de pruebas clasificadas correctamente del total de pruebas realizadas. Hablando de la situación particular,

de cada estado se toman en promedio 85 iteraciones o repeticiones del patrón; para los 3 estados, da un total de 255 repeticiones, las cuales pertenecen a las repeticiones hechas por las 5 personas restantes.

Para cada estado, la tasa de clasificación se calcula mediante la Ecuación 4.1:

$$Tasa\ de\ Clasificación = \frac{Pruebas\ Correctas}{Pruebas\ Totales} = \frac{Pruebas\ Correctas}{85} \times 100\% \quad (4.1)$$

Y para estimar la tasa de clasificación global para las 5 personas, se emplea el promedio de las tasas de clasificación para los tres estados. Ello se estima mediante la Ecuación 4.2:

$$T.Clasificación_{Gl} = \frac{T.Clasificación_{Reposo} + T.Clasificación_{Derecha} + T.Clasificación_{Izquierda}}{3} \quad (4.2)$$

Una vez descrita la forma de obtener los porcentajes de eficiencia. La Tabla 4.2 muestra los resultados obteniendo por la metodología propuesta para cada pensamiento. Basado en los resultados mostrados en la Tabla 4.2 es posible observar un equilibrio entre las clasificaciones correctas. El estado de reposo es claramente diferenciable de ambas imaginaciones motoras (izquierda y derecha); obteniendo una tasa de clasificación decente de 74.11%. Por otra parte, la distinción entre las imaginaciones motoras derecha e izquierda se obtiene un 72.94% y 69.41% de eficiencia, respectivamente, el cual fue un poco inferior comparándolo con la distinción del reposo, esto se le atribuye a la gran similitud de los datos capturados por la diadema.

Tabla 4.2. Matriz de confusión

		SALIDAS			CLASIFICACIÓN	
		<i>Reposo</i>	<i>Imaginación Motora Derecha</i>	<i>Imaginación Motora Izquierda</i>	<i>Número de Pruebas</i>	<i>Porcentaje (%)</i>
ENTRADAS	<i>Reposo</i>	63	18	4	85	74.11%
	<i>Imaginación Motora Derecha</i>	0	62	23	85	72.94%
	<i>Imaginación Motora Izquierda</i>	2	24	59	85	69.41%
		Eficiencia Total			255	72.15%

Es muy importante mencionar que los valores de eficiencia estimados con este nuevo método son bastante buenos en comparación con el trabajo de tesis presentado por Cruz-Ramírez (2018), donde una eficiencia del 48.24% y 67.05% para clasificar los pensamientos a la izquierda y derecha son obtenidos, respectivamente, lo que indica que la nueva metodología es capaz de discernir entre esos dos pensamientos de forma más eficiente que el trabajo propuesto por Cruz. Adicionalmente, esta nueva metodología se puede considerar es de baja carga computacional en comparación a la presentada por Cruz-Ramírez (2018), ya que los nodos seleccionados en la TWP se pueden llevar a un simple filtro IIR o FIR y la característica, actividad, es solamente la varianza de la señal.

CAPÍTULO V

Conclusiones y perspectivas

5.1 Conclusiones

La identificación correcta de características en señales EEG para poderlas asociar al pensamiento humano es un gran reto, esto debido a la naturaleza de las señales. Por estas razones, este trabajo de tesis evalúa la transformada wavelet de paquetes, los parámetros de Hjorth y las redes neuronales para poder discernir patrones de movimiento entre diferentes estados mentales tales como reposo, imaginación motora hacia la izquierda e imaginación motora hacia la derecha. En base a los resultados obtenidos y habiendo concluido el trabajo, es pertinente decir que se cumplieron los objetivos, además de que se validó la hipótesis, puesto que se logró una metodología de alto rendimiento y sumamente eficiente con una tasa de clasificación total bastante aceptable del 72.15%.

Hablando más específicamente de la tasa de clasificación, la metodología propuesta obtuvo una tasa de clasificación bastante balanceada en las clasificaciones del reposo y las diversas imaginaciones motrices, las tasas de clasificación no se alejaron más del 4.7% entre ellas, lo cual es algo bastante eficiente y prácticamente útil al momento de la implementación. Ahora, si se compara la exactitud de la clasificación para los dos tipos de imaginación motriz, se halla que la derecha fue superior a la izquierda, con una tasa de clasificación del 72.94% y 69.41% respectivamente.

Una consideración importante por la cual se le atribuye la eficiencia en la tasa de clasificación obtenida es la forma no tan minuciosa en que se capturaron las señales EEG, la no linealidad del cerebro, y en general, de los sistemas biológicos, entre otras; los cuales puedan afectar a las bioseñales inmiscuidas en la corteza cerebral.

El desempeño del brazo robótico estuvo decente para el costo del actuador, la conexión realizada mediante el puente H modelo L298N, el motor de la pinza y el Arduino Mega estuvo endeble, al tener que usar cables y caimanos para la fijación en las terminales. El uso de un actuador que permita la incorporación de un Arduino a la estructura beneficiaría al diseño y a las conexiones eléctricas. El uso del microcontrolador Arduino Mega podría considerarse sobrado, pero no lo es así. Al

ser el microcontrolador Arduino más comercial en México, este resulta ser también el más económico, a pesar de tener una gran cantidad de pines I/O, por lo tanto, el uso de esta placa resulto en tener ventajas a un largo plazo considerando principalmente la expansión e integración de las tareas tanto en términos de software (funciones y procesamiento) como en hardware (más y nuevos actuadores, ejemplo: motores).

5.2 Prospectivas

Como primera prospectiva, en la parte computacional, queda el complementar el esfuerzo hecho hasta el momento con otros algoritmos o probar diversas técnicas de procesamiento y extracción de características de señales, así como algoritmos clasificadores genéticos, para mejorar la tasa de diferenciación. Incluso, la posibilidad de implementar un preprocesamiento de las ondas/señales EEG para adecuarlas o prepararlas para que se les aplique un procesamiento más robusto, y así generar resultados más eficientes.

Por la parte de adquisición, se pueden mejorar las condiciones del lugar de captura de las señales EEG, usar otro sistema de adquisición más robusto y con más sensores, ampliar el número de sujetos de prueba, exhortar a los mismos para que sigan los lineamientos antes y durante la toma de las ondas del encéfalo, de manera que las muestras salgan lo más *limpias* posible.

Ya en un plan a mediano o largo plazo, el desarrollo de un sistema de adquisición y monitoreo de señales EEG en tiempo real actuando en un conjunto de actuadores más completo, como sería una silla de ruedas o una prótesis transradial es necesario. Finalmente, otra prospectiva de trabajo es el diseño de un sistema embebido, el cual posea ya un sistema de adquisición de las señales de EEG, filtros FIR o IIR, drivers para el control de los motores involucrados y conexión remota, etc.

Referencias Bibliográficas.

- Adeli, H., Zhou, Z., & Dadmehr, N. (2003). Analysis of EEG records in an epileptic patient using wavelet transform. *Journal of Neuroscience Methods*, 123(1), 69-87.
- Amézquita-Sánchez, J., 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.
- Babiloni, C., Pizzella, V., Del Gratta, C., Ferretti, A., & Romani, G. L. (2009). Fundamentals of electroencefalography, magnetoencefalography, and functional magnetic resonance imaging. *International Review of Neurobiology*, 86, 67-80.
- Baravalle, R., Rosso, O., & Montani, F. (2018). Causal Shannon–Fisher Characterization of Motor/Imagery Movements in EEG. *Entropy*, 20(9), 660.
- Batres-Mendoza, P., Montoro-Sanjose, C., Guerra-Hernandez, E., Almanza-Ojeda, D., Rostro-Gonzalez, H., Romero-Troncoso, R., & Ibarra-Manzano, M. (2016). Quaternion-based signal analysis for motor imagery classification from electroencephalographic signals. *Sensors*, 16(3), 336.
- Brunner, C., Naeem, M., Leeb, R., Graitmann, B., & Pfurtscheller, G. (2007). Spatial filtering and selection of optimized components in four class motor imagery EEG data using independent components analysis. *Pattern Recognition Letters*, 28(8), 957-964.
- Carino-Escobar, R., Cantillo-Negrete, J. (2016). Decodificación de imaginación motora en la señal de electroencefalografía mediante mapas auto-organizados. *Revista del Centro de Investigación. Universidad La Salle. D.F. México*
- Cruz Ramírez, H. (2018). Metodología basada en la Descomposición Empírica de Modos Completa y Fractales para la Clasificación de Imaginación Motora

usando Señales Electroencefalográficas. Universidad Autónoma de Querétaro, México, Tesis de Licenciatura.

Díaz-Blancas, G. (2014). Reconocimiento de patrones de señales EEG mediante redes neuronales. Centro de investigación y desarrollo de tecnología digital. IPN CITEDI. Tijuana, México.

Dorador-González, J. M., Ríos-Murillo, P., Flores-Luna, I., Juárez-Mendoza, A. (2004). Robótica Y Prótesis Inteligentes. (U. N. México, Ed.) Revista Digital Universitaria. Recuperado de <http://www.revista.unam.mx/vol.6/num1/art01/int01.htm>.

Farry, K. A., Walker, I. D., & Baraniuk, R. G. (1996). Myoelectric teleoperation of a complex robotic hand. *IEEE Transactions on Robotics and Automation*, 12(5), 775-788.

Garcia-Perez, A., Amezquita-Sanchez, J. P., Dominguez-Gonzalez, A., Sedaghati, R., Osornio-Rios, R., & Romero-Troncoso, R. J. (2013). Fused empirical mode decomposition and wavelets for locating combined damage in a truss-type structure through vibration analysis. *Journal of Zhejiang University SCIENCE A*, 14(9), 615-630.

Goering, R. (2014) MATLAB edges closer to electronic design automation world, *EE Times*.

Hernández, V. M., Santibáñez, V., Carrillo, R. V., Molina, J., & López, J. J. (2008). Control PD de Robots: Dinámica de Actuadores y Nueva Sintonía. *Revista Iberoamericana de Automática e Informática Industrial RIAI*, 5(4), 62-68.

Hjorth, B. (1970). EEG analysis based on time domain properties. *Electroencephalography and clinical neurophysiology*, 29(3), 306-310.
Iturralde P., Patrone M., (2012). Reconocimiento de señales EEG. Montevideo, Uruguay.

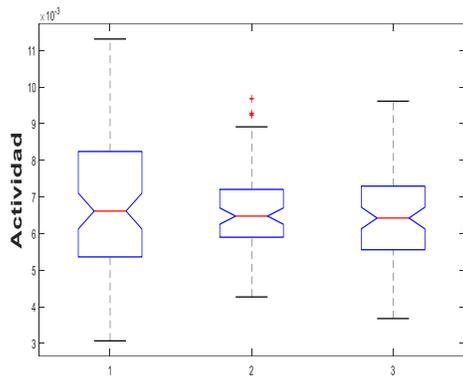
- Xue, J. Z., Zhang, H., Zheng, C. X., & Yan, X. G. (2003). Wavelet packet transform for feature extraction of EEG during mental tasks. *Proceedings of the 2003 International Conference on Machine Learning and Cybernetics*, pp. 360-363.
- Kaboli, M., De La Rosa-T, A., Walker, R., & Cheng, G. (2015). In-Hand Object Recognition via Texture Properties with Robotic Hands, Artificial Skin, and Novel Tactile Descriptors. *IEEE-RAS International Conference on Humanoid Robots (Humanoids)*, pp. 1155-1160.
- Kellaway, P. (1990). An orderly approach to visual analysis: characteristics of the normal EEG of adults and children. En D. Daly, & T. Pedley, *Current practice of clinical electroencephalography*. New York, NY: Raven Press.
- Lahart, J. (2009). Taking an Open-Source Approach to Hardware. *The Wall Street Journal*. Obtenido de: <https://www.wsj.com/articles/SB10001424052748703499404574559960271468066>
- Lopez-Ramirez, M., Ledesma-Carrillo, L., Cabal-Yepez, E., Rodriguez-Donate, C., Miranda-Vidales, H., & Garcia-Perez, A. (2016). EMD-based feature extraction for power quality disturbance classification using moments. *Energies*, 9(7), 565.
- Mallat, S. (1998). A theory for multiresolution signal decomposition: The wavelet representation. *IEEE Transactions on Pattern Analysis Machine Intelligent*, 1, 1-27.
- Omrani, M., Murnaghan, C. D., Pruszynski, J. A., & Scott, S. H. (2016). Distributed task-specific processing of somatosensory feedback for voluntary motor control. *Elife*, 5, e13141.
- Lebedev, M. A., & Nicolelis, M. A. (2006). Brain-machine interfaces: past, present and future. *TRENDS in Neurosciences*, 29(9), 536-546.

- Neuper, C., Scherer, R., Reiner, M., & Pfurtscheller, G. (2005). Imagery of motor actions: Differential effects of kinesthetic and visual–motor mode of imagery in single-trial EEG. *Cognitive brain research*, 25(3), 668-677.
- Philip, K. (2006). *Dirección de marketing*. 13va Edición. España: Pearson Education.
- Rafiee, J., Rafiee, M. A., Prause, N., & Schoen, M. P. (2011). Wavelet basis functions in biomedical signal processing. *Expert systems with Applications*, 38(5), 6190-6201.
- Salgado, B. M., & López, R. A. (2017). *Caracterización de Señales EEG Mediante Wavelet Packet y Entropía Difusa para Tareas de Imaginación Motora*. Colombia.
- Sánchez Reyes, L. M., Rodríguez Reséndiz, J. (2008). *Sistema de monitoreo neuronal para el análisis de potenciales enfocados a personas con problemas motrices*. Universidad Autónoma de Querétaro, Tesis de Licenciatura.
- Schalk, G., McFarland, D. J., Hinterberger, T., Birbaumer, N., & Wolpaw, J. R. (2004). BCI2000: a general-purpose brain-computer interface (BCI) system. *IEEE Transactions on Biomedical Engineering*, 51(6), 1034-1043.
- Schmidhuber, J. (2015). Deep Learning in Neural Networks: An Overview. *Neural Networks*, 61, 85-117.
- Ting, W., Guo-zheng, Y., Bang-hua, Y., & Hong, S. (2008). EEG feature extraction based on wavelet packet decomposition for brain computer interface. *Measurement*, 41(6), 618-625.
- Torres-García, A. A. (2016). *Análisis y clasificación de electroencefalogramas (EEG) registrados durante el habla imaginada*. Instituto Nacional de Astrofísica, Óptica y Electrónica, México, Tesis de Doctorado.
- Vidal, A. F. P., Salas-López, G., Gómez, A. M., Oliver-Salazar, M. A., & Beltrán, C. G. (2014). Aspectos Críticos para la Correcta Adquisición de Señales EEG. *Memorias del XVI Congreso Latinoamericano de Control Automático*.

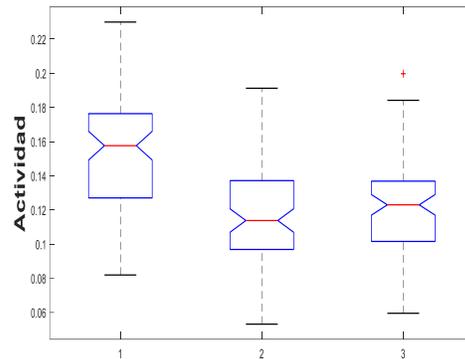
- Vignolo-Barchiesi, J. (2008) Introducción al procesamiento de señales digitales. Ediciones Universitarias de Valparaíso. Pontificia Universidad Católica de Valparaíso.
- Vourkas, M., Micheloyannis, S., & Papadourakis, G. (2000). Use of ANN and Hjorth parameters in mental-task discrimination. Proceeding on advances in medical signal and information processing, pp 327-332.
- WHO. (2013). Lesiones medulares. Obtenido de <https://www.who.int/es/news-room/fact-sheets/detail/spinal-cord-injury>.

Anexos

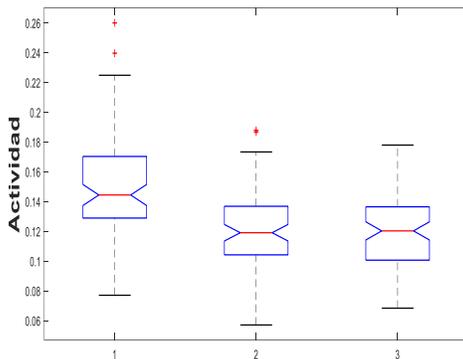
Anexo 1. Graficas de ANOVAS del Parámetro de Hjorth Actividad



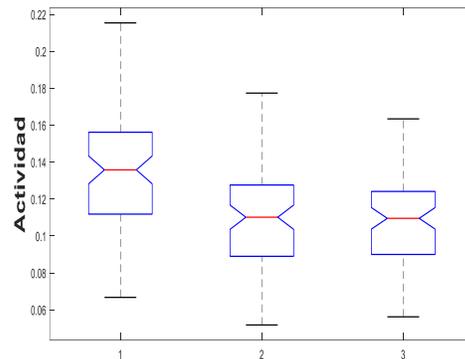
Sensor AF3 nodo 1. 1: Reposo, 2: Izquierda y 3: Derecha.



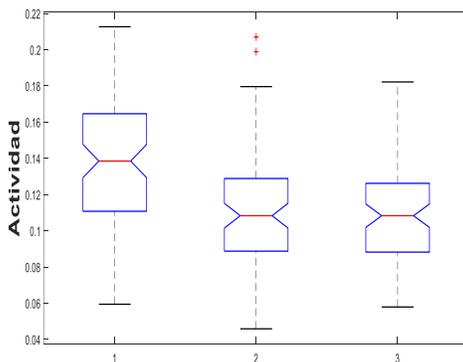
Sensor AF3 nodo 2. 1: Reposo, 2: Izquierda y 3: Derecha.



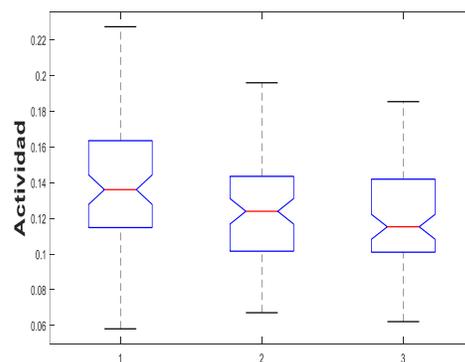
Sensor AF3 nodo 3. 1: Reposo, 2: Izquierda y 3: Derecha.



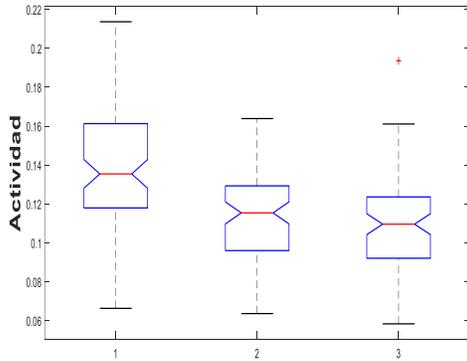
Sensor AF3 nodo 4. 1: Reposo, 2: Izquierda y 3: Derecha.



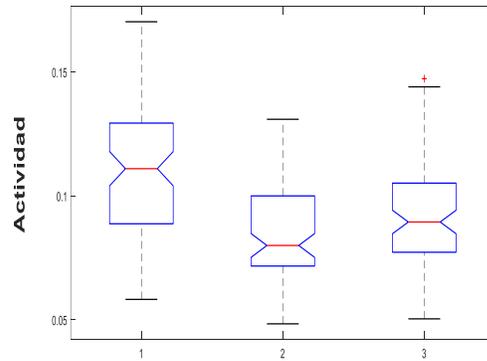
Sensor AF3 nodo 5. 1: Reposo, 2: Izquierda y 3: Derecha.



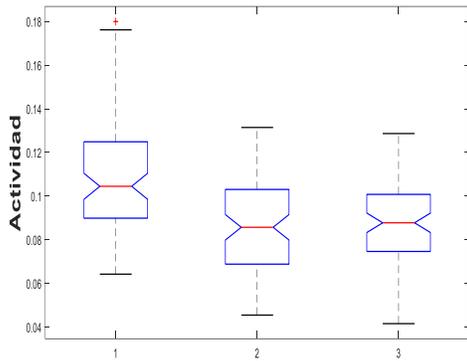
Sensor AF3 nodo 6. 1: Reposo, 2: Izquierda y 3: Derecha.



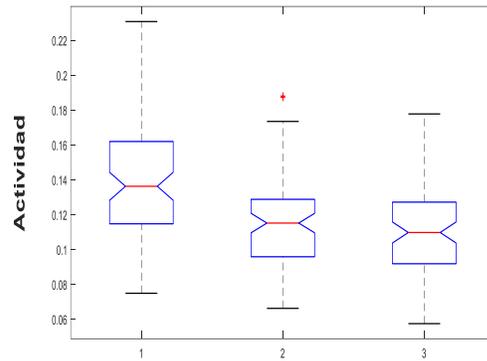
Sensor AF3 nodo 7. 1: Reposo, 2: Izquierda y 3: Derecha.



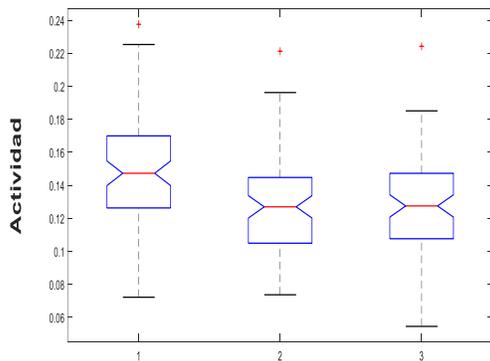
Sensor AF3 nodo 8. 1: Reposo, 2: Izquierda y 3: Derecha.



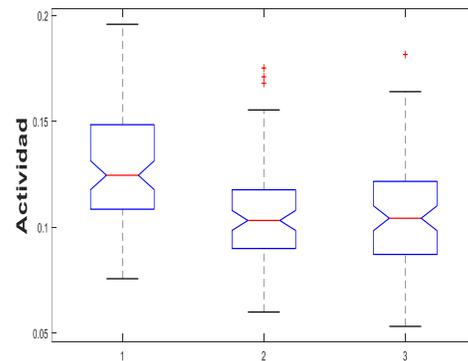
Sensor AF3 nodo 9. 1: Reposo, 2: Izquierda y 3: Derecha.



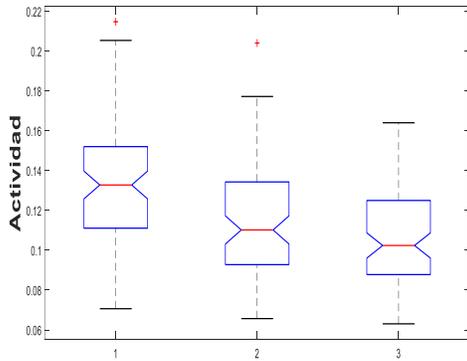
Sensor AF3 nodo 10. 1: Reposo, 2: Izquierda y 3: Derecha.



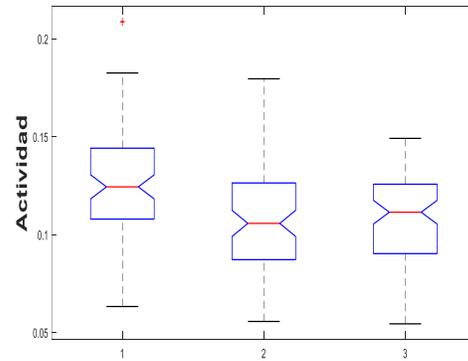
Sensor AF3 nodo 11. 1: Reposo, 2: Izquierda y 3: Derecha.



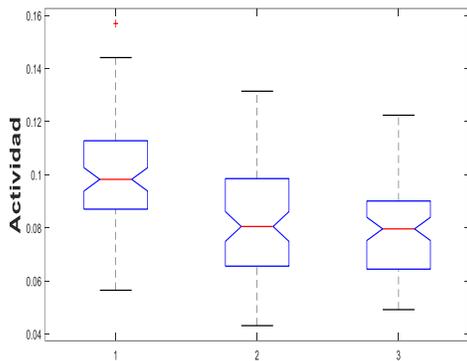
Sensor AF3 nodo 12. 1: Reposo, 2: Izquierda y 3: Derecha.



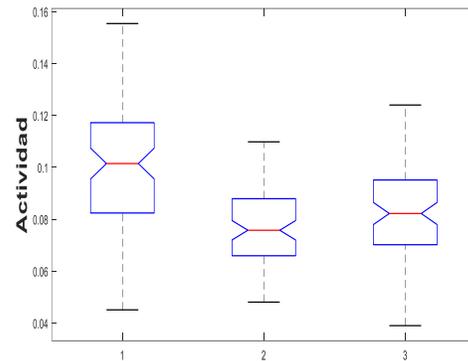
Sensor AF3 nodo 13. 1: Reposo, 2: Izquierda y 3: Derecha.



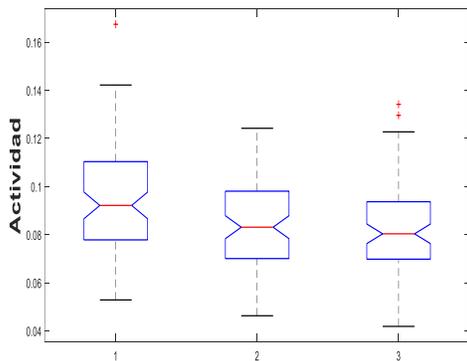
Sensor AF3 nodo 14. 1: Reposo, 2: Izquierda y 3: Derecha.



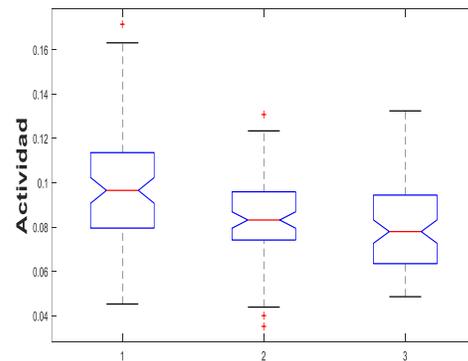
Sensor AF3 nodo 15. 1: Reposo, 2: Izquierda y 3: Derecha.



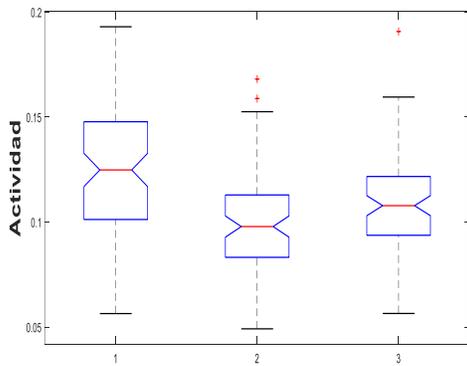
Sensor AF3 nodo 16. 1: Reposo, 2: Izquierda y 3: Derecha.



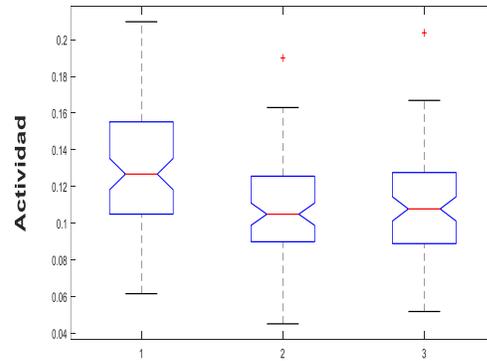
Sensor AF3 nodo 17. 1: Reposo, 2: Izquierda y 3: Derecha.



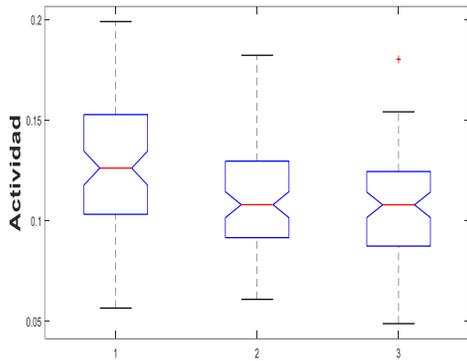
Sensor AF3 nodo 18. 1: Reposo, 2: Izquierda y 3: Derecha.



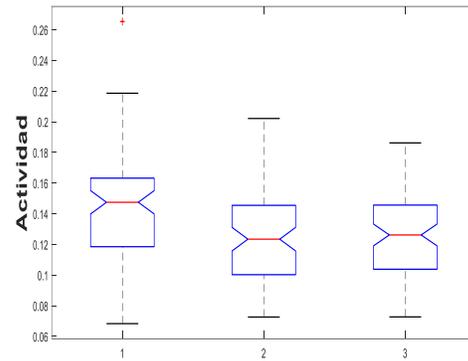
Sensor AF3 nodo 19. 1: Reposo, 2: Izquierda y 3: Derecha.



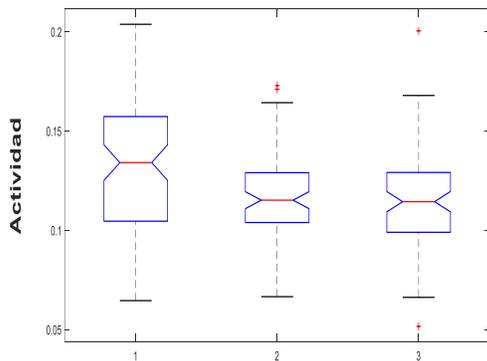
Sensor AF3 nodo 20. 1: Reposo, 2: Izquierda y 3: Derecha.



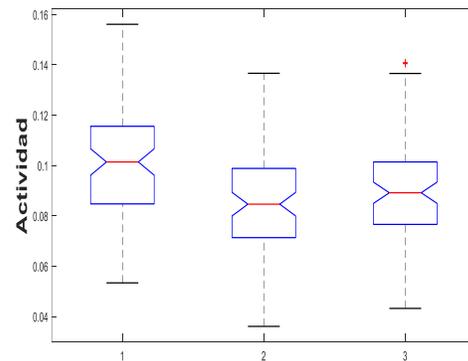
Sensor AF3 nodo 21. 1: Reposo, 2: Izquierda y 3: Derecha.



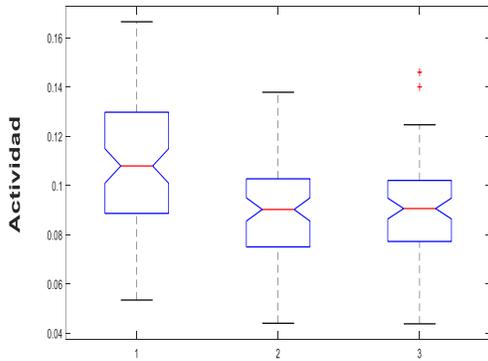
Sensor AF3 nodo 22. 1: Reposo, 2: Izquierda y 3: Derecha.



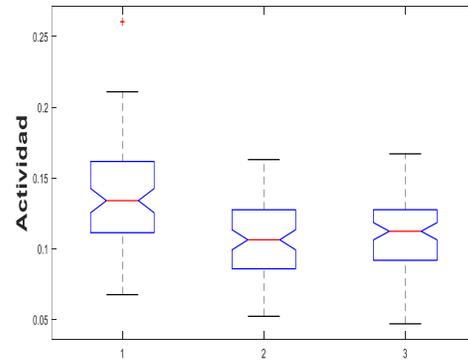
Sensor AF3 nodo 23. 1: Reposo, 2: Izquierda y 3: Derecha.



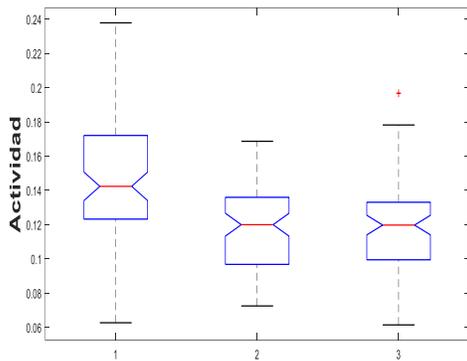
Sensor AF3 nodo 24. 1: Reposo, 2: Izquierda y 3: Derecha.



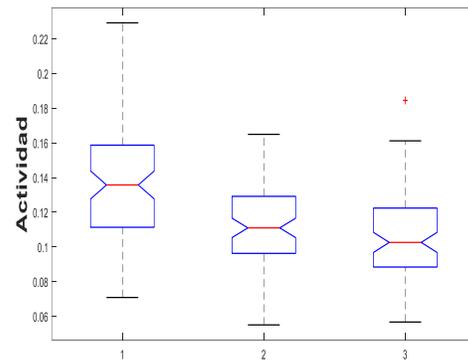
Sensor AF3 nodo 25. 1: Reposo, 2: Izquierda y 3: Derecha.



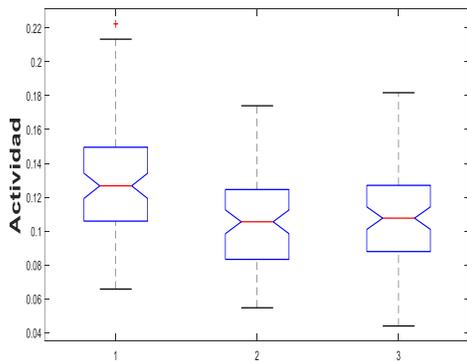
Sensor AF3 nodo 26. 1: Reposo, 2: Izquierda y 3: Derecha.



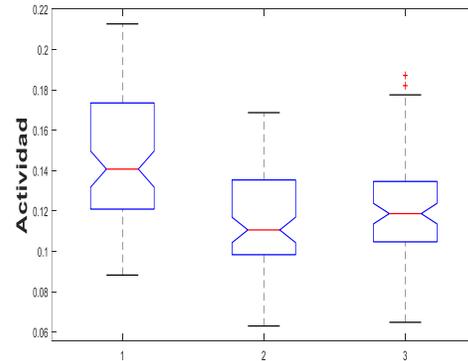
Sensor AF3 nodo 27. 1: Reposo, 2: Izquierda y 3: Derecha.



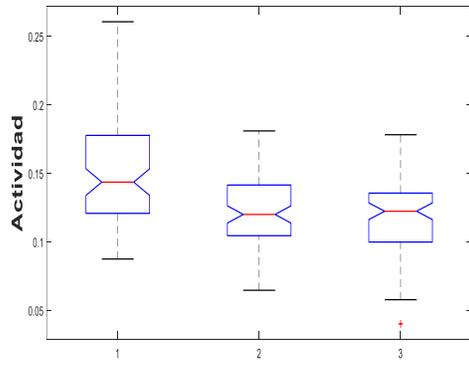
Sensor AF3 nodo 28. 1: Reposo, 2: Izquierda y 3: Derecha.



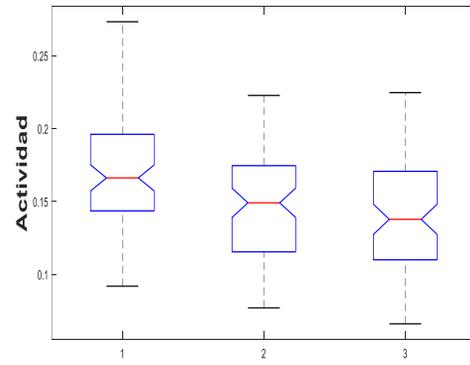
Sensor AF3 nodo 29. 1: Reposo, 2: Izquierda y 3: Derecha.



Sensor AF3 nodo 30. 1: Reposo, 2: Izquierda y 3: Derecha.

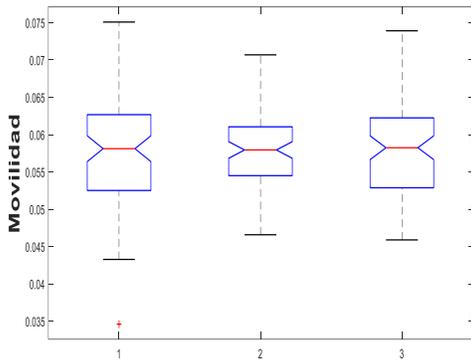


Sensor AF3 nodo 31. 1: Reposo, 2: Izquierda y 3: Derecha.

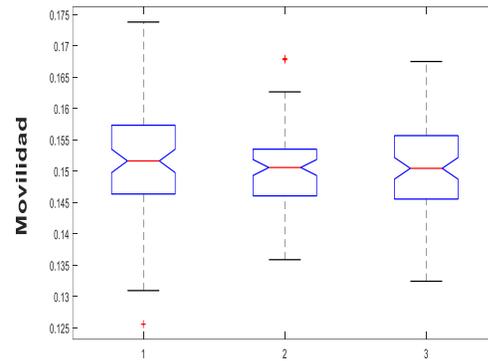


Sensor AF3 nodo 32. 1: Reposo, 2: Izquierda y 3: Derecha.

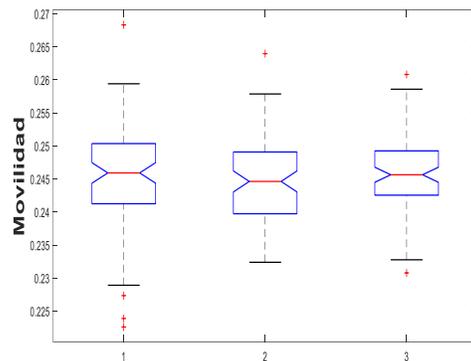
Graficas de ANOVAS del Parámetro de Hjorth Movilidad



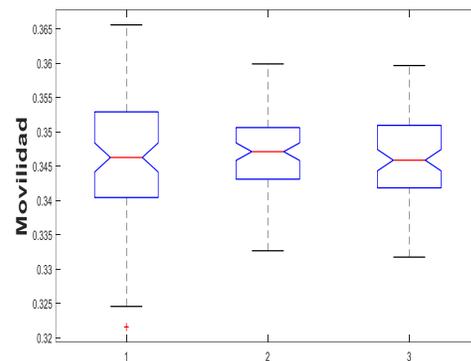
Sensor AF3 nodo 1. 1: Reposo, 2: Izquierda y 3: Derecha.



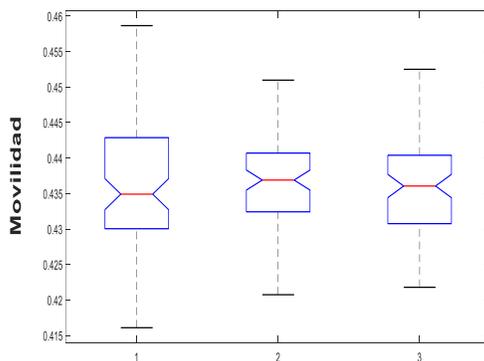
Sensor AF3 nodo 2. 1: Reposo, 2: Izquierda y 3: Derecha.



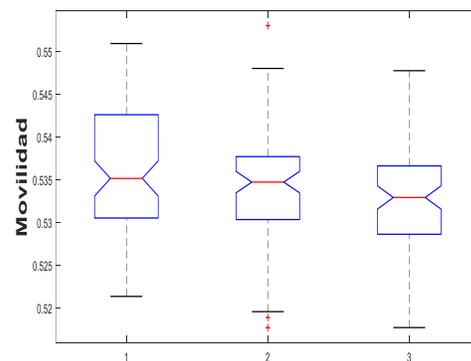
Sensor AF3 nodo 3. 1: Reposo, 2: Izquierda y 3: Derecha.



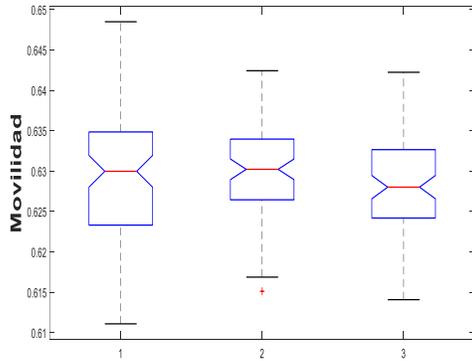
Sensor AF3 nodo 4. 1: Reposo, 2: Izquierda y 3: Derecha.



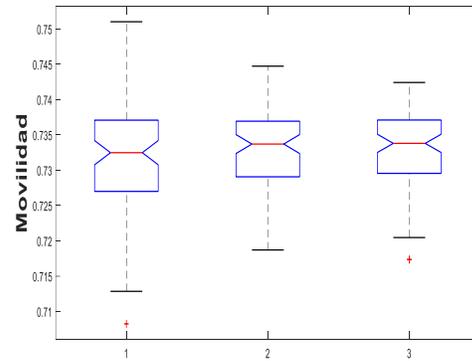
Sensor AF3 nodo 5. 1: Reposo, 2: Izquierda y 3: Derecha.



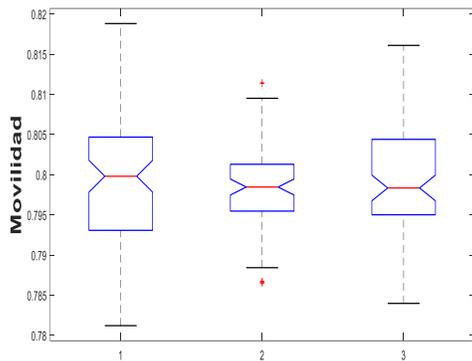
Sensor AF3 nodo 6. 1: Reposo, 2: Izquierda y 3: Derecha.



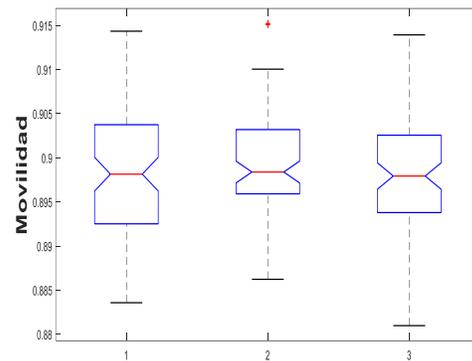
Sensor AF3 nodo 7. 1: Reposo, 2: Izquierda y 3: Derecha.



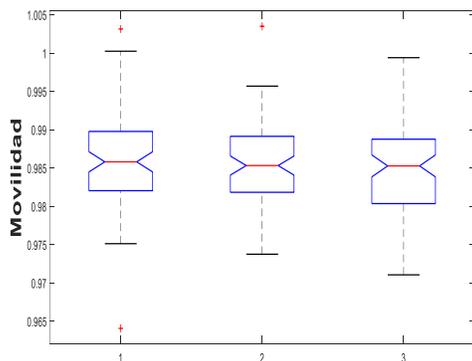
Sensor AF3 nodo 8. 1: Reposo, 2: Izquierda y 3: Derecha.



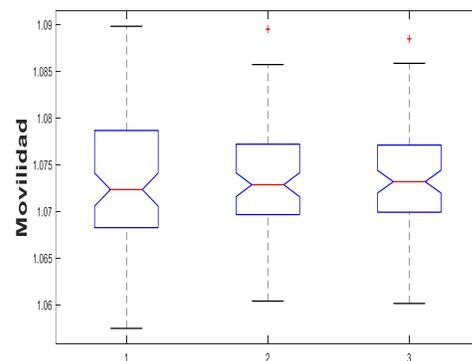
Sensor AF3 nodo 9. 1: Reposo, 2: Izquierda y 3: Derecha.



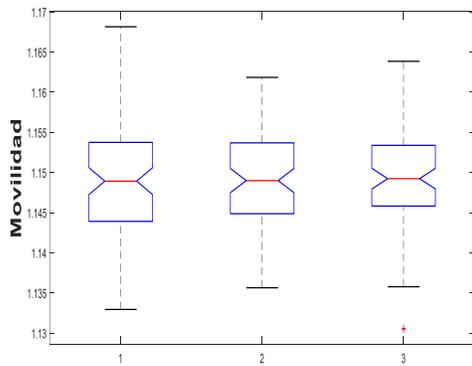
Sensor AF3 nodo 10. 1: Reposo, 2: Izquierda y 3: Derecha.



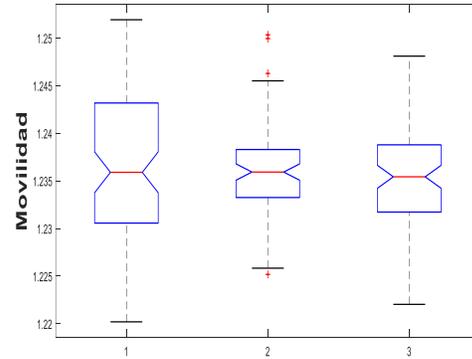
Sensor AF3 nodo 11. 1: Reposo, 2: Izquierda y 3: Derecha.



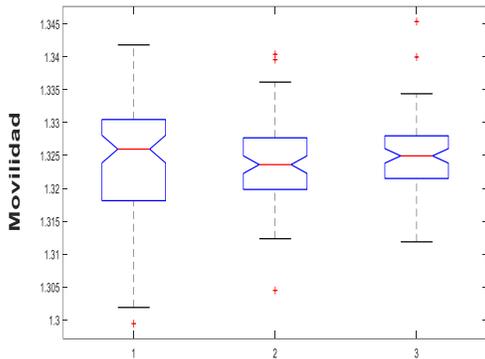
Sensor AF3 nodo 12. 1: Reposo, 2: Izquierda y 3: Derecha.



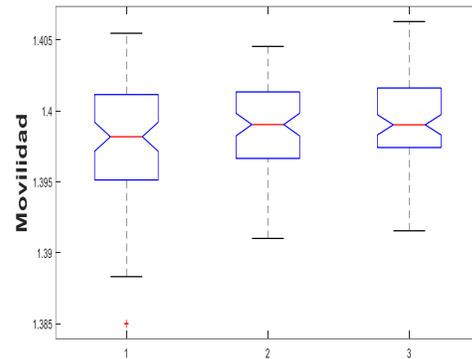
Sensor AF3 nodo 13. 1: Reposo, 2: Izquierda y 3: Derecha.



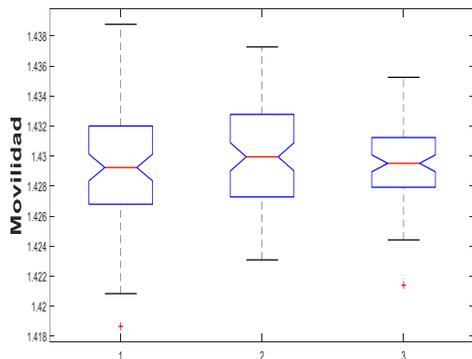
Sensor AF3 nodo 14. 1: Reposo, 2: Izquierda y 3: Derecha.



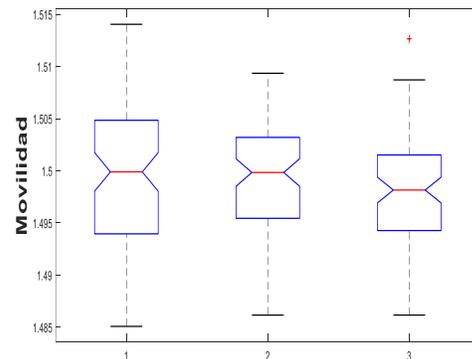
Sensor AF3 nodo 15. 1: Reposo, 2: Izquierda y 3: Derecha.



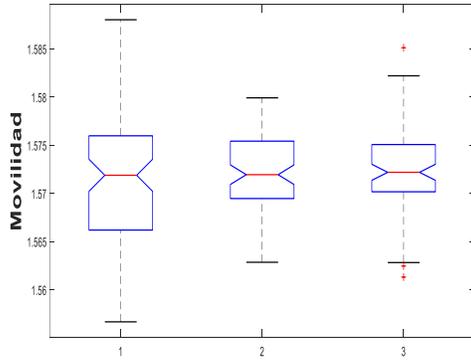
Sensor AF3 nodo 16. 1: Reposo, 2: Izquierda y 3: Derecha.



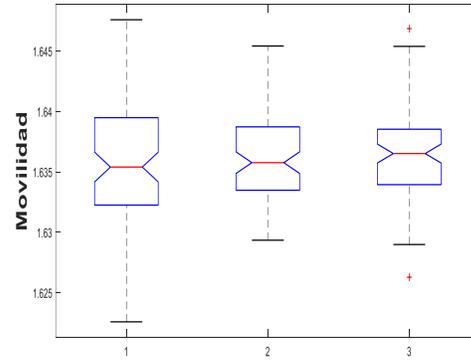
Sensor AF3 nodo 17. 1: Reposo, 2: Izquierda y 3: Derecha.



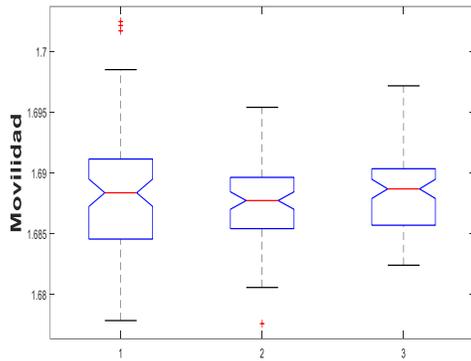
Sensor AF3 nodo 18. 1: Reposo, 2: Izquierda y 3: Derecha.



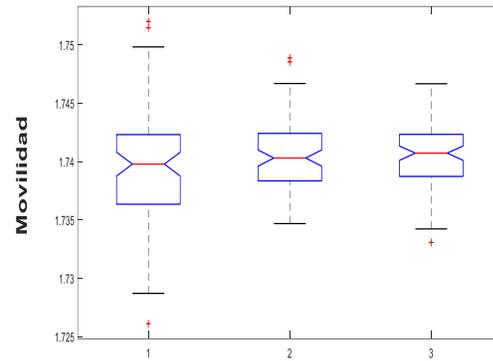
Sensor AF3 nodo 19. 1: Reposo, 2: Izquierda y 3: Derecha.



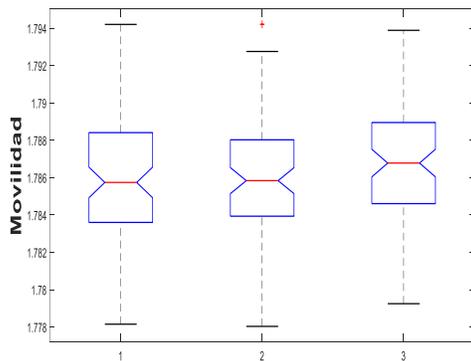
Sensor AF3 nodo 20. 1: Reposo, 2: Izquierda y 3: Derecha.



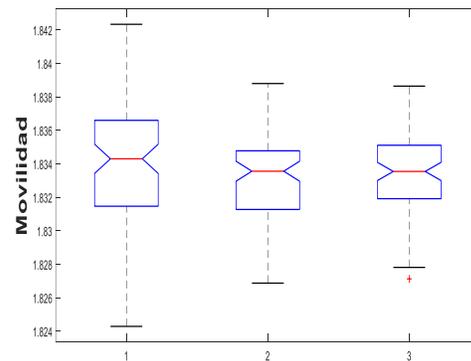
Sensor AF3 nodo 21. 1: Reposo, 2: Izquierda y 3: Derecha.



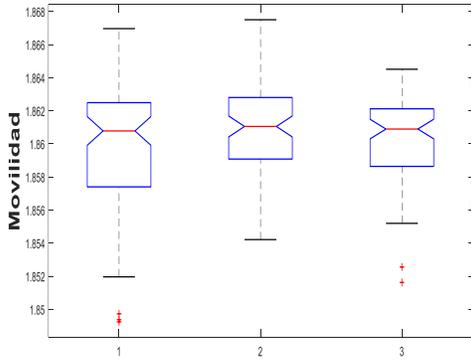
Sensor AF3 nodo 22. 1: Reposo, 2: Izquierda y 3: Derecha.



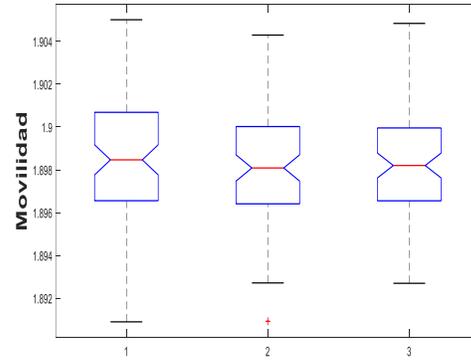
Sensor AF3 nodo 23. 1: Reposo, 2: Izquierda y 3: Derecha.



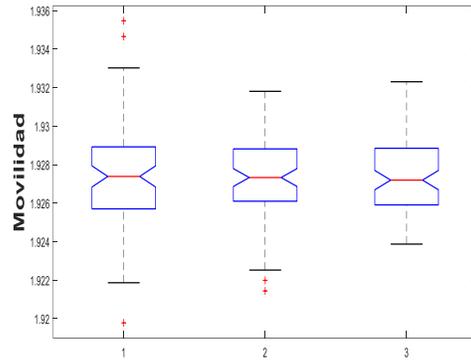
Sensor AF3 nodo 24. 1: Reposo, 2: Izquierda y 3: Derecha.



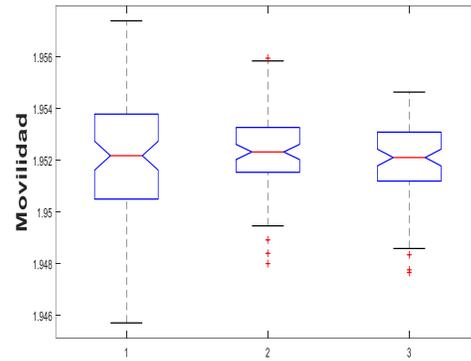
Sensor AF3 nodo 25. 1: Reposo, 2: Izquierda y 3: Derecha.



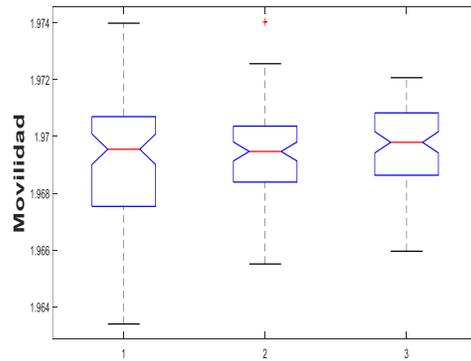
Sensor AF3 nodo 26. 1: Reposo, 2: Izquierda y 3: Derecha.



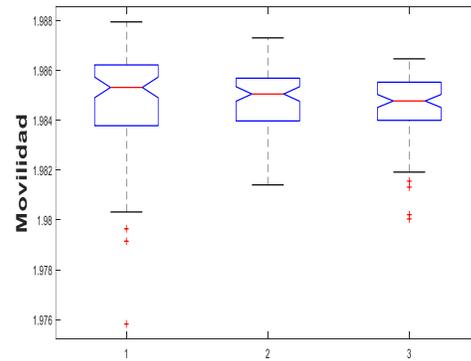
Sensor AF3 nodo 27. 1: Reposo, 2: Izquierda y 3: Derecha.



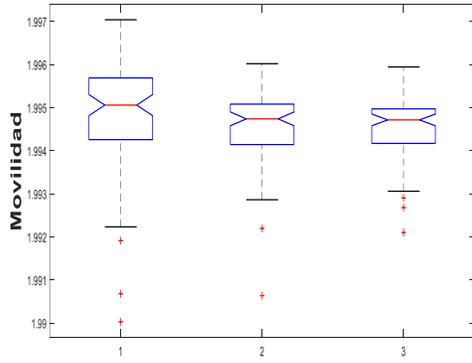
Sensor AF3 nodo 28. 1: Reposo, 2: Izquierda y 3: Derecha.



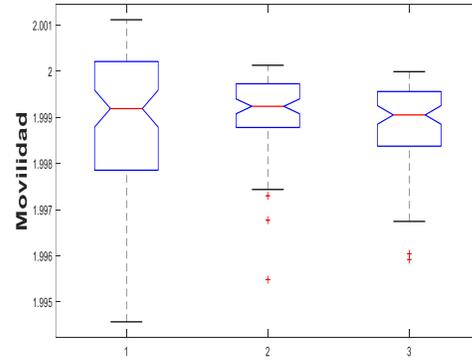
Sensor AF3 nodo 29. 1: Reposo, 2: Izquierda y 3: Derecha.



Sensor AF3 nodo 30. 1: Reposo, 2: Izquierda y 3: Derecha.

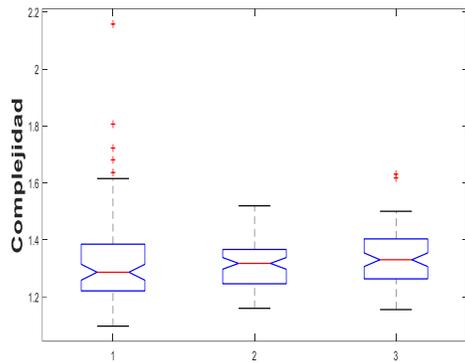


Sensor AF3 nodo 31. 1: Reposo, 2: Izquierda y 3: Derecha.

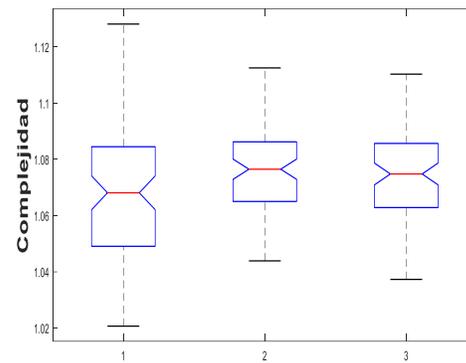


Sensor AF3 nodo 32. 1: Reposo, 2: Izquierda y 3: Derecha.

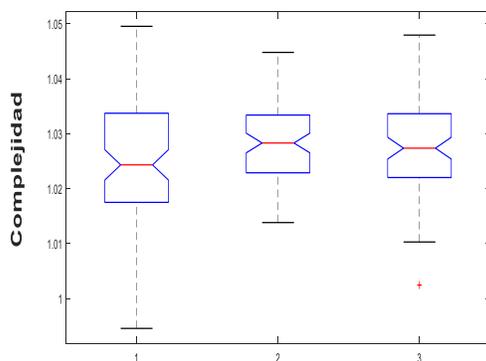
Graficas de ANOVAS del Parámetro de Hjorth Complejidad



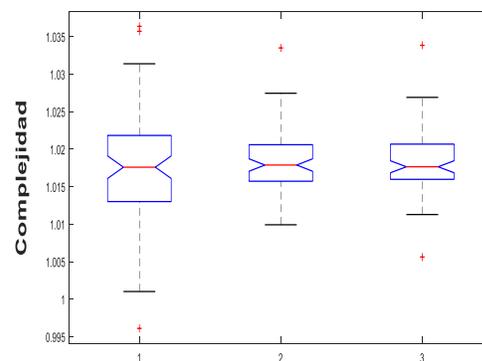
Sensor AF3 nodo 1. 1: Reposo, 2: Izquierda y 3: Derecha.



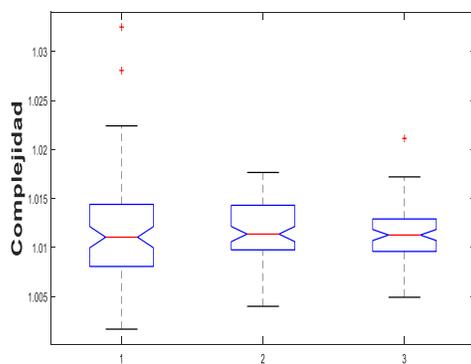
Sensor AF3 nodo 2. 1: Reposo, 2: Izquierda y 3: Derecha.



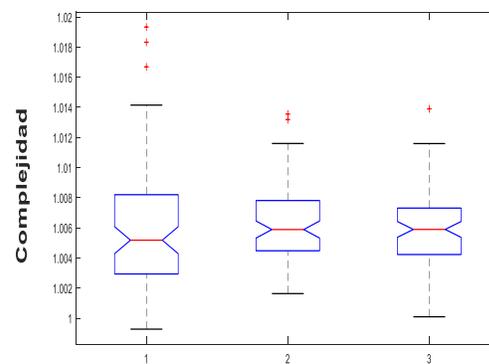
Sensor AF3 nodo 3. 1: Reposo, 2: Izquierda y 3: Derecha.



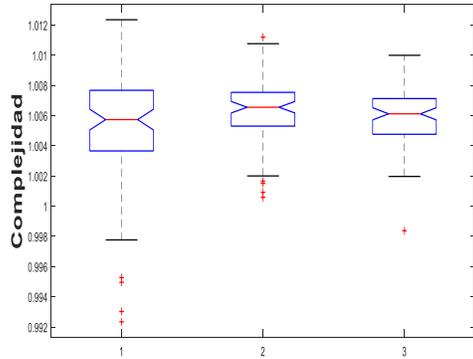
Sensor AF3 nodo 4. 1: Reposo, 2: Izquierda y 3: Derecha.



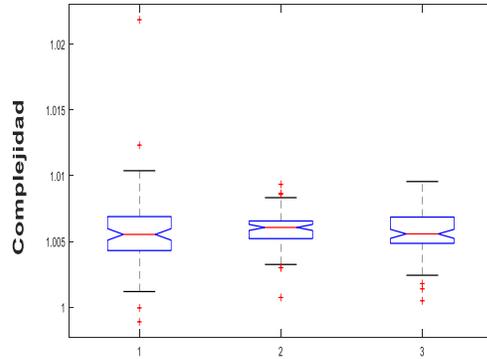
Sensor AF3 nodo 5. 1: Reposo, 2: Izquierda y 3: Derecha.



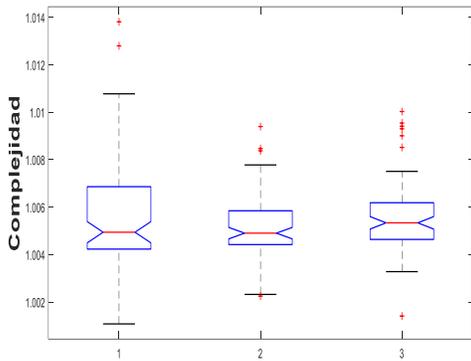
Sensor AF3 nodo 6. 1: Reposo, 2: Izquierda y 3: Derecha.



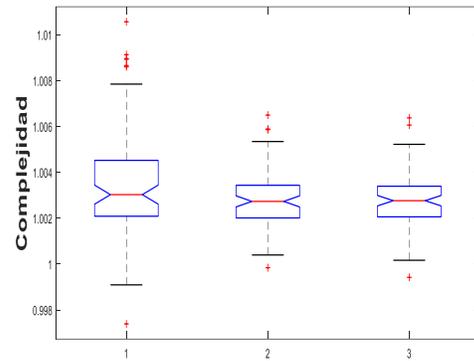
Sensor AF3 nodo 7. 1: Reposo, 2: Izquierda y 3: Derecha.



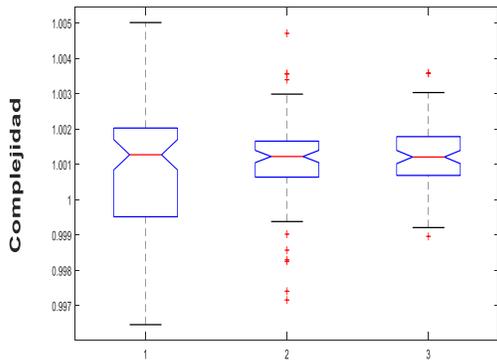
Sensor AF3 nodo 8. 1: Reposo, 2: Izquierda y 3: Derecha.



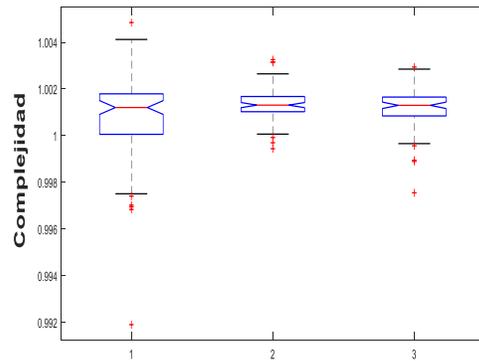
Sensor AF3 nodo 9. 1: Reposo, 2: Izquierda y 3: Derecha.



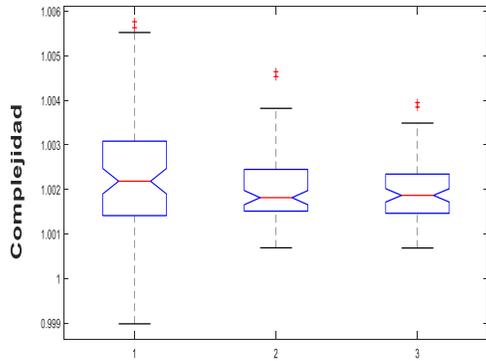
Sensor AF3 nodo 10. 1: Reposo, 2: Izquierda y 3: Derecha.



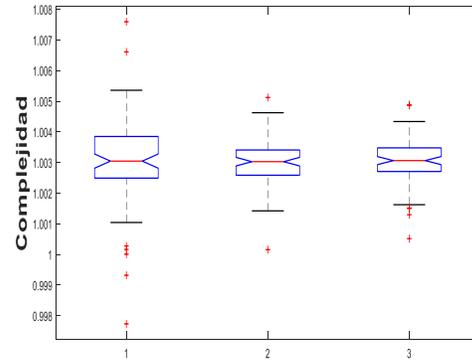
Sensor AF3 nodo 11. 1: Reposo, 2: Izquierda y 3: Derecha.



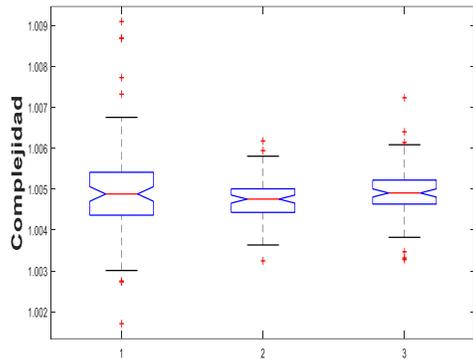
Sensor AF3 nodo 12. 1: Reposo, 2: Izquierda y 3: Derecha.



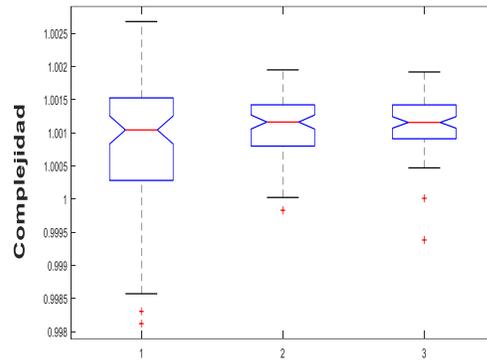
Sensor AF3 nodo 13. 1: Reposo, 2: Izquierda y 3: Derecha.



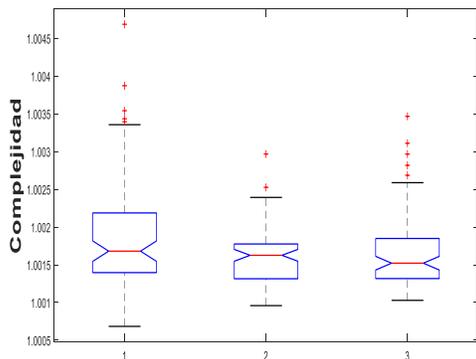
Sensor AF3 nodo 14. 1: Reposo, 2: Izquierda y 3: Derecha.



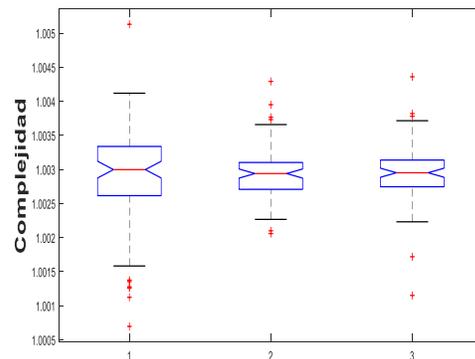
Sensor AF3 nodo 15. 1: Reposo, 2: Izquierda y 3: Derecha.



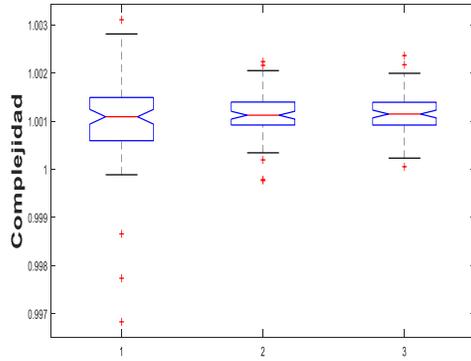
Sensor AF3 nodo 16. 1: Reposo, 2: Izquierda y 3: Derecha.



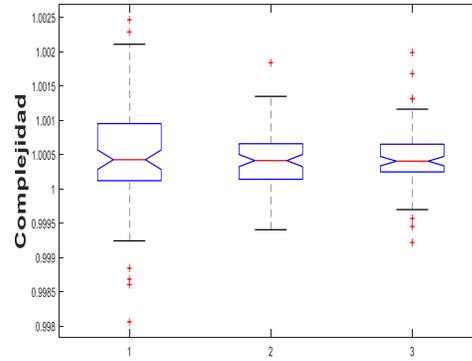
Sensor AF3 nodo 17. 1: Reposo, 2: Izquierda y 3: Derecha.



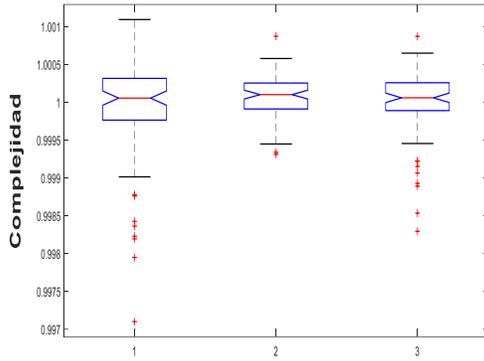
Sensor AF3 nodo 18. 1: Reposo, 2: Izquierda y 3: Derecha.



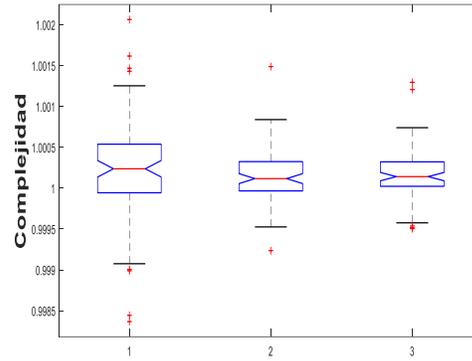
Sensor AF3 nodo 19. 1: Reposo, 2: Izquierda y 3: Derecha.



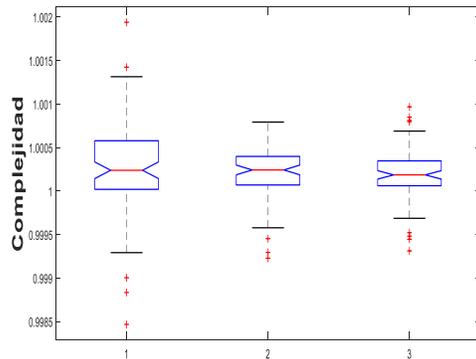
Sensor AF3 nodo 20. 1: Reposo, 2: Izquierda y 3: Derecha.



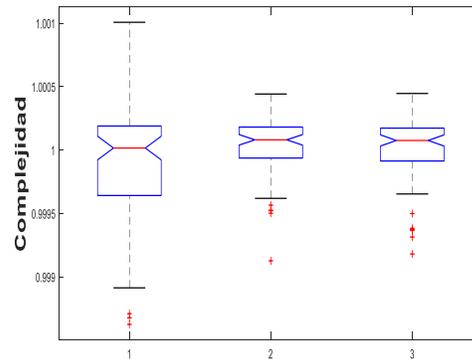
Sensor AF3 nodo 21. 1: Reposo, 2: Izquierda y 3: Derecha.



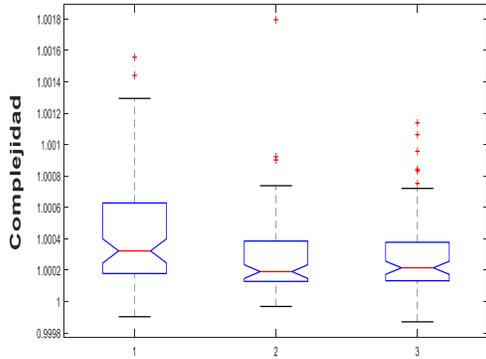
Sensor AF3 nodo 22. 1: Reposo, 2: Izquierda y 3: Derecha.



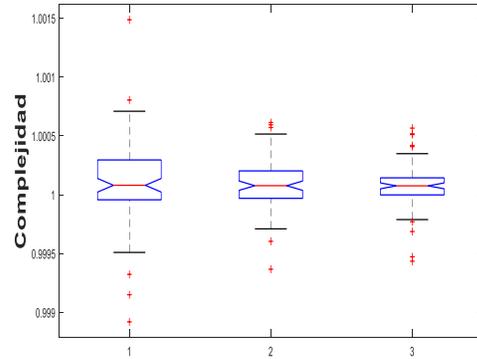
Sensor AF3 nodo 23. 1: Reposo, 2: Izquierda y 3: Derecha.



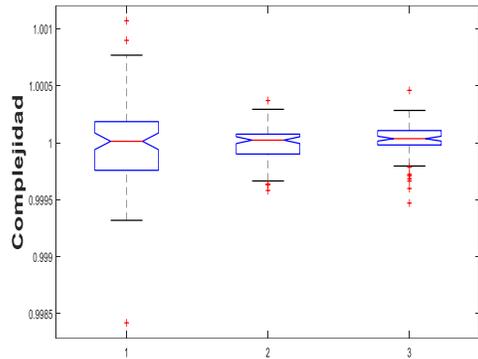
Sensor AF3 nodo 24. 1: Reposo, 2: Izquierda y 3: Derecha.



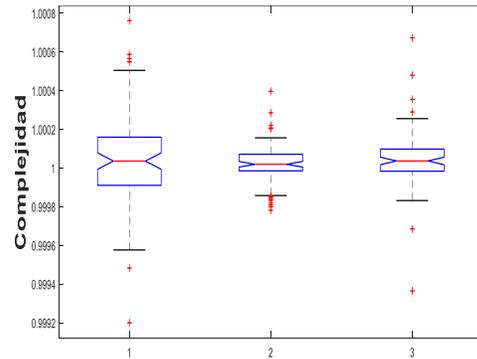
Sensor AF3 nodo 25. 1: Reposo, 2: Izquierda y 3: Derecha.



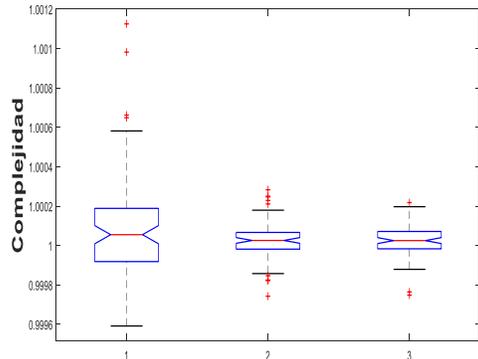
Sensor AF3 nodo 26. 1: Reposo, 2: Izquierda y 3: Derecha.



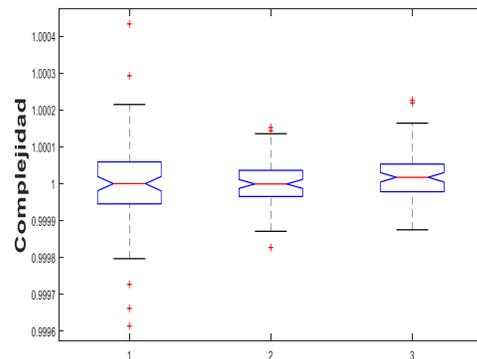
Sensor AF3 nodo 27. 1: Reposo, 2: Izquierda y 3: Derecha.



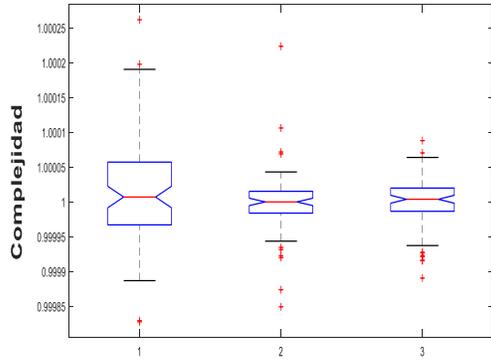
Sensor AF3 nodo 28. 1: Reposo, 2: Izquierda y 3: Derecha.



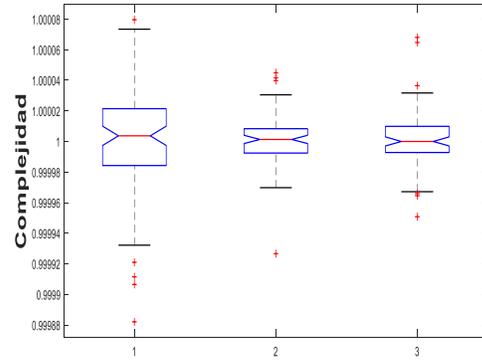
Sensor AF3 nodo 29. 1: Reposo, 2: Izquierda y 3: Derecha.



Sensor AF3 nodo 30. 1: Reposo, 2: Izquierda y 3: Derecha.



Sensor AF3 nodo 31. 1: Reposo, 2: Izquierda y 3: Derecha.



Sensor AF3 nodo 32. 1: Reposo, 2: Izquierda y 3: Derecha.