



**CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS AVANZADOS
DEL INSTITUTO POLITÉCNICO NACIONAL**

UNIDAD ZACATENCO
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA
SECCIÓN DE BIOELECTRÓNICA

Adquisición, análisis y clasificación de señales electroencefalográficas (EEG) para
identificar movimientos reales de las extremidades superiores

Tesis que presenta

Esmeralda Ivonne Muñoz López

para obtener el grado de

Maestra en Ciencias

en la Especialidad de

Ingeniería Eléctrica

Director de tesis: Dr. Roberto Muñoz Guerrero

RESUMEN

La necesidad del desarrollo de prótesis data desde hace muchas décadas, pero solo en los últimos años se ha contado con la tecnología necesaria para desarrollar prótesis que imiten la función y desempeño de la parte real que se sustituye. Actualmente, las prótesis mioeléctricas se adaptan mejor a las necesidades de las personas que requieren de ellas, sin embargo carecen de la velocidad y precisión necesarias para cubrir las del todo. Los avances más recientes de la medicina y la electrónica han hecho posible el desarrollo de prótesis más eficientes, apoyadas por las interfaces cerebro computadora (por sus siglas en inglés *Brain Computer Interface* BCI). Las BCI se basan principalmente en el análisis de las señales electroencefalográficas (por sus siglas en inglés *electroencephalography/electroencephalogram* EEG) captadas durante algún tipo de actividad cerebral con la finalidad de controlar un componente externo, como lo son las prótesis. Contribuyendo al desarrollo de BCI, el presente trabajo se basa en identificar en la señal EEG, patrones de movimientos reales de las extremidades superiores de sujetos sin problemas neuromusculares. Para extraer las características en frecuencia de las señales EEG, se calculó la transformada wavelet discreta (por sus siglas en inglés *Discrete Wavelet Transform* DWT) y la transformada rápida de Fourier (por sus siglas en inglés *Fast Fourier Transform* FFT), tomando como referencia el ritmo mu (8-13 Hz), que representa la actividad motora. Utilizando los resultados de la DWT como medio de compactación se procedió a la aplicación del análisis de componentes principales (por sus siglas en inglés *Principal Component Analysis* PCA) para reducir la dimensionalidad de los datos por medio de la disminución de canales. Para la clasificación de los patrones de movimiento se utilizó una red neuronal artificial (por sus siglas en inglés *Artificial Neural Network* ANN) del tipo perceptrón multicapa. El mayor porcentaje de exactitud (87%) para movimientos con ojos cerrados y para movimientos con ojos abiertos (86%), se obtuvo normalizando los datos obtenidos de las técnicas empleadas para la extracción de características.

ABSTRACT

The need to develop prosthesis began since many decades ago, but only in recent years, we have had the necessary technology to develop prostheses that mimic the function and performance of the real part that is being replaced. Currently, the myoelectric prosthesis to the needs of people who require them adapt, but lack the speed and precision needed to cover them all. The most recent advances in medicine and electronics have made possible the development of more efficient prosthesis, supported by the brain computer interfaces (BCI). The BCI is mainly based on the analysis of electroencephalographic signals (EEG) captured during some kind of brain activity in order to control an external component, such as prostheses. Contributing to the development of BCI, the present work is based on identifying the EEG signal patterns actual movements of the upper extremities of subjects without neuromuscular problems. To extract the frequency characteristics of the EEG signals, the discrete wavelet transform (DWT) and fast Fourier transform (FFT) is calculated by reference to the rate μ (8-13 Hz) which represents motor activity. Using the results of the DWT are proceeded to the application of principal component analysis (PCA) to reduce the dimensionality of the data by decreasing channels an artificial neural network was used (ANN) for classification of the movement patterns of Multilayer Perceptron. The highest percentage of accuracy (87%) for movements with eyes closed and open eye movements (86%).

Agradecimientos

Agradezco al Consejo Nacional de Ciencia y Tecnología (CONACYT) por su apoyo y patrocinio para realizar mis estudios de maestría.

Al Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional (CINVESTAV) y a la sección de Bioelectrónica, en especial al Dr. Roberto Muñoz Guerrero por el apoyo, la orientación y discusión crítica durante la realización del presente trabajo de investigación.

Al Instituto Nacional de Rehabilitación (INR), en especial a la Dra. Jessica Cantillo Negrete, por el apoyo para realizar el presente trabajo de investigación.

Contenido General

	Pag.
Resumen	i
Abstract	ii
Lista de figuras	vi
Lista de tablas	ix
1 Introducción	1
1.1 Planteamiento del problema	1
1.2 Objetivo general	3
1.3 Objetivos específicos	3
1.4 Justificación	3
1.5 Estructura	5
2 Marco Teórico	6
2.1 Electroencefalografía (EEG)	6
2.1.1 Generación de EEG	6
2.1.2 Contribuciones del neocórtex al control del movimiento	7
2.1.3 Ritmos cerebrales	10
2.2 Procesamiento digital de señales EEG	11
2.2.1 Cancelación de artefactos	12
2.2.2 Extracción de características en el dominio del tiempo y frecuencia	13
2.2.3 Extracción de características espaciales	14
2.2.4 Redes neuronales artificiales	15
3 Antecedentes y estado del arte	17

4	Desarrollo	19
4.1	Solución propuesta	19
4.2	Adquisición de las señales EEG	20
4.2.1	Protocolo para la adquisición de las señales EEG	20
4.3	Procesamiento de las señales EEG	26
4.3.1	Pre-procesamiento	27
4.3.2	Extracción de características	30
4.3.3	Clasificación de patrones de movimiento	36
5	Pruebas	40
5.1	Pruebas realizadas en el laboratorio con el sistema de adquisición ADS1299EEG-FE	40
5.2	Pruebas realizadas en la clínica con el sistema de adquisición g.BCI sys	45
6	Resultados	47
6.1	Adquisición de las señales EEG	47
6.2	Extracción de características	49
6.2.1	Transformada rápida de Fourier	50
6.2.2	Transformada wavelet discreta	52
6.2.3	Análisis de componentes principales.	53
6.3	Clasificación con redes neuronales artificiales.	56
7	Discusión	66
8	Conclusiones y perspectiva	68
	Referencias	70
	Apéndice	76

Lista de figuras

Figura	Pag.
2.1 Representación esquemática de las partes del cerebro.	7
2.2 Regiones generales del neocórtex. Las áreas numeradas hacen referencia a las áreas de la corteza según el mapa del sistema de Brodmann.	8
2.3 Homúnculo de Penfield.	9
2.4 Formas de ondas cerebrales.	11
2.5 Posición 10-20 de los electrodos de EEG convencionales para la colocación de 21 electrodos.	12
4.1 Diagrama a bloques del sistema de adquisición y clasificación de señales electroencefalográficas para la identificación de movimientos reales de las extremidades superiores.	20
4.2 Sistema de adquisición de la señal EEG.	22
4.3 Conexiones del sistema de adquisición de la señal EEG.	22
4.4 Posición del sujeto de prueba durante la adquisición de la señales EEG	23
4.5 Diagrama de flujo del sistema de adquisición de la señal EEG.	25
4.6 Selección de sujetos de prueba con respecto a sus niveles de eliminación.	27
4.7 Acercamiento de la señal EEG llevada a 0 - ojos abiertos, canal 2.	28
4.8 Marcadores de tiempo en señal EEG filtrada de la secuencia 1 de movimientos con ojos abiertos.	29

4.9	Ventaneo de la señal EEG.	31
4.10	Transformada rápida de Fourier aplicada a la señal EEG.	33
4.11	Niveles de descomposición de la DWT con sus respectivas frecuencias.	34
4.12	Diagrama de flujo del código generado para la identificación de patrones de movimiento en las señales EEG por medio de una ANN.	39
5.1	Señal EEG reconstruida a partir de los coeficientes obtenidos en el nivel de descomposición 6.	42
5.2	Distancias euclidianas de la señal original y la señal reconstruida para 9 niveles de descomposición y 16 sujetos de prueba.	43
5.3	Transformación lineal de señales EEG por medio de PCA y su varianza.	43
5.4	Posición del sujeto de prueba durante la adquisición de la señal con el equipo g.BCI sys.	46
6.1	Señales EEG - base de datos obtenida en la clínica.	48
6.2	Porcentajes de exactitud (PE) para cada una de las ventanas por segmento.	48
6.3	Porcentajes de exactitud (PE) empleando diferentes herramientas de extracción de características.	49
6.4	Diagrama de caja y bigotes.	50
6.5	Diagramas de caja utilizando los coeficientes de la FFT - base de datos del laboratorio.	51
6.6	Diagramas de caja utilizando los coeficientes de la FFT - base de datos de clínica.	52
6.7	Dispersión de los datos por medio de PCA - base de datos del laboratorio.	55
6.8	Dispersión de los datos por medio de PCA - base de datos de la clínica.	56
6.9	Porcentajes de exactitud de 30 entrenamientos de datos de prueba.	58

6.10	Regresión lineal - base de datos obtenida en el laboratorio.	59
6.11	Regresión lineal - base de datos obtenida en la clínica.	60

Lista de tablas

Tabla	Pag.
4.1 Secuencias de movimiento realizadas durante la adquisición de las señales EEG.	26
6.1 Niveles de descomposición wavelet.	53
6.2 Matriz de confusión - ojos cerrados. Base de datos del laboratorio.	62
6.3 Matriz de confusión - ojos abiertos. Base de datos del laboratorio.	63
6.4 Matriz de confusión - ojos cerrados. Base de datos de la clínica.	64
6.5 Matriz de confusión - ojos abiertos. Base de datos de la clínica.	65
A.1 Distancias euclidianas de la señal original y la señal reconstruida para 9 niveles de descomposición y 16 sujetos de prueba.	81
A.2 Porcentajes de exactitud (PE) de la clasificación con respecto a las ventanas. . .	82

Capítulo 1

Introducción

1.1 Planteamiento del problema

La amputación conlleva a un cambio en la imagen corporal, que en muchos casos va acompañado por un rechazo social, que no solo tiene un impacto negativo en el desarrollo de actividades cotidianas sino también provocar incapacidad laboral. El impacto social relacionado con los pacientes amputados causa un cambio en uno o más de los siguientes puntos:

- modo de vivir de las personas
- su comunidad: cohesión, identidad, independencia, etc.
- su ambiente físico
- sus derechos personales y de propiedad
- sus miedos y aspiraciones
- niveles de bienestar

En la actualidad existe una gran cantidad de personas que presentan amputación de alguna o ambas extremidades superiores. El 90% de los aparatos prescritos son prótesis automotrices por cable y el 10% son mioeléctricas, pero requieren de una capacitación prolongada y tediosa, sin embargo, gracias a los avances de la medicina y la electrónica, se desarrolló el campo de las neuroprótesis, apoyadas por las BCI (por sus siglas en inglés *Brain Computer Interface* BCI) [2, 3, 4]. Estas interfaces no dependen del accionar de las fibras musculares, sino que extraen los movimientos del cuerpo registrados eléctricamente en el cerebro por medio del electroencefalograma ó de los potenciales evocados. Esto permite mejorar la velocidad y precisión, creando así un control de prótesis más cercano al natural. La actividad electrofisiológica para una BCI puede obtenerse mediante electrodos superficiales o implantados, por lo que se pueden clasificar como técnicas invasivas y no invasivas [5, 6, 7].

En las últimas décadas, las BCI existentes necesitaban de una cantidad considerable de tiempo de entrenamiento o utilizar bioseñales invasivas para su funcionamiento [8]. Los trabajos realizados en los últimos años, han comprobado que es posible realizar una BCI no invasiva por medio de la EEG (por sus siglas en inglés *electroencephalography/ electroencephalogram* EEG) [9, 10]. La EEG es el registro y evaluación de los potenciales eléctricos generados por el cerebro y obtenidos por medio de electrodos situados sobre la superficie del cuero cabelludo. Dicho registro posee formas muy complejas que presentan una gran variación dependiendo de la localización de los electrodos e incluso entre individuos. Esto es debido al gran número de interconexiones que presentan las neuronas y por la estructura no uniforme del encéfalo [11].

Para apoyar en el desarrollo de neuroprótesis, este trabajo se basa en el proceso de registro y análisis de señales EEG. Durante este proceso, la etapa de extracción de características es probablemente el paso más crítico, ya que determina directamente tanto el rendimiento como la precisión del algoritmo de clasificación utilizado [12]. Distintos criterios pueden ser observados a la hora de llevar a cabo el proceso de extracción de características, a partir de

las señales EEG medidas, de un conjunto de características válido para la identificación de patrones de movimientos reales.

1.2 Objetivo general

Identificar en la señal electroencefalográfica los patrones de movimientos reales de las extremidades superiores de sujetos sin problemas neuromusculares.

1.3 Objetivos específicos

- generar una base de datos de registros obtenidos durante la ejecución de movimientos de las extremidades superiores
- implementar un algoritmo para realizar el procesamiento de las señales EEG adquiridas durante las pruebas realizadas en las extremidades superiores
- identificar las características en frecuencia de las señales EEG resultantes en cada fase de prueba de los movimientos reales y reposo de las extremidades superiores
- clasificar a partir de las señales electroencefalográficas el reposo y los movimientos reales de las extremidades superiores

1.4 Justificación

Con respecto a los datos de incidencia, el Instituto Nacional de Estadísticas y Geografía (INEGI), reporta que en el 2001, 664 mil individuos sufrieron pérdida de pie, pierna o brazo [13]. Mientras que la Academia Nacional de Cirugía reporta que se amputan en México 75 personas diarias. En el 2015, la Academia Nacional de Medicina, señaló que sólo 1 de cada 10 personas con miembros amputados se rehabilita y que de los rehabilitados únicamente el 30%

sabe usar adecuadamente sus prótesis [1]. Por otra parte, describió que para la rehabilitación de los pacientes amputados, no sólo es ponerles una prótesis sino que es importante fortalecer su musculatura y fortalecer al paciente para que no la abandone por falta del sentir algún beneficio. Para la mayoría de los amputados el proceso de optar por una prótesis resulta ser largo, tediosos y complicado [14].

Por último, comentó sobre los trasplantes de miembro superior; dijo que no se han hecho más de 70 en el mundo en los últimos 20 años, pero que se sabe que disminuyen la expectativa de vida pues hay que contender con problemas de rechazo y su tratamiento mediante inmunosupresores [1].

En la actualidad las prótesis mioeléctricas son las más utilizadas, pero presentan ciertos inconvenientes como el número limitado de articulaciones además de que al momento de usarlas por primera vez la rehabilitación suele ser de un tiempo prolongado [3, 4]. Es por ello que en este trabajo se propone apoyar en el desarrollo de una neuroprótesis. Los beneficios más importantes que aportan las neuroprótesis a los amputados son:

- disminución del tiempo de rehabilitación: el amputado aún recuerda cómo movía el miembro superior por lo que representa una tarea sencilla el recordarlo
- mejor calidad de vida: a diferencia de las prótesis mioeléctricas, las neuroprótesis poseen un mayor número de grados de libertad, permitiendo así, realizar un mayor número de actividades de la vida cotidiana

Para este trabajo es preciso generar una base de datos propia de registros EEG de personas aparentemente sanas, con el fin de encontrar patrones de movimiento en su actividad cerebral y así poder desarrollar en futuros trabajos, una BCI que dará como resultado la realización de una neuroprótesis [15, 16, 17, 18].

1.5 Estructura

A continuación se detallan los capítulos en los que se ha estructurado el presente trabajo:

Introducción

Presenta el planteamiento del problema, la definición de objetivos generales y de los específicos, y la justificación del análisis de las señales EEG.

Marco teórico

Redacta las bases teóricas del aspecto fisiológico, con un enfoque de ingeniería, que serán aplicadas en el desarrollo del presente trabajo.

Antecedentes y estado del arte

Explica los hallazgos científicos y tecnológicos más relevantes respecto al procesamiento y adquisición de las señales EEG.

Desarrollo

Presenta las herramientas y protocolos utilizados para la adquisición y el procesamiento de señales electroencefalográficas.

Pruebas

Explica la realización de las pruebas realizadas durante el desarrollo del proyecto.

Resultados

Muestra los resultados obtenidos de las pruebas realizadas en el laboratorio con el sistema de adquisición AD1299EEG-FE y la validación con la comparación de los mismos con los resultados obtenidos con el sistema de adquisición g.BCIy utilizado en la clínica.

Discusión

Análisis e interpretación de los resultados obtenidos durante la realización de este trabajo.

Conclusiones y perspectivas

Muestra las conclusiones generales del trabajo realizado y los alcances que se pudieran obtener de un trabajo a futuro.

Capítulo 2

Marco Teórico

2.1 Electroencefalografía (EEG)

La EEG es una exploración neurofisiológica que se basa en el registro de la actividad bioeléctrica cerebral en condiciones basales de reposo, en vigilia o sueño, y durante diversas activaciones (habitualmente estimulación luminosa intermitente) mediante un equipo de electroencefalografía [19].

2.1.1 Generación de EEG

Una señal EEG es una medida de corrientes de flujo durante la excitación sináptica de las dendritas de neuronas piramidales en la corteza cerebral. Cuando las neuronas son activadas, las corrientes sinápticas son producidas sin las dendritas. La corriente genera un campo magnético por electromiograma (en inglés *electromyography* EMG) y un campo eléctrico secundario sobre el cuero cabelludo medible por los sistemas de EEG. Desde el punto de vista anatómico el cerebro se puede dividir en tres partes: el cerebro, el cerebelo y tallo cerebral (figura 2.1). El cerebro se compone de ambos lóbulos, izquierdo y derecho del cerebro con capas superficiales altamente contorneados llamada "corteza cerebral". El cerebro incluye las regiones para la iniciación del movimiento, conciencia de la sensibilidad, análisis complejo,

y la expresión de las emociones y el comportamiento. El cerebelo coordina los movimientos voluntarios de los músculos y mantiene el equilibrio. El tronco cerebral controla las funciones involuntarias como la respiración, la regulación del corazón, los biorritmos, neurohormona y secciones de la hormona [20].

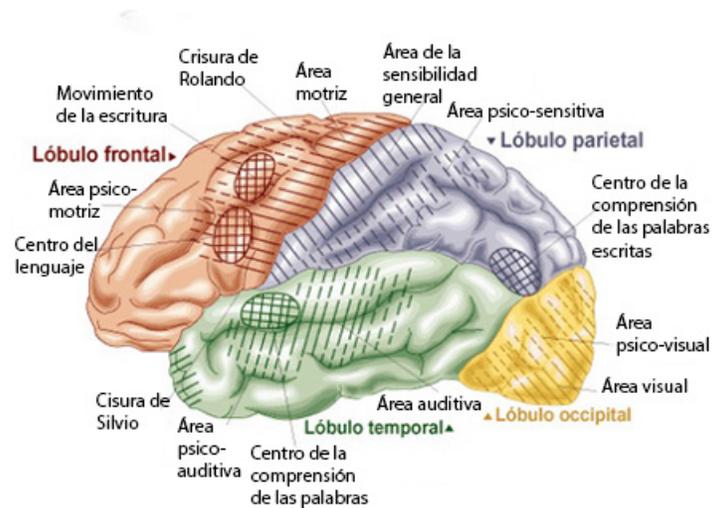


Figura 2.1 Representación esquemática de las partes del cerebro.

2.1.2 Contribuciones del neocórtex al control del movimiento

Se cree que cuatro regiones generales del neocórtex, como se muestra en la figura 2.2, producen la mayoría de los movimientos que decidimos hacer. Si comenzamos por delante y seguimos hacia atrás, estas regiones son la corteza prefrontal que organiza planes de movimiento e informa a la corteza premotora (área 6 de Brodmann) que controla los movimientos coordinados y el modo en que deben ejecutarse los planes, la corteza motora primaria (área 4 de Brodmann) que controla los movimientos simples y las regiones sensitivas posteriores de la corteza [20]. Las regiones sensitivas de la corteza posterior pueden iniciar respuestas rápidas a eventos sensitivos a través de proyecciones que se hacen hacia

la corteza motora primaria y pueden influir en los planes para los movimientos a través de proyecciones hacia la corteza prefrontal.

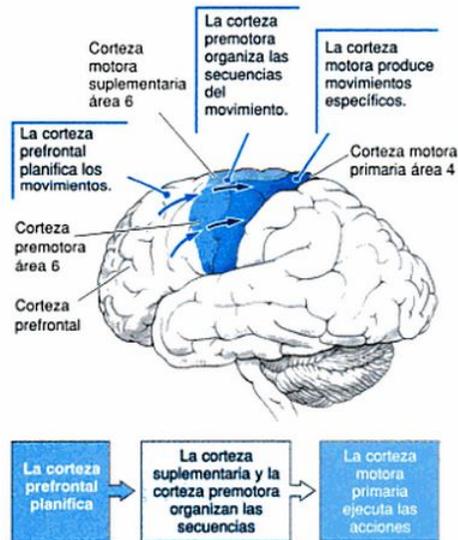


Figura 2.2 Regiones generales del neocórtex. Las áreas numeradas hacen referencia a las áreas de la corteza según el mapa del sistema de Brodmann.

Según la teoría actual se puede considerar que la corteza motora primaria y la corteza premotora contienen un diccionario de movimientos (un lexicón) a partir del cual se seleccionan los más apropiados. Estas regiones reciben instrucciones de la corteza prefrontal, que elabora planes para los movimientos [21].

En la década de 1950, Wilder Penfield utilizó la estimulación eléctrica para hacer un mapa de la corteza de pacientes conscientes que iban a someterse en neurocirugía. Penfield observó que la mayoría de los movimientos inducidos por sus experimentos eran desencadenados por la estimulación de la circunvolución precentral, también conocida como área 4 de Brodmann, región que, debido al papel que desempeña en el movimiento se denomina actualmente, corteza motora primaria. Penfield también obtuvo evidencia de que se puede

producir movimiento estimulando la región dorsal de la corteza premotora. Este autor resumió sus descubrimientos haciendo dibujos de partes del cuerpo para representar las áreas de la corteza motora primaria y la corteza premotora donde la estimulación hacía que esas partes se movieran [22]. El resultado fue un homúnculo (persona pequeña) extendido en la corteza motora, como se ilustra para la corteza motora primaria en la figura 2.3. Como el cuerpo es simétrico, cada hemisferio contiene la representación de una imagen relativamente en espejo de ese homúnculo. La característica más notable del homúnculo motor es la desproporción de sus partes corporales, en comparación con los tamaños relativos del cuerpo propiamente dicho. Estas distorsiones de tamaño se deben a que las partes grandes de la corteza motora regulan las manos, dedos, labios y lengua, dándonos un control motor muy exacto sobre esas partes del cuerpo [21].

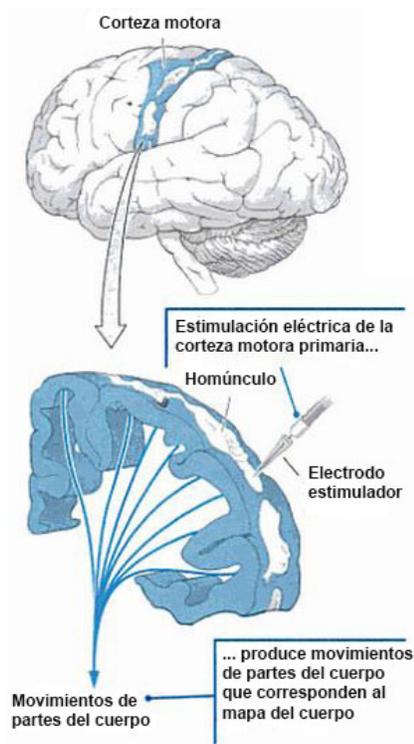


Figura 2.3 Homúnculo de Penfield.

2.1.3 Ritmos cerebrales

En las personas adultas sanas, las amplitudes y frecuencias de las señales EEG cambian de un estado a otro, tales como la vigilia y el sueño. Las características de las ondas también cambian con la edad. Hay cinco grandes ritmos cerebrales que se distinguen por sus diferentes rangos de frecuencia. Estas bandas de frecuencia de baja a alta frecuencia, respectivamente se llaman *alfa* (α), *theta* (θ), *beta* (β), *delta* (δ) y *mu* (μ). Respecto a los ritmos *delta* (0.5-3.5 Hz) y *beta* (13-30 Hz) se encuentran principalmente en la región frontal de la corteza cerebral, el ritmo beta se presenta en un estado de reposo con ojos abiertos y el ritmo delta se presenta en un estado de sueño profundo (adulto) y muy raras veces se pueden experimentar en estado despierto. El ritmo *theta* (4-7 Hz) se genera en la región temporal durante un estado de sueño o en meditación profunda (fantasía, imaginación e inspiración creativa) y el ritmo *alfa* (8-13 Hz) se localiza en la región parietal occipital y se produce en un estado de reposo con ojos cerrados (la amplitud disminuye durante la atención, especialmente visual, y durante el esfuerzo mental). El ritmo *mu* (8-13 Hz) se localiza en regiones centrales del cerebro y se vincula a los sistemas sensorial y motor, sin relación con lo visual ni con la actividad mental. La amplitud de las señales se encuentra en el rango de 0 a 300 mV con un ancho de banda de 0.5 a 100 Hz. La mayor parte del tiempo son asíncronas y no tienen un patrón. La aplicación de patrones se asocia con la existencia de patologías cerebrales o con ciertas ondas de funcionamiento normal, como se muestra en la figura 2.4, [23].

2.1.3.1 Colocación del electrodo convencional

La Federación Internacional de Sociedades de Electroencefalografía y Neurofisiología Clínica ha recomendado el establecimiento de electrodos convencionales (configuración 10-20), constituido por 21 electrodos (con exclusión de los electrodos lóbulo de la oreja), como se muestra en la figura 2.5. A menudo los electrodos del lóbulo de la oreja llamados A1 y A2,

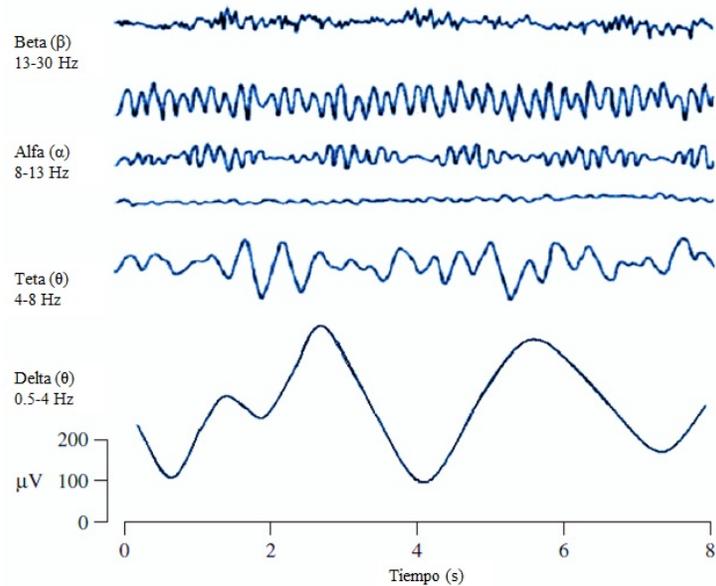


Figura 2.4 Formas de ondas cerebrales.

conectados respectivamente a los lóbulos de las orejas izquierda y derecha, se utilizan como los electrodos de referencia. El sistema 10-20 considera algunas distancias constantes mediante el uso de puntos de referencia anatómicos específicos de la cual se realiza la medición y luego utiliza 10 o 20% de la distancia especificada como el intervalo de electrodo [24].

2.2 Procesamiento digital de señales EEG

El procesamiento de señales digitales se concentra en la representación, transformación y manipulación de señales, y de la información que ellas contienen. Para la interpretación de las señales EEG se requiere el tratamiento de la señal, por lo que se aplica un procesamiento digital previo (filtrado, extracción de características, etc.) seguido por un sistema de reconocimiento de patrones que produzca una representación simbólica [25].

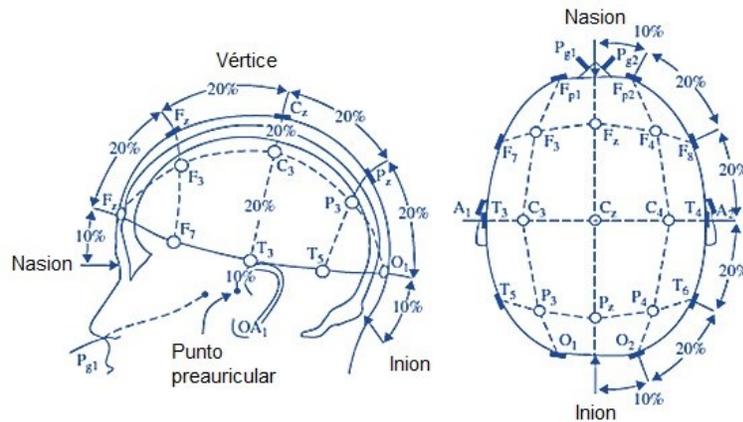


Figura 2.5 Posición 10-20 de los electrodos de EEG convencionales para la colocación de 21 electrodos.

2.2.1 Cancelación de artefactos

A menudo es difícil de comprender y detectar los ritmos cerebrales de los electroencefalogramas del cuero cabelludo, incluso con ojos cerrados debido a que son muy susceptibles de ruido y artefactos. Los principales artefactos se pueden dividir en artefactos relacionados con el paciente (fisiológica), como el parpadeo y movimiento de ojos, y del sistema que son las interferencias 60 Hz de la fuente de alimentación, la fluctuación de impedancia, defectos de cable, ruido eléctrico de los componentes electrónicos, y las impedancias desbalanceadas de los electrodos. La aplicación de filtros permite disminuir el ruido y las interferencias sin producir ningún cambio o distorsión de las señales [24].

En el procesamiento de señales, el ventaneo es una función matemática usada con frecuencia en el análisis y el procesamiento de señales para evitar las discontinuidades al principio y al final de los bloques analizados, también suele emplearse cuando el análisis se centra en una señal de longitud voluntariamente limitada [26].

2.2.2 Extracción de características en el dominio del tiempo y frecuencia

2.2.2.1 Transformada wavelet discreta

A partir de una señal electroencefalográfica se pueden obtener los ritmos de la señal y la energía contenida en cada uno de estos ritmos [27]. La transformada wavelet permite obtener la representación en diferentes rangos de frecuencia de una señal [28], y la relación entre los rangos obtenidos y los ritmos de la señal se realiza aplicando los siguientes principios [29, 30]:

- cálculo de los coeficientes wavelet, consiste en aplicar la transformada wavelet discreta (por sus siglas en inglés *Discrete Wavelet Transform* DWT) en varios niveles de descomposición. Cada nivel de descomposición de la transformada wavelet divide el ancho de banda inicial en dos anchos de banda, uno correspondiente a la parte alta y otro correspondiente a la parte baja.
- selección de los coeficientes: una vez calculados los coeficientes de la señal para diferentes niveles de descomposición, se debe aplicar este proceso, el cual consiste en seleccionar solamente los coeficientes que superen un ancho de banda determinado para considerarlos en la reconstrucción de la señal, mientras que los coeficientes por debajo de este umbral se eliminan.
- reconstrucción de la señal a partir de los coeficientes seleccionados: este proceso es inverso a la descomposición de la señal y comprende dos pasos: sobremuestreo y filtrado de los coeficientes utilizando filtros pasa bajas y pasa altas de reconstrucción. La reconstrucción se realiza con todos los coeficientes de los niveles de descomposición de salida de los filtros pasa altas y coeficientes del último nivel de salida del filtro pasa bajas.

2.2.2.2 Transformada rápida de Fourier

La transformada rápida de Fourier (por sus siglas en inglés *Fast Fourier Transform* FFT), es un algoritmo eficiente que permite ahorrar cálculos y evaluar de manera rápida la Transformada Discreta y su inversa.

La transformada rápida de Fourier FFT es un algoritmo que reduce el tiempo de cálculo de n^2 pasos a $n \cdot \log_2(n)$. El único requisito, es que el número de puntos (N) en la serie tiene que ser de una potencia de 2 (2^n puntos). El algoritmo de la FFT, se define en la ecuación 2.1.

$$X(k) = \sum_{j=1}^N \exp\left(-\frac{2\pi i}{N}\right)_N^{(j-1)(k-1)}, \text{ para } k = 0, 1, \dots, N - 1 \quad (2.1)$$

La transformada rápida inversa se puede calcular con al menos $n \cdot \log_2(n)$ operaciones y está definida en la ecuación 2.2, [12, 31].

$$x(j) = \frac{1}{N} \sum_{k=1}^N x(k) \exp\left(-\frac{2\pi i}{N}\right)_N^{-(j-1)(k-1)}, \text{ para } k = 0, 1, \dots, N - 1 \quad (2.2)$$

2.2.3 Extracción de características espaciales

La contaminación de las señales de EEG con una variedad de diferentes artefactos como EOG (por sus siglas en inglés *electrooculography* EOG) o EMG es una cuestión importante en el análisis de datos de EEG. La resolución espacial de señales de EEG se ve comprometida debido al volumen de conducción a través del cuero cabelludo, el cráneo y otras capas del cerebro. En el campo de la investigación BCI, estos factores influyen en la precisión de la clasificación de la actividad relacionada con la tarea. Para hacer frente a estos problemas, los datos del EEG multicanales, son tratados con un filtro espacial que produce una combinación lineal de los canales de EEG optimizando las características extraídas de dicha combinación.

Las características se extraen de la combinación lineal de los canales mediante el análisis de componentes principales (por sus siglas en inglés *Principal Component Analysis* PCA) [33, 34].

2.2.3.1 Análisis de componentes principales

El PCA realiza una transformación lineal, encontrando un nuevo sistema de coordenadas a partir del conjunto original de datos. En este nuevo sistema de coordenadas la varianza de mayor valor del conjunto de datos es capturada por el primer eje, llamado primer componente principal (por sus siglas en inglés *Principal Component* PC); la segunda mayor varianza es capturada por el segundo eje, y así sucesivamente. Para construir esta transformación lineal se debe construir primero la matriz de covarianza o la matriz de coeficientes de correlación [9]. Este criterio indica que los valores propios asociados a cada PC y superiores a uno se incluirán en el número de PC's que capturen la mayor variabilidad de los datos con la menor pérdida de información [10].

2.2.4 Redes neuronales artificiales

Las redes neuronales (por sus siglas en inglés *Artificial Neuronal Networks* ANN) se han hecho muy populares debido a la facilidad en su uso e implementación y la habilidad para aproximar cualquier función matemática. Las ANN, con su marcada habilidad para obtener resultados de datos complicados e imprecisos, pueden utilizarse para extraer patrones y detectar tramas que son muy difíciles de apreciar por humanos u otras técnicas computacionales. Según Skapura la definición de una ANN es la siguiente: "Las redes neuronales son conjuntos de elementos de cálculo simples, usualmente adaptativos, interconectados masivamente en paralelo y con una organización jerárquica que le permite interactuar con algún sistema del mismo modo que lo hace el sistema nervioso biológico". En general, se puede encontrar que una ANN se suele caracterizar por tres partes fundamentales: la topología de la red, la

regla de aprendizaje y el tipo de entrenamiento [36]. Las ANN, gracias al masivo paralelismo de su estructura, gozan de una serie de ventajas:

- aprendizaje adaptativo, capacidad de aprender a realizar tareas basadas en un entrenamiento o una experiencia inicial
- autoorganización, una red neuronal puede crear su propia organización o representación de la información que recibe durante la etapa de aprendizaje
- tolerancia a fallos, gracias a poseer la información distribuida o vía información redundantes de su estructura; sin embargo, algunas capacidades de la red se pueden retener, incluso sufriendo daños considerables
- capacidad de generalización, ante la entrada de datos nuevos es capaz de producir resultados coherentes de acuerdo con la naturaleza del problema para el cual han sido entrenadas
- operación en tiempo real, el cómputo neuronal puede realizarse en paralelo, bien vía software o mediante máquinas especiales para obtener esta ventaja (hardware masivamente paralelo).

Capítulo 3

Antecedentes y estado del arte

Las publicaciones existentes demuestran que, conectando electrodos de forma no invasiva sobre el cuero cabelludo en la corteza motora, es posible registrar señales EEG de movimientos de las extremidades superiores y además que es posible registrar en el EEG un estado de planeación antes de la ejecución de los movimientos [57, 14]. La señal EEG, requiere de una etapa de adquisición y una de procesamiento, para la identificación de los patrones que determinan el tipo de movimiento. En [38] se ha demostrado que la velocidad con que el sujeto mueve la extremidad superior, también es registrada durante la adquisición de la señal EEG, por lo que para este trabajo se definió un protocolo de adquisición que considera este factor. El procesamiento de la señal se divide en cuatro etapas que actúan de forma secuencial:

1. Cancelación de artefactos. Las señales EEG con frecuencia presentan artefactos debido a otros tipos de actividades eléctricas producto del movimiento ocular y muscular o el producido por la línea eléctrica, para hacer frente a este problema los estudios realizados han hecho uso de los filtros Notch y filtros pasa banda [39, 40, 41, 42].
2. Extracción de características en el dominio de la frecuencia. Existen técnicas para traducir la señal cerebral de entrada en un conjunto de características espectrales, como

los modelos autorregresivos [43] adaptativos, el método de Welch [44], la FFT [45] y la más usada transformada wavelet [46, 47].

3. Extracción de características espaciales. Un método que puede ser utilizado en esta etapa, además de la selección de electrodos, consiste en aplicar algoritmos de filtrado espacial; por ejemplo, el filtro laplaciano, el algoritmo de patrones espaciales, el análisis de componentes independientes (ICA) y PCA [48, 49].
4. Clasificación de los patrones de movimiento. Para esta etapa existen métodos, como ecuaciones lineales, análisis de discriminante lineal (LDA) [47], análisis de discriminante de Fisher (FDA) [50], máquinas de soporte vectorial y el más usado redes neuronales [51, 52].

Como ya se mencionó en la etapa número dos, las herramientas como lo es la DWT y la FFT se han implementado en la clasificación de señales EEG de forma exitosa, por lo que para este trabajo se hará uso de ellas en conjunto con PCA y ANN para la identificación de patrones de movimiento.

Capítulo 4

Desarrollo

4.1 Solución propuesta

Desarrollar un sistema de adquisición para la obtención de registros EEG durante la ejecución de movimientos reales de las extremidades superiores siguiendo un protocolo definido, descrito en la sección 4.2.1. Este sistema consta de la tarjeta de adquisición ADS1299EEG-FE de Texas Instruments para la obtención de registros EEG. Los registros EEG deberán ser almacenados en archivos Excel 2015 mediante la plataforma de Labview 2012 e importados a la de MATLAB R2015a para continuar con su procesamiento. Debido a que la señal EEG es una señal no estacionaria, no lineal, de una magnitud muy pequeña y cuyas propiedades varían en función del tiempo analizado, se aplicará un procesamiento digital conformado por la cancelación de artefactos por medio de filtros digitales, la obtención de características en frecuencia, para acotar las frecuencias en función de la banda de frecuencias de interés, ritmo *mu*, con la FFT y la DWT, la obtención de características espaciales con el PCA y la clasificación con ANN. En la figura 4.1 se muestra un diagrama a bloques general del sistema a desarrollar.

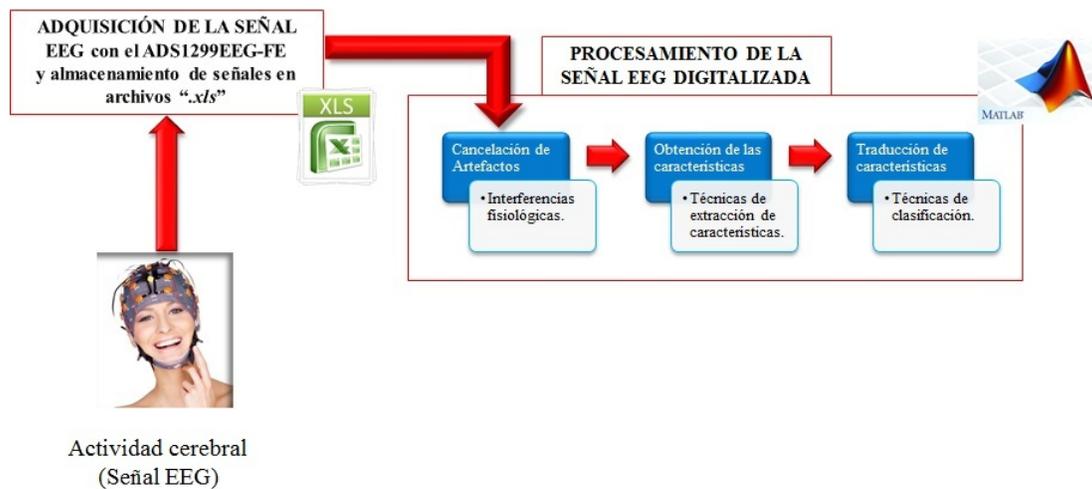


Figura 4.1 Diagrama a bloques del sistema de adquisición y clasificación de señales electroencefalográficas para la identificación de movimientos reales de las extremidades superiores.

4.2 Adquisición de las señales EEG

4.2.1 Protocolo para la adquisición de las señales EEG

El objetivo del proceso de selección de los sujetos de prueba es determinar si se encuentran en condiciones adecuadas para poder registrar su EEG mientras realiza diversas secuencias de movimiento. Para la selección de sujetos de prueba, a cada uno de los candidatos se les dio a llenar un formato (véase el apéndice A.5) considerando los siguientes criterios:

- **Criterios de inclusión.** Se consideraron a los sujetos de prueba que se encuentran entre los 20 y 30 años de edad capaces de comprender y respetar las instrucciones orales y visuales, indicadas en el procedimiento. Además, estos sujetos de prueba se deben evaluar como candidatos si cuentan con antecedentes patológicos relevantes y/o sin antecedentes de traumatismos craneoencefálicos.

- **Criterios de Exclusión.** No se incluyeron al protocolo personas con antecedentes de traumatismos craneoencefálicos, información patológica relevante, como alguna enfermedad neurológica, psiquiátrica y/o tóxico-metabólica. Además, se excluyeron a las personas que no respetaron las indicaciones previas al registro EEG. Los registros EEG que no se concluyeron por falta del cumplimiento en relación con el entorno o por alguna falla técnica también fueron excluidos.

Las indicaciones para los sujetos de prueba que realizaron el registro EEG fueron: cabello limpio y seco, sin productos capilares, sin joyería, tomar el medicamento habitual con normalidad en su caso, realizar comidas habituales, haber dormido mínimo seis horas el día anterior al registro y no haber ingerido bebidas alcohólicas una noche anterior al registro EEG. A cada sujeto de prueba se le explicó de forma detallada en qué consistía esta investigación y bajo su consentimiento se procedió a la firma del informe (véase el apéndice A.5). Debido a que al realizar las secuencias de movimiento el sujeto necesita concentración se consideró un ambiente controlado, libre de ruido visual y auditivo, limpio, y un asiento cómodo. Debido a que al realizar las secuencias de movimiento el sujeto necesita concentración se consideró un ambiente controlado, libre de ruido visual y auditivo, limpio, y un asiento cómodo.

El sistema de adquisición de las señales EEG utilizadas para este proyecto, fue diseñado con la implementación de una gorra Electro-Cap mediano con un sistema internacional 10-20, un electrodo de oreja, el PDK ADS1299EEG-FE, una laptop con el software (LabView y MATLAB) necesario para la adquisición y el análisis de las señales EEG, un monitor de computadora, unas bocinas y una video cámara , figura 4.2.

Para la adquisición de la señal EEG se conectaron 8 electrodos al ADS1299EEG-FE. Los 8 electrodos se conectaron sobre el cuero cabelludo de acuerdo al sistema internacional 10-20 y la referencia se colocó en el lóbulo derecho, como se muestra en la figura 4.3.



Figura 4.2 Sistema de adquisición de la señal EEG.

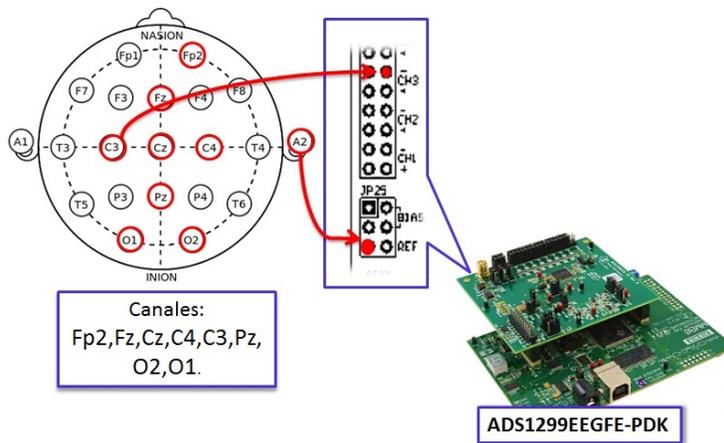


Figura 4.3 Conexiones del sistema de adquisición de la señal EEG.

El firmware del PDK ADS1299EEG-FE fue modificado con el fin de poder usar marcadores durante la adquisición para poder identificar el término e inicio de cada movimiento. Estos marcadores de tiempo (segundos) estuvieron sincronizados con el almacenamiento de las señales EEG en archivos “.xls” con el fin de que fuera más accesible, organizada y certera

la identificación de patrones de movimiento de las extremidades superiores. Además de modificarse de tal forma que se fuera generando una base de datos con los archivos “.xls” con los movimientos ejecutados por los sujetos de prueba y los marcadores de tiempos (en segundos) generados durante la adquisición en archivos “.mat”.

Durante la adquisición el sistema se mantuvo aislado al conectar la tarjeta ADS1299EEG-FE a cuatro baterías doble A de 1.5 V cada una, la laptop se mantuvo con su batería interna y lo único que se conectó al toma corriente fue el monitor empleado para la visualización de las secuencias de movimiento.

Para la adquisición de la señal EEG se le pidió a cada uno de los sujetos presentarse después de las 8 y antes de las 13 horas del día para evitar que el sujeto de prueba perdiera la concentración por factores como el hambre y el sueño. A cada sujeto de prueba se le pidió sentarse en una silla con descansa brazos, en posición erguida y con los brazos a los costados, frente a un monitor en el cual se muestra un dibujo animado que sirve como guía durante la ejecución de las secuencias de movimiento, figura 4.4.

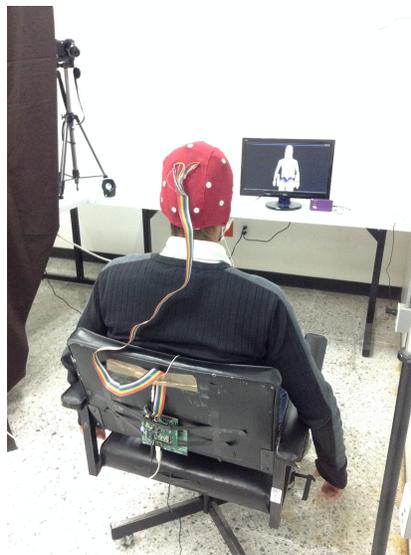


Figura 4.4 Posición del sujeto de prueba durante la adquisición de la señales EEG

El procedimiento del sistema es conectar los electrodos de la gorra al canal correspondiente de la tarjeta ADS1299EEG-FE y el electrodo de oreja a la referencia, conectar la tarjeta ADS1299EEG-FE, las bocinas y el monitor a la laptop, hacer un chequeo general del sistema, colocarle la gorra y el electrodo de oreja a la persona (a cada electrodo empleado en las pruebas se le suministro gel conductor por medio de una jeringa con aguja sin punta), el sujeto de prueba debe realizar un entrenamiento previo que consta de una sincronización en tiempo del sujeto con la animación, al realizar las secuencias de movimiento, una vez entrenado el sujeto se comienza con la adquisición de la señal.

Cada secuencia de movimiento inicia con un beep agudo que ayuda a que el sujeto identifique el inicio de la secuencia, un estado de reposo de 15 segundos para dar tiempo a que el sistema se estabilice y la persona se relaje, una onda auditiva (voz) que indica los movimientos a ejecutar, un beep grave que indica el inicio del movimiento 1 con una duración de 10 segundos, un beep grave que indica el término del movimiento 1 y el inicio del movimiento 2 de una duración de 10 segundos, un beep grave que le indica al sujeto que puede volver a su estado de reposo y un beep agudo que indica el término de la secuencia, figura 4.5. Cada secuencia de movimiento fue grabada con una video cámara y monitoreada por una persona dedicada a analizar el momento de la ejecución de cada movimiento.

Todas las secuencias de movimiento primero se ejecutaron con los ojos abiertos y después con los ojos cerrados, esto con el fin de analizar sí era factible realizar la clasificación de movimientos reales con ojos abiertos a pesar de los artefactos generados por el parpadeo que se presentan con normalidad durante las pruebas. La base de datos se generó con las secuencias que fueron ejecutadas por cada uno de los sujetos, Tabla 4.1:

Tomando como referencia los criterios de selección mencionados al inicio de esta sección y de acuerdo a la orientación recibida en el Instituto Nacional de Rehabilitación, se estableció un nivel de eliminación para cada uno de los 24 sujetos, el cual define cuales sujetos serán seleccionados para el procesamiento y cuáles serán eliminados. Los parámetros para obtener

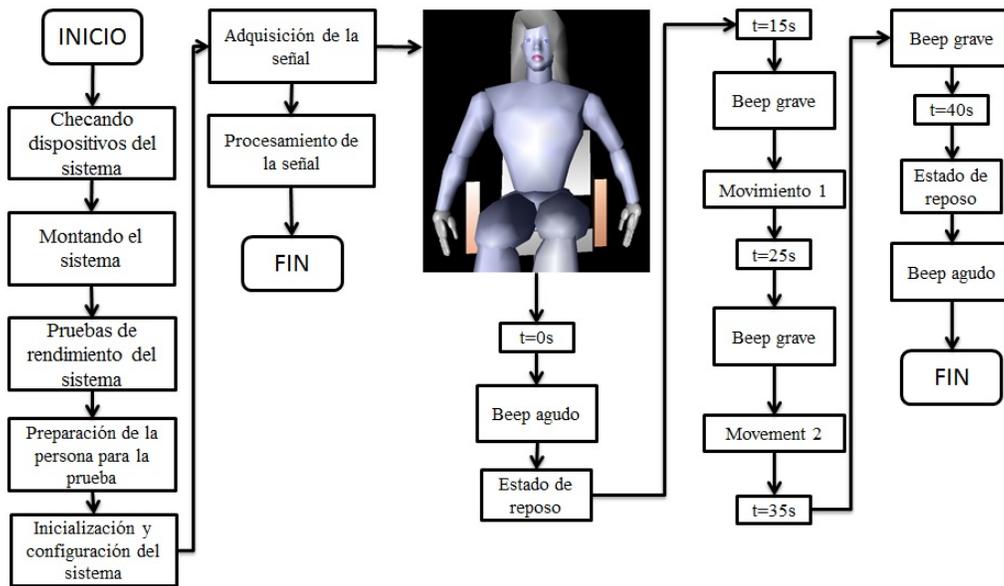


Figura 4.5 Diagrama de flujo del sistema de adquisición de la señal EEG.

este nivel de eliminación son: enfermedades (p1), sueño (p2), irritabilidad (p3), estrés (p4), operación cerebral (p5), ajuste de gorra con electrodos (p6), rendimiento del sistema (p7), visibilidad del sujeto (p8) y condiciones del ambiente para realizar las pruebas (p9). Cada parámetro fue evaluado en una escala del 0 al 3, siendo 0 el más favorable y 3 el menos favorable para la selección del sujeto. El nivel de eliminación (NE) se obtuvo haciendo una sumatoria de todos los parámetros, ecuación 4.1.

$$NE = p1 + p2 + p3 + p4 + p5 + p6 + p7 + p8 + p8 + p9 \quad (4.1)$$

Los sujetos que presentan un nivel de eliminación menor a 6, son los sujetos seleccionados y los que presentan un nivel de eliminación que va de 6 en adelante corresponden a los sujetos discriminados en la etapa de procesamiento. Se definió de esta forma, debido a que por arriba del nivel de eliminación 6, los sujetos presentan un mayor número de parámetros

Tabla 4.1 Secuencias de movimiento realizadas durante la adquisición de las señales EEG.

No.	Estado 1	Movimiento 1	Movimiento 2	Estado 2
1	Reposo	Flexión extremidad superior derecha	Extensión extremidad superior derecha	Reposo
2	Reposo	Flexión extremidad superior izquierda	Extensión extremidad superior izquierda	Reposo
3	Reposo	Flexión codo derecho	Extensión codo derecho	Reposo
4	Reposo	Flexión codo izquierdo	Extensión codo izquierdo	Reposo
5	Reposo	Pronación mano derecha	Supinación mano derecha	Reposo
6	Reposo	Pronación mano izquierda	Supinación mano izquierda	Reposo
7	Reposo	Cierre mano derecha	Apertura mano derecha	Reposo
8	Reposo	Cierre mano izquierda	Apertura mano izquierda	Reposo

o bien un parámetro significativo para la eliminación. En la figura 4.6 se muestra que, de los 24 registros de los sujetos de prueba, 16 cumplieron los criterios de inclusión para el procesamiento de las señales EEG.

4.3 Procesamiento de las señales EEG

Al finalizar la adquisición de las señales EEG durante 40 segundos para cada secuencia de movimiento y con una frecuencia de muestreo de 1.4 kHz, se procedió a realizar el procesamiento off-line de las señales EEG.

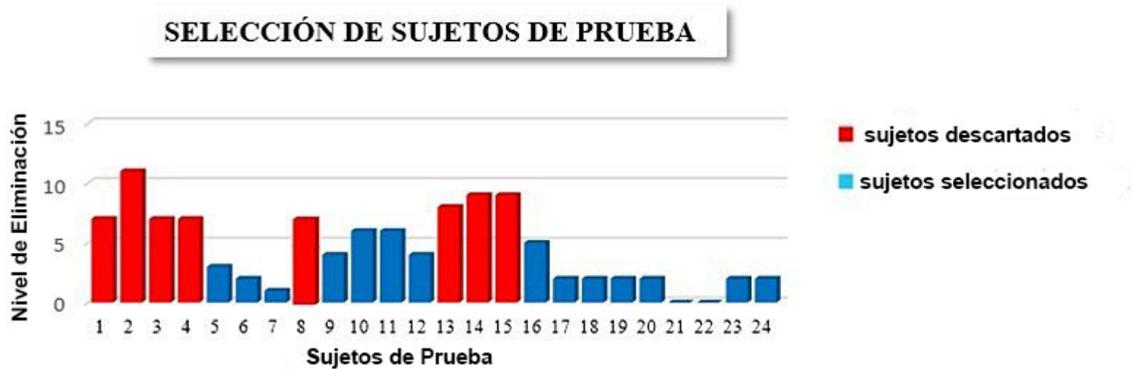


Figura 4.6 Selección de sujetos de prueba con respecto a sus niveles de eliminación.

4.3.1 Pre-procesamiento

Al finalizar la adquisición de las señales EEG durante 40 segundos para cada secuencia de movimiento y con una frecuencia de muestreo de 1.4 kHz, se procedió a realizar el procesamiento off-line de las señales EEG.

4.3.1.1 Filtros

Se aplicó un filtro pasa bajas de décimo orden a 45 Hz debido a que el ancho de banda correspondiente a la actividad eléctrica producto del movimiento ocular se encuentra por arriba de los 50Hz, [52]. Se aplicó un filtro Notch a 60 Hz para eliminar el ruido provocado por elementos externos al paciente, como lo es el producido por la línea eléctrica. Estos filtros fueron aplicados directamente desde el software del kit de desarrollo AD1299EEG-FE. Con el fin de eliminar la componente de corriente directa (por sus siglas en inglés *Direct Current* CD), a cada señal EEG se le resta el promedio de ella misma, esto se realizó siguiendo la ecuación 4.2, figura 4.7 [53].

$$\mu = \frac{1}{N} \sum_{i=1}^N A_i$$

μ : promedio de la señal.

N : número de muestras del EEG (2000 muestras).

A_i = señal EEG.

(4.2)

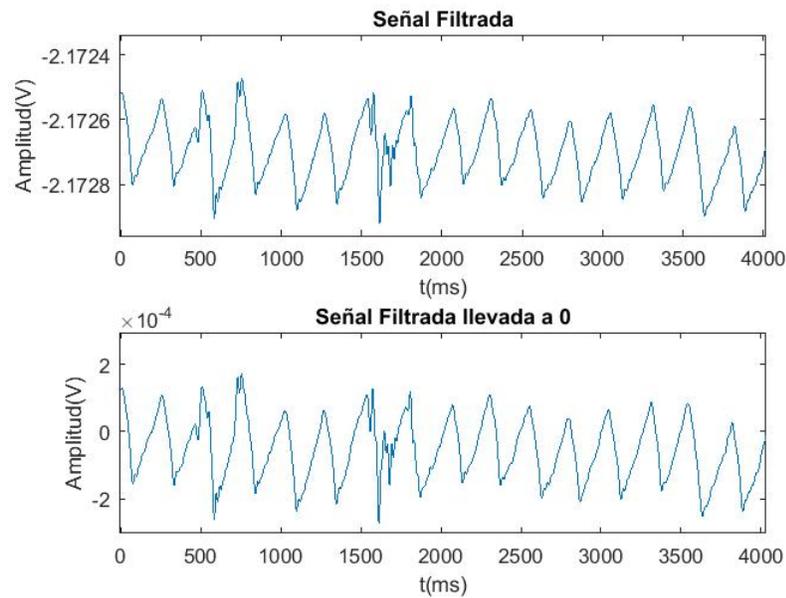


Figura 4.7 Acercamiento de la señal EEG llevada a 0 - ojos abiertos, canal 2.

4.3.1.2 Ventaneo

La segmentación de la señal filtrada se realizó tomando como referencia los marcadores de tiempo de inicio y fin de cada ejecución de movimiento del sujeto de prueba por medio de un algoritmo generado en MATLAB R2015a, figura 4.8.

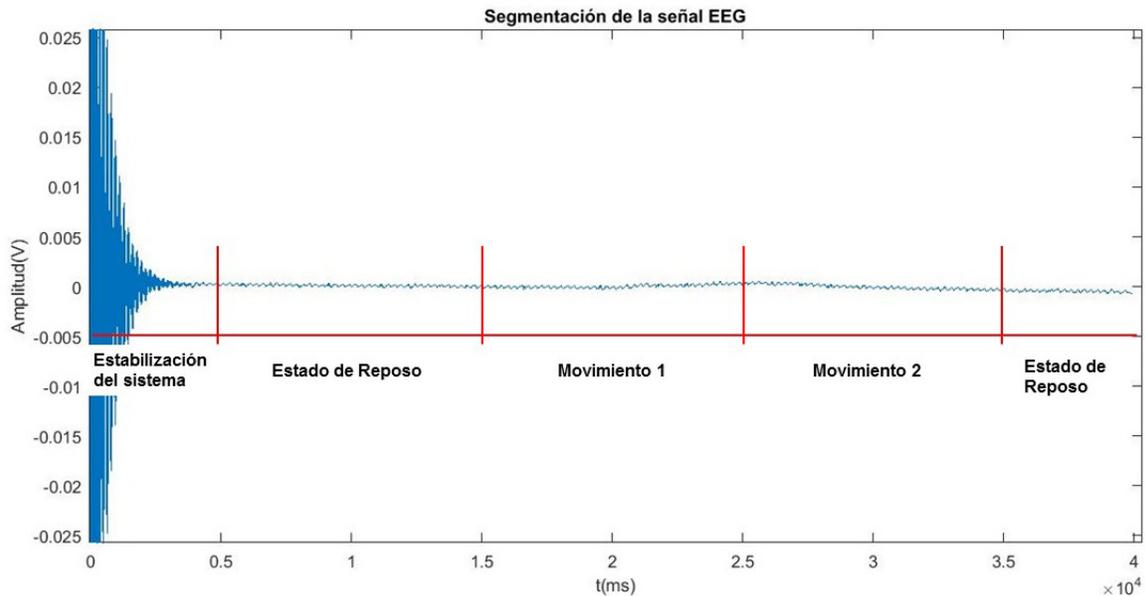


Figura 4.8 Marcadores de tiempo en señal EEG filtrada de la secuencia 1 de movimientos con ojos abiertos.

Después de haber identificado las muestras de la señal correspondiente a los marcadores de tiempo se procedió a realizar la segmentación para tomar 3 segmentos de 2 segundos para el estado de reposo y 3 segmentos de 2 segundos para cada ejecución del movimiento. Se evitaron los primeros y últimos 2 segundos de cada ejecución de movimiento y de reposo debido a que en [54] mencionan que existe un periodo de la planeación del movimiento antes de ejecutarlo y/o imaginarlo. Los segmentos que se obtuvieron de cada señal de 40 segundos y que se analizarán son:

- estado de reposo 1-segmento 1: 3 a 5 segundos
- estado de reposo 1-segmento 2: 5 a 7 segundos
- estado de reposo 1-segmento 3: 7 a 9 segundos

- movimiento 1-segmento 1: 18 a 20 segundos
- movimiento 1-segmento 2: 20 a 22 segundos
- movimiento 1-segmento 3: 22 a 24 segundos
- movimiento 2-segmento 1: 28 a 30 segundos
- movimiento 2-segmento 2: 30 a 32 segundos
- movimiento 2-segmento 3: 32 a 34 segundos
- estado de reposo 2-segmento 1: de 37 a 39 segundos

El ventaneo se utiliza con el fin de evitar que las discontinuidades introducidas al analizar sólo una fracción de la señal o al introducir muestras con un valor cero que introduzcan componentes de alta frecuencia en el espectro, que son más bien artefacto de las discontinuidades introducidas y no pertenecen a la señal. En la figura 4.9 se muestra la aplicación de las ventanas (hamming, hanning, blackman, chebwin, kaiser y barthannwin) a la señal EEG correspondiente al movimiento 1, canal 2, persona 1 con ojos abiertos.

4.3.2 Extracción de características

Con el objeto de encontrar la técnica de extracción de características predominantes para la identificación de patrones de movimiento en las señales EEG, se realizó un análisis en el dominio del tiempo mediante la FFT y DWT.

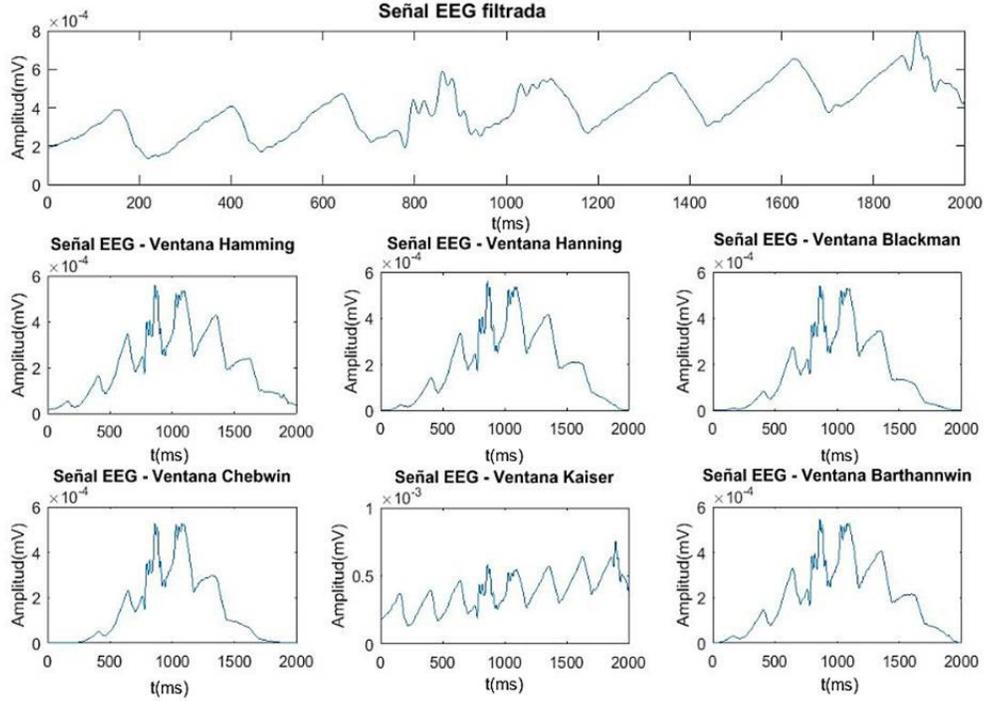


Figura 4.9 Ventaneo de la señal EEG.

4.3.2.1 Transformada rápida de Fourier

Para calcular el contenido en frecuencia de la señal EEG muestreada se calculó la FFT por medio de la ecuación 4.3:

$$X(j) = \frac{1}{N} \sum_{k=0}^{N-1} x(k) \cdot e^{-i2\pi \frac{jk}{N}}$$

donde, $j = 0, 1, \dots, N - 1$ (4.3)

$x(k)$: muestras de la señal.

N : número de muestras del EEG (2000 muestras).

Con la transformada $X(j)$ se obtiene un estimador de la densidad espectral, conocido como periodograma, y que está dado por:

$$\hat{S}(j) = \frac{1}{N}[X(j)]^2$$

donde, $j = 0, 1, \dots, N - 1$ (4.4)

$\hat{S}(j)$: periodograma del EEG $x(k)$

El estimador 4.4 presenta un sesgo que disminuye al incrementar el número de muestras N y una varianza proporcional al cuadrado del espectro real. Para mejorar la estimación se utiliza el periodograma modificado que consiste en un promedio de periodogramas:

$$\hat{S}'_i(n) = \frac{1}{L} \sum_{i=1}^L \hat{S}_i(n)$$

donde, $n = 0, 1, \dots, M - 1$ (4.5)

$\hat{S}'_i(n)$: periodograma para cada uno de los L segmentos en que se dividió el registro.

El EEG original de longitud $N= 2000$ se divide en L segmentos de longitud M cada uno ($N=L.M.$) [54, 55]. Para cada segmento se obtiene el periodograma ec. 4.4 y posteriormente se promedian los L periodogramas como señala la ec. 4.5.

En la figura 4.10 se muestra el periodograma resultante de la señal EEG (ventana kaiser, debido a que en la tabla 4.2 muestra el mayor porcentaje de clasificación con respecto a las demás ventanas, persona 1, canal C3, movimiento flexión extensión codo derecho con ojos

abiertos) en el que se puede observar que existe energía sobre la banda de frecuencia de 8 Hz-13 Hz correspondiente al ritmo *mu*, lo cual demuestra que es posible encontrar patrones de movimiento mediante la señales EEG aplicando transformada rápida de Fourier.

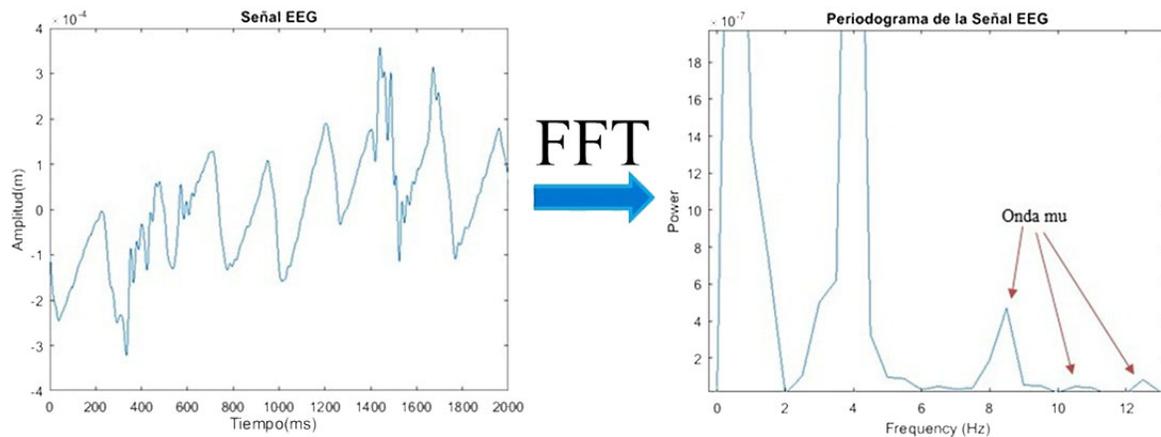


Figura 4.10 Transformada rápida de Fourier aplicada a la señal EEG.

4.3.2.2 Transformada wavelet discreta

La aplicación de la DWT, comprende tres partes: cálculo de los coeficientes wavelet, selección de coeficientes y reconstrucción de la señal a partir de los coeficientes seleccionados [56], esto con el fin de identificar si no hubo pérdida de información durante la transformación.

Cálculo de coeficientes wavelet.

En el presente trabajo se aplica la DWT con 8 niveles de descomposición, utilizando como wavelet madre una Daubechies de tercer orden (db3), esto debido a sus propiedades de soporte compacto (duración finita), ortogonalidad y asimetría [57, 58, 59, 60]. El número

máximo de niveles de descomposición se basa en la frecuencia de muestreo utilizada en el proceso de digitalización de la señal EEG (1.024 kHz). A cada nivel de descomposición le corresponde un vector mediante la convolución de la señal con la carga del filtro paso bajo (LPF) para los coeficientes de aproximación y otro con el filtro paso alto (HPF) para los coeficientes de detalle, obteniendo así una disminución de la resolución para cada una de las ventanas en cada uno de los canales, personas y movimientos. La figura 4.11 muestra las frecuencias correspondientes a cada uno de los niveles de descomposición, tomando como referencia la señal EEG acondicionada con la ventana kaiser, de la persona 1, canal C3, movimiento flexión extensión de la extremidad superior derecha con ojos abiertos.

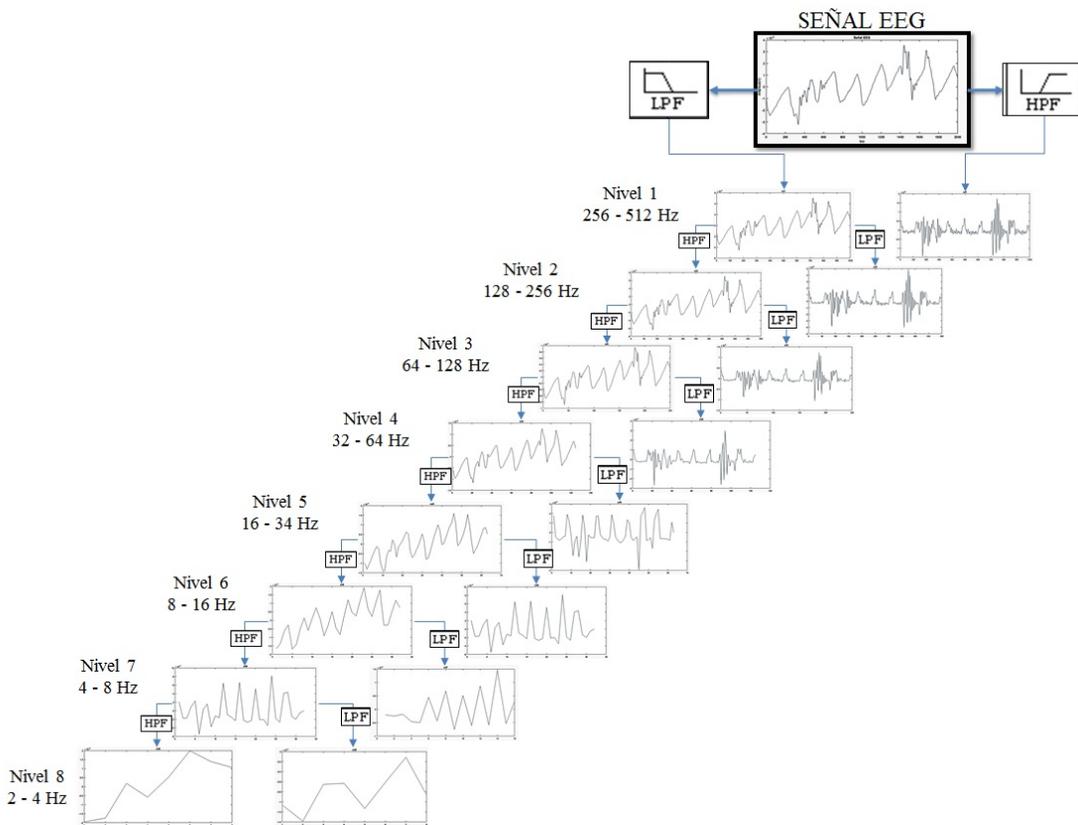


Figura 4.11 Niveles de descomposición de la DWT con sus respectivas frecuencias.

Selección de coeficientes

Para una correcta elección de los coeficientes wavelet se consideró la banda de frecuencia μ que va de 8 a 13 Hz, ya que se presenta en las señales EEG cuando se realiza un movimiento de las extremidades del cuerpo. El nivel de descomposición 6 abarca las frecuencias de 8 a 16 Hz, por lo que los coeficientes del nivel de descomposición 6 son los correctos para la reconstrucción de la señal EEG.

Reconstrucción de la señal EEG a partir de los coeficientes seleccionados.

La transformación y reconstrucción de la señal EEG se realizó para las 16 personas y los 2000 datos por cada ejecución de movimiento, con sus respectivas mediciones. La secuencia de la señal original $c_0(n)$ se reconstruyó a partir de las secuencias de coeficientes de aproximación $c_i(n)$ y de los coeficientes wavelet $d_i(n)$ con $0 < i < M$, donde $i=M$ es la menor resolución en la descomposición [61].

La aproximación discreta $c_{i-1}(n)$ en el nivel de descomposición 6 se obtuvo con la suma de dos convoluciones, una entre la aproximación discreta $c_i(n)$ y el filtro pasa bajas $p(n)$ y otra entre los coeficientes wavelet $d_i(n)$ y el filtro pasa altas $q(n)$, ec. 5.1.

$$\begin{aligned} c_{i-1}(n) &= \langle P_{i-1}f, \phi_{i-1,n} \rangle \\ &= \sum_k c_i(k) \langle \phi_{i,k}, \phi_{i-1,n} \rangle + \sum_k d_i(k) \langle \psi_{i,k}, \phi_{i-1,n} \rangle \\ &= 2^{-\frac{1}{2}} \sum_k c_i(k) p(n-2k) + 2^{-\frac{1}{2}} \sum_k d_i(k) q(n-2k) \end{aligned} \quad (4.6)$$

Con el fin de verificar la reconstrucción de la señal original, se calculó el error con la distancia euclidiana de la señal original P y la señal reconstruida Q, siguiendo la ecuación 4.7, [62].

$$d_E(P, Q) = \sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2} = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (4.7)$$

4.3.2.3 Análisis de componentes principales

Los coeficientes de aproximación 6, resultado de la DWT de la señal EEG, se ingresaron al PCA. Este PCA se realizó en base a la matriz de varianza-covarianza de los datos, obteniendo así un nuevo sistema de coordenadas con respecto a los eigenvectores, PC's [63].

4.3.3 Clasificación de patrones de movimiento

Para evitar redundancia en la información, se procedió a normalizar los datos obtenidos en la etapa de filtrado y extracción de características de la señal, en base a su valor máximo y mínimo. La normalización, en su forma estándar, se define en la ecuación 4.8, [69]:

$$y = \frac{(x-x_{min})(d_2-d_1)}{x_{max}-x_{min}} + d_1$$

donde,

x : valor a normalizar (4.8)

(x_{max}, x_{min}) : rango del valor de x

(d_1, d_2) : rango al que será reducido el valor x

4.3.3.1 Red neuronal artificial del tipo perceptrón multicapa con retropropagación

Para clasificar los 16 movimientos con una ANN del tipo Perceptrón Multicapa con Retropropagación, se utilizaron los datos normalizados. La regresión lineal, resultado de la red neuronal, se calculó siguiendo la ecuación 4.9.

$$Y = mx + b \tag{4.9}$$

Para calcular b y m se utilizó el principio de mínimos cuadrados obteniendo las ecuaciones 4.10 y 4.11, donde x son los objetivos e y son las salidas de la red neuronal [29].

$$m = \frac{n \sum x_i y_i - \sum x_i \sum y_i}{n \sum x_i^2 - (\sum x_i)^2}, \tag{4.10}$$

$$b = \frac{\sum y_i \sum x_i^2 - \sum x_i \sum x_i y_i}{n \sum x_i^2 - (\sum x_i)^2}. \tag{4.11}$$

Los porcentajes de exactitud de la clasificación, se obtuvieron contando los datos coincidentes entre el vector de objetivos y de salidas de la red neuronal, considerando el número de datos coincidentes se divide entre el total de datos del vector de objetivos. El resultado de esta operación es el porcentaje de exactitud de clasificación.

El diseño del código para la clasificación de movimientos implementando la red neuronal se realizó siguiendo el diagrama de flujo de la figura 4.12 En el diagrama de flujo, la tarea a resolver es identificar los patrones movimientos reales de las extremidades superiores en las señales EEG, los parámetros a combinar son las épocas, la tasa de aprendizaje y el error; la arquitectura de la red se refiere al número de neuronas en la capa de entrada, la oculta y la de salida, la información de entrada a la red neuronal son las características obtenidas de las técnicas empleadas y los datos de salida de la red se representan con el porcentaje de exactitud que logró la red neuronal con los parámetros seleccionados, cabe mencionar que este procedimiento se realizó continuamente hasta obtener un porcentaje de clasificación mayor al 80%.

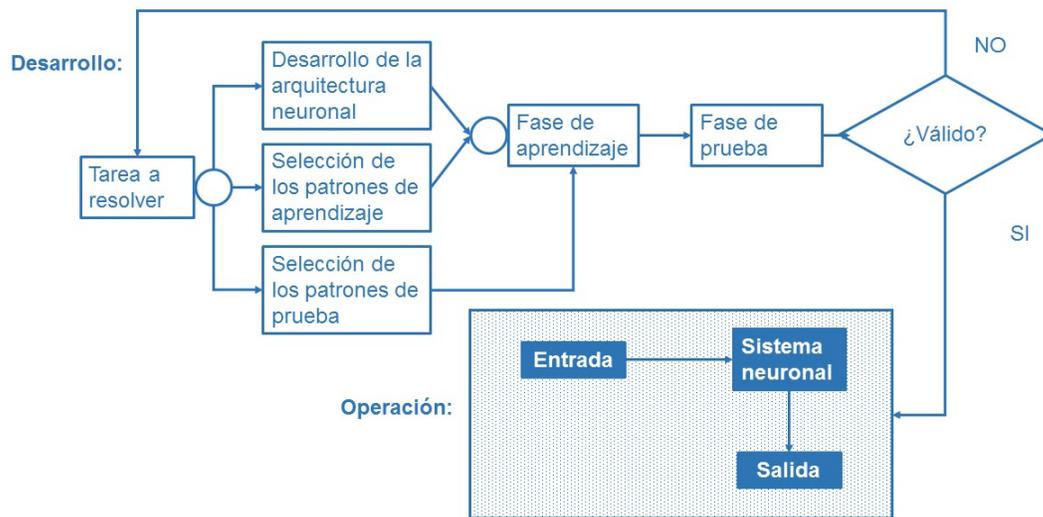


Figura 4.12 Diagrama de flujo del código generado para la identificación de patrones de movimiento en las señales EEG por medio de una ANN.

Capítulo 5

Pruebas

5.1 Pruebas realizadas en el laboratorio con el sistema de adquisición ADS1299EEG-FE

Para poder validar los resultados obtenidos del sistema del laboratorio, se realizaron pruebas en el Instituto Nacional de Rehabilitación con 6 sujetos. Con el fin de valorar la identificación de los movimientos, se eligieron 6 de los 16 sujetos de las pruebas realizadas en el laboratorio, cada uno con 5 canales, 16 movimientos con ojos cerrados, 16 movimientos con ojos abiertos, reposo con ojos cerrados y reposo con ojos abiertos. Cada registro contiene 3 segmentos de prueba con una duración de 2s para cada uno de los 32 movimientos y 4 segmentos de 2s para el estado de reposo.

Los movimientos considerados para las pruebas son: flexión extremidad superior derecho, extensión extremidad superior derecho, flexión extremidad superior izquierdo, extensión extremidad superior izquierdo, flexión codo derecho, extensión codo derecho, flexión codo izquierdo, extensión codo izquierdo, pronación mano derecha, supinación mano derecha,

pronación mano izquierda, pronación mano izquierda, cierre mano derecha, apertura mano derecha, cierre mano izquierda y apertura mano izquierda.

Considerando el primer párrafo de este capítulo, se tiene un total de “1530” señales EEG (6 personas, 5 canales por cada una, 16 movimientos y 1 reposo, 3 segmentos por cada movimiento de la persona). Con el filtrado, la segmentación y haciendo una combinación de cada una de las 6 ventanas (hamming, hanning, blackman, chebwin, kaiser y barthannwin) con un algoritmo de transformación de la señal y redes neuronales, se siguió con el siguiente procedimiento:

1. ventaneo, FFT para la extracción de características y ANN para la clasificación de patrones de movimiento
2. ventaneo, DWT para la extracción de características y ANN para la clasificación de patrones de movimiento
3. ventaneo, DWT para la extracción de características, PCA para una mayor distribución de los datos y ANN para la clasificación de patrones de movimiento

De acuerdo a la tabla A.4 de la sección 6.1 la ventana kaiser dio un mejor porcentaje de clasificación para la mayoría de los segmentos, por lo que se empleó para cada una de las pruebas. En las pruebas realizadas se obtuvieron vectores de 29 características para la FFT.

Para la DWT, la secuencia de la señal original se reconstruyó, siguiendo la ecuación 5.1 de la sección 4.3.2.2, a partir de las secuencias de coeficientes de aproximación y de los coeficientes wavelet, figura 5.1.

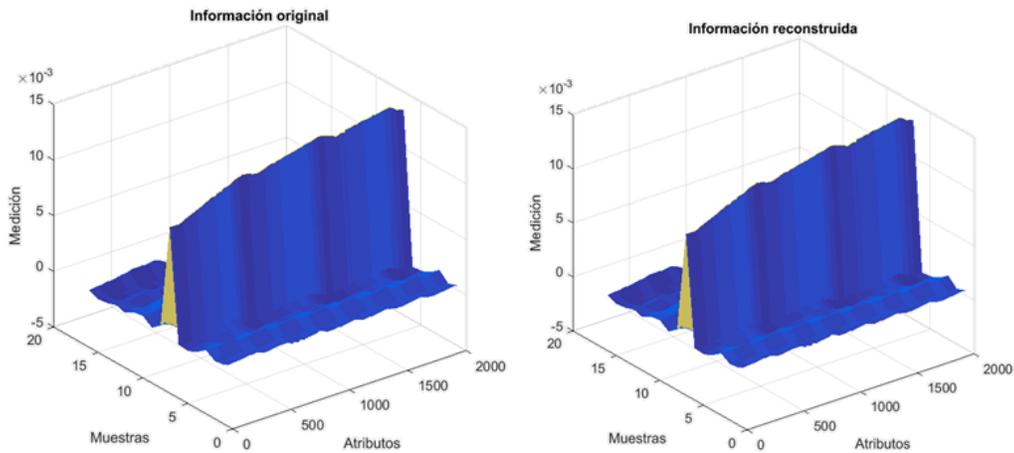


Figura 5.1 Señal EEG reconstruida a partir de los coeficientes obtenidos en el nivel de descomposición 6.

Considerando la ecuación 4.7 de la sección 4.3.2.2, las distancias euclidianas de la señal original y la reconstruida, se calcularon para 9 niveles de descomposición y 16 sujetos de prueba (véase el Apéndice A.3 tabla A.1). Durante las pruebas realizadas se comprobó que, aunque el error es muy pequeño, aumenta en proporción a los niveles de descomposición, figura A.1. Para la DWT se tomaron los coeficientes de aproximación del nivel de descomposición 6 y se obtuvieron vectores de 32 características.

La DWT se usó como una técnica de compactación de información y los vectores resultantes se utilizaron como datos de entrada para PCA. Para las pruebas del PCA, se definieron 5 canales como atributos y 16 movimientos como clases. En la figura 5.3(a), se muestra que existe poca dispersión de los datos para los dos primeros PC's, lo cual lleva a considerar un mayor número de PC's, en la figura 5.3(b), se muestra una línea curva indicando que la suma de los porcentajes de varianza para 4 componentes fue mayor al 90%, por lo que se eligieron 4 componentes principales para reducir la dimensionalidad de la señal EEG acondicionada con la ventana tipo kaiser, 16 personas y 16 movimientos con ojos abiertos [64].

Distancias euclidianas de la señal original y la señal reconstruida

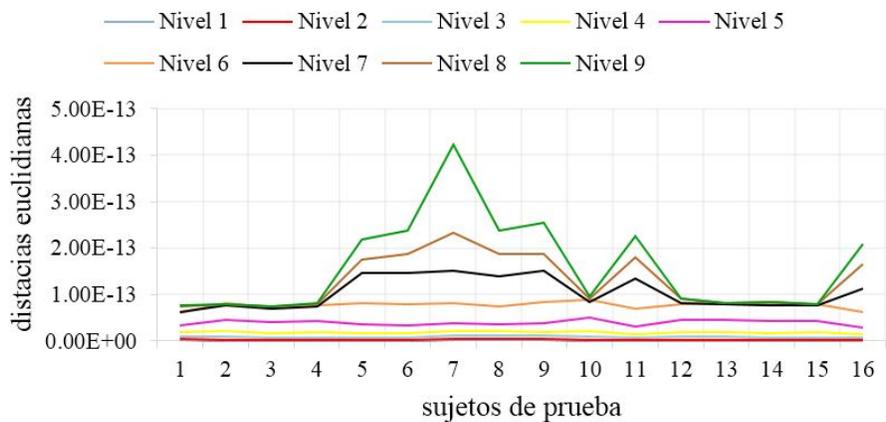
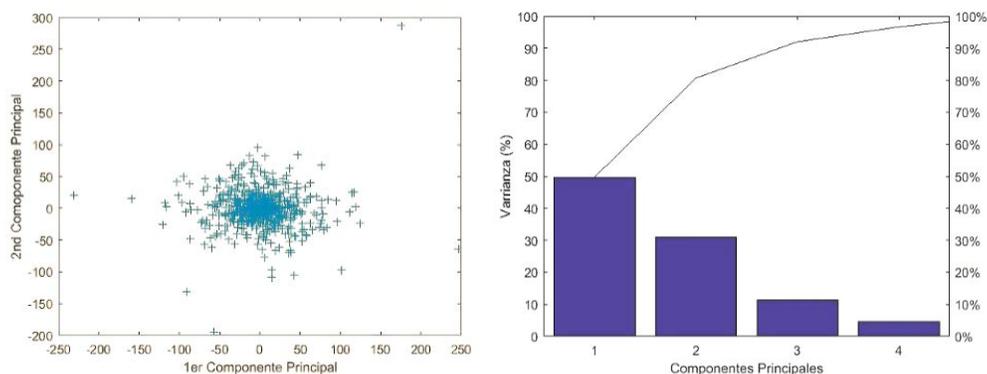


Figura 5.2 Distancias euclidianas de la señal original y la señal reconstruida para 9 niveles de descomposición y 16 sujetos de prueba.



(a) Componentes Principales 1 y 2. (b) Porcentajes de varianza para cada uno de los PC's.

Figura 5.3 Transformación lineal de señales EEG por medio de PCA y su varianza.

Para conocer si era viable identificar los patrones de 16 movimientos de las extremidades superiores, se llevó a cabo el siguiente procedimiento:

1. como primer paso se ingresaron a la red neuronal los datos de un movimiento y reposo, después otro movimiento y reposo, y así sucesivamente se fue intercambiando el movimiento de entrada hasta clasificar cada uno de los movimientos contra el reposo,
2. después se ingresaron a la red movimientos de 2 en 2, después de 4 en 4,
3. después se ingresaron a la red 8 movimientos correspondientes a la extremidad superior derecha, después solo los 8 movimientos correspondientes a la extremidad superior izquierda,
4. y por último los 16 movimientos.

NOTA: Este procedimiento se aplicó primero para movimientos con ojos cerrados y después para movimientos con ojos abiertos.

Una vez obtenidos los resultados de salida de la red y teniendo los objetivos de prueba de la clasificación se procedió a calcular la sensibilidad (ec. 5.1), especificidad (ec. 5.2) y exactitud (ec. 5.3) por medio de los falsos positivos (FP), falsos negativos (FN), verdaderos positivos (VP) y verdaderos negativos (VN) [65, 66]. Los verdaderos positivos corresponden a los movimientos correctamente clasificados dentro de su clase, los falsos negativos son los que no clasificó correctamente pero que pertenecen a esa clase. Los verdaderos negativos son los no clasificados dentro de esa clase que pertenecen a otro movimiento y los falsos positivos son los que clasificó erróneamente dentro de otra clase. Por lo anterior, la sensibilidad es la tasa de movimientos correctamente clasificados dentro de su clase y la especificidad es la tasa de los movimientos no clasificados dentro de esa clase que pertenecen a otro movimiento. La exactitud define la capacidad de la red neuronal para clasificar correctamente los patrones de movimiento.

$$\text{Sensibilidad} = \frac{VP}{VP + FN} \quad (5.1)$$

$$\text{Especificidad} = \frac{VN}{VN + FP} \quad (5.2)$$

$$\text{Exactitud} = \frac{VP + VN}{VP + FP + VN + FN} \quad (5.3)$$

5.2 Pruebas realizadas en la clínica con el sistema de adquisición g.BCI sys

Las señales EEG utilizadas para el proceso de validación fueron adquiridas en el Instituto Nacional de Rehabilitación (INR) de la Ciudad de México por medio del sistema de investigación para aplicaciones BCI, g.BCI sys, de la marca g.tec medical engineering. Este sistema cuenta con componentes de hardware y software necesarios para la adquisición de datos en tiempo real, análisis fuera de línea y disponibilidad para neurofeedback. El amplificador de este equipo, tiene un alto rendimiento y alta precisión de bioseñales. A diferencia del sistema ADS1299EEG-FE utilizado en laboratorio que cuenta con un muestreo de hasta 16 kHz el sistema g.BCI sys cuenta con un muestreo simultáneo de todos los canales de hasta 38,4 kHz.

El procedimiento de adquisición de las señales EEG en la clínica se ejecutó de la misma forma que el del laboratorio, sección 4.2, excepto que en clínica solo se realizaron registros a 6 personas y que las señales EEG fueron adquiridas entre las 14 y 20 hrs. del día, cabe



Figura 5.4 Posición del sujeto de prueba durante la adquisición de la señal con el equipo g.BCIsys.

mencionar que este cambio se realizó debido a la disponibilidad del equipo, figura 5.4. Para el procesamiento de las señales EEG adquiridas en la clínica, se aplicaron los algoritmos utilizados en la sección 4.3, para la extracción de características y clasificación.

Capítulo 6

Resultados

6.1 Adquisición de las señales EEG

Como ya se dijo en capítulos anteriores, las señales EEG son señales complejas y no-estacionarias, cuyas propiedades varían en función del tiempo analizado. Debido a ello, un análisis visual en el dominio del tiempo no permite extraer mucha información. Para corroborar lo anterior, en la figura 6.1 se muestra la señal EEG adquirida con el sistema de la clínica g.BCI sys de la persona 1 y el canal C3 correspondiente a la zona motora, donde visualmente no se identifica qué señal corresponde a una ejecución del movimiento de pronación mano derecha o supinación mano derecha. En este sentido, el análisis espectral permite estudiar la evolución del contenido de frecuencias de las señales EEG, lo cual es muy útil para encontrar los ritmos *mu* y así poder identificar patrones de movimiento.

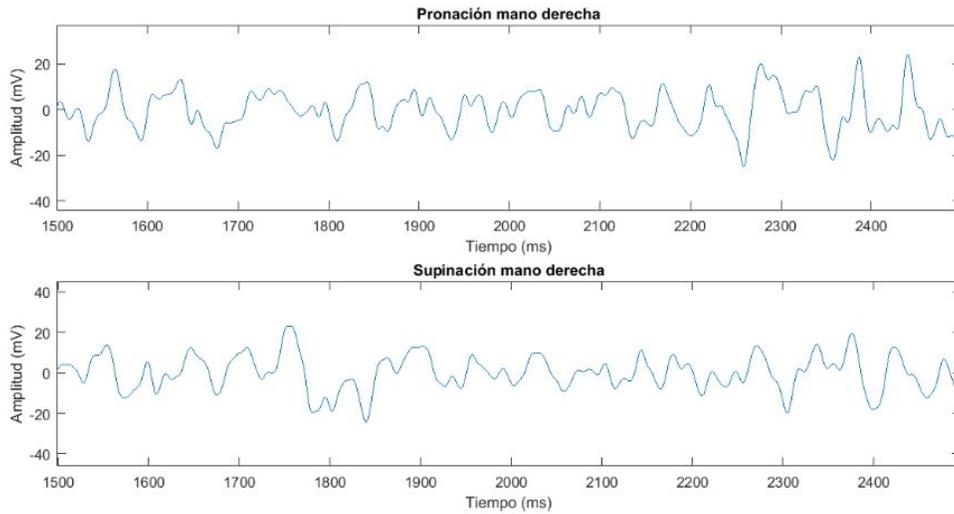


Figura 6.1 Señales EEG - base de datos obtenida en la clínica.

Los resultados de las pruebas de clasificación con las señales EEG segmentadas y las ventanas tipo hamming, hanning, blackman, chebwin, kaiser y barthanwin, para cada uno de las técnicas de extracción de características se muestran en la figura 6.2 (véase el Apéndice A.2, tabla A.2). En la figura 6.3, se muestra una comparativa de los resultados obtenidos de la clasificación al emplear diferentes herramientas para la extracción de características.

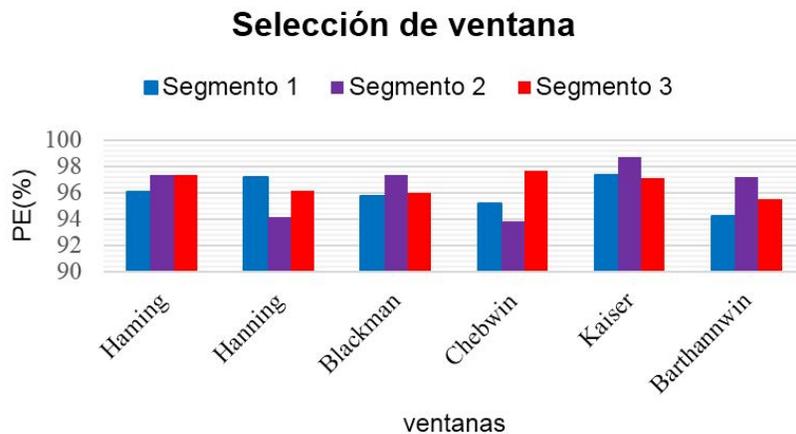


Figura 6.2 Porcentajes de exactitud (PE) para cada una de las ventanas por segmento.

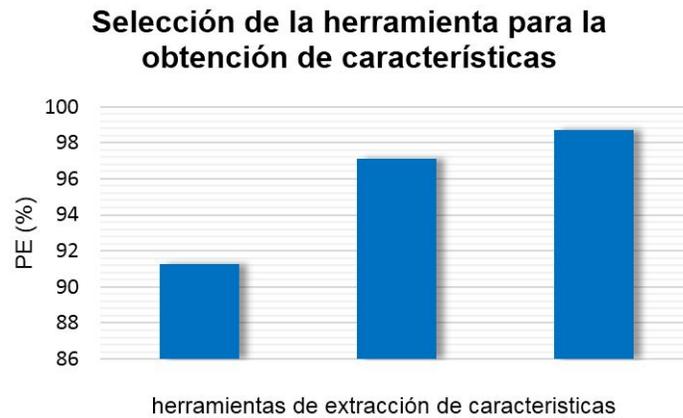


Figura 6.3 Porcentajes de exactitud (PE) empleando diferentes herramientas de extracción de características.

Como se mencionó a priori, después de algunas pruebas (figura A.4 y figura 6.2), el mejor porcentaje de clasificación se presentó utilizando la ventana kaiser y DWT con PCA para las bases de datos con ojos abiertos y ojos cerrados, excepto para el segmento 3 que dio un mejor porcentaje con la ventana chebwin para la base de datos con ojos cerrados, esta variación pudo haberse presentado a causa de algún artefacto como el movimiento ocular o muscular.

6.2 Extracción de características

Para la extracción de características, las señales EEG utilizadas fueron preprocesadas con un filtro Notch a 60 Hz y uno pasa bajas a 45 Hz, una segmentación de 2000 ms para cada movimiento, eliminación la componente CD y la aplicación de una ventana tipo kaiser.

6.2.1 Transformada rápida de Fourier

La FFT se calculó para caracterizar, en el dominio de la potencia en los ritmos cerebrales, las señales EEG preprocesadas.

Con el fin de reducir la información obtenida de la FFT, se procedió a realizar el gráfico estadístico “diagrama de caja y bigotes”, figura 6.4, el cual utiliza 5 medidas estadísticas: el valor mínimo (L_i), el primer cuartil (Q_1), la mediana, el tercer cuartil (Q_3) y el valor máximo (L_s). El rango intercuartil (RIC), es la distancia entre el primer y tercer cuartil [67].

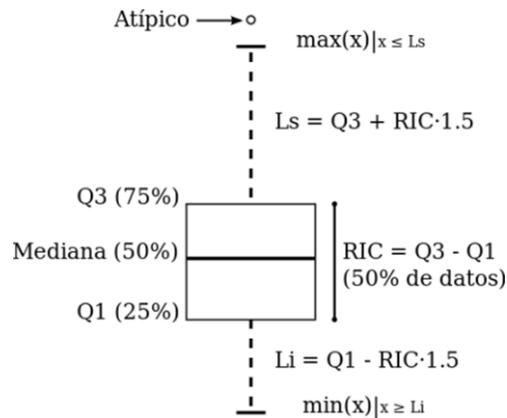
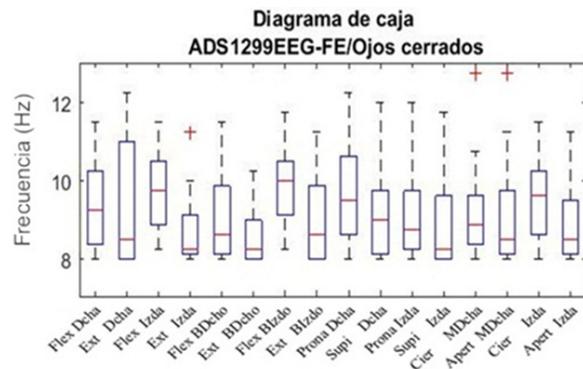


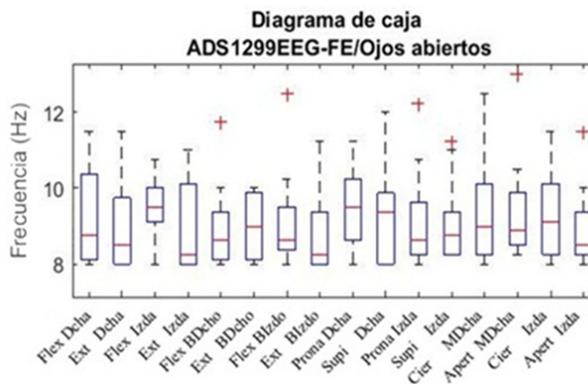
Figura 6.4 Diagrama de caja y bigotes.

Para la obtención de este diagrama, se consideraron los resultados de la FFT, tomando como datos de entrada los picos más altos del espectro de frecuencias sobre el ritmo μ (8-13 Hz). Con el fin de realizar una comparación entre la base de datos generada con el sistema de laboratorio y el sistema de clínica, se consideraron solo 6 de los 16 sujetos de prueba con 5 canales para cada uno de los movimientos, esto para tener el mismo número de sujetos de prueba para todos los diagramas de caja, porque como ya se mencionó anteriormente, la base de datos obtenida en clínica se generó con 6 sujetos de prueba. Se generaron 2 diagramas de

caja para los resultados de la FFT obtenidos con la base de datos generada en el laboratorio, el primero corresponde a los movimientos con ojos cerrados y el segundo a los movimientos con ojos abiertos, y 2 diagramas más para los resultados de la FFT obtenidos con la base de datos generada en la clínica, de igual forma uno para movimientos con ojos cerrados y otro para movimientos con ojos abiertos, figuras 6.5 y 6.6. Los resultados obtenidos del diagrama de caja para ambas bases de datos muestran que una característica favorable para la identificación de movimientos es la mediana, debido a que varía con respecto al tipo de movimiento.

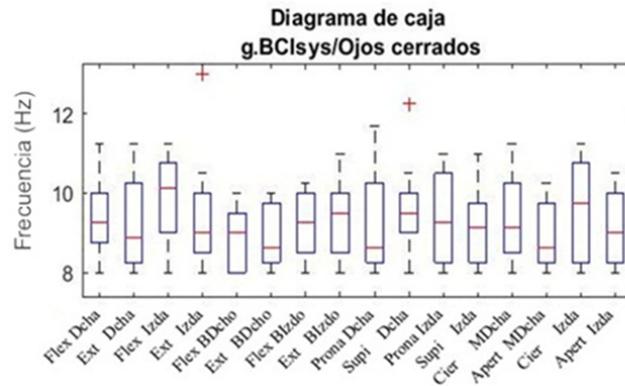


(a) Diagrama de caja de movimientos con ojos cerrados.

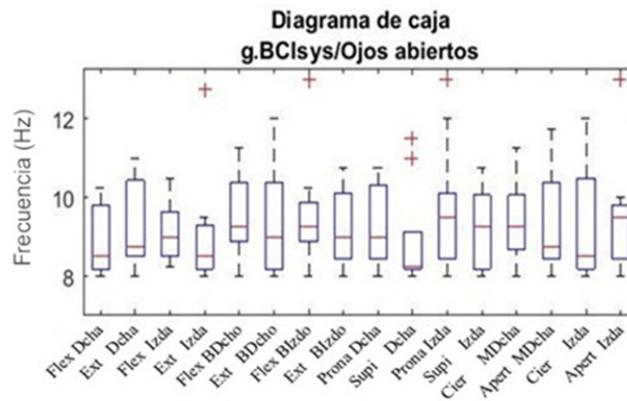


(b) Diagrama de caja de movimientos con ojos abiertos.

Figura 6.5 Diagramas de caja utilizando los coeficientes de la FFT - base de datos del laboratorio.



(a) Diagrama de caja de movimientos con ojos cerrados.



(b) Diagrama de caja de movimientos con ojos abiertos.

Figura 6.6 Diagramas de caja utilizando los coeficientes de la FFT - base de datos de clínica.

6.2.2 Transformada wavelet discreta

Una segunda técnica de extracción de características utilizada para este trabajo fue la DWT. Para ello se utilizó como wavelet madre a una Daubechies de tercer orden (db3) y los coeficientes del nivel de descomposición 6, los cuales, para este trabajo, corresponden al ritmo *mu* y ritmo *alfa*.

En la tabla 6.1 el ritmo *alfa* se encuentra en el mismo nivel de descomposición que el ritmo de interés (ritmo *mu*), sin embargo, de acuerdo a la consulta bibliográfica la presencia de esta disminuye desaparece al abrir los ojos o al concentrarse en una tarea [68], y como para este trabajo el sujeto de prueba requiere estar concentrado en las indicaciones auditivas y su mirada fija en la simulación visual, no representará problema para la identificación de los patrones de movimiento.

Tabla 6.1 Niveles de descomposición wavelet.

Niveles de descomposición	Frecuencia (Hz)	Ritmo cerebral
4	32-64	<i>gamma</i>
5	16-34	<i>beta</i>
6	8-16	<i>alfa, mu</i>
7	4-8	<i>theta</i>
8	2-4	<i>delta</i>
9	0-1	<i>delta</i>

Para este trabajo, además de utilizar DWT como una herramienta de extracción de características, también se usó como medio de compactación de información, con el fin de usar los coeficientes wavelet como datos de entrada en PCA.

6.2.3 Análisis de componentes principales.

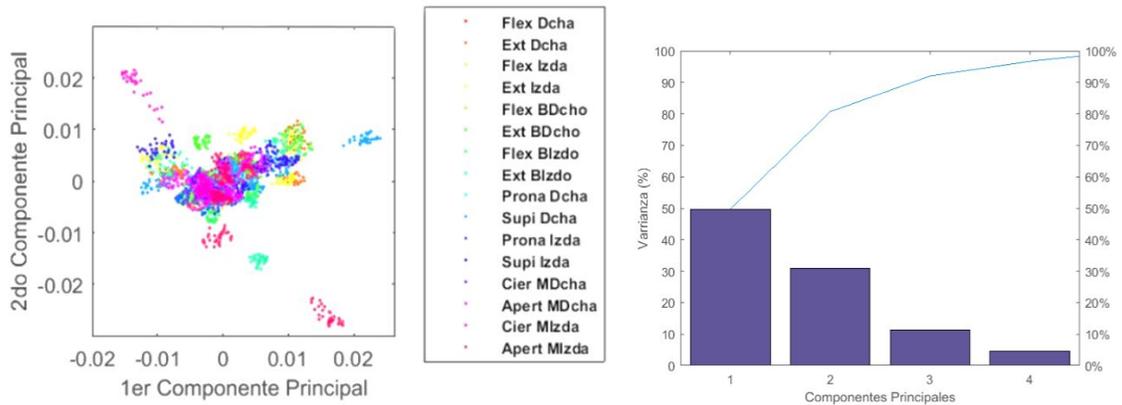
A continuación, se muestran los mejores resultados obtenidos de la base de datos generada en el laboratorio y la base de datos generada en la clínica.

6.2.3.1 Resultados de las pruebas realizadas en el laboratorio con el sistema de adquisición ADS1299EEG-FE

En el PCA se tomaron los datos resultantes de la DWT para obtener los eigenvectores (componentes principales) de la matriz de covarianza, [33]. En el proceso de dispersión de datos se seleccionaron 6 de los 16 sujetos, debido a que presentaron una variabilidad de datos muy similar entre ellos, por lo que los sujetos seleccionados fueron: 2, 5, 6, 12, 13 y 15. Se obtuvo una varianza del 95.72% con 4 componentes principales para ojos cerrados y para ojos abiertos se obtuvo una varianza de 95.0315% con 4 componentes principales, figura 6.7. Debido a que las señales de movimientos con ojos abiertos contienen más artefactos que con ojos cerrados, estos datos tuvieron que ser estandarizados en base a la varianza (distancia de una medición respecto a la media) [63].

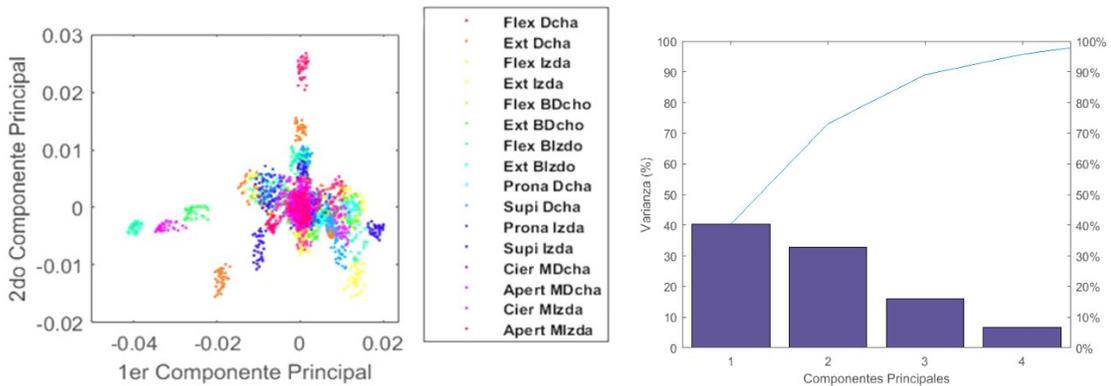
6.2.3.2 Resultados de las pruebas realizadas en la clínica con el sistema de adquisición g.BCIsys

Para el PCA se tomaron los datos resultantes de la DWT. A continuación, se muestra la variabilidad de los datos de la base de datos obtenida en la clínica, durante la ejecución de movimientos con ojos cerrados y con ojos abiertos, figura 6.8. Los datos con ojos abiertos presentaron mejor variabilidad con los datos estandarizados con base en la varianza [29]. Para el caso de ojos cerrados se obtuvo una varianza del 97.4% con 4 componentes principales y para ojos abiertos de 98.1% con 4 componentes principales.



(a) Componentes Principales 1 y 2- ojos cerrados.

(b) Porcentajes de varianza para cada uno de los PC's- ojos cerrados.

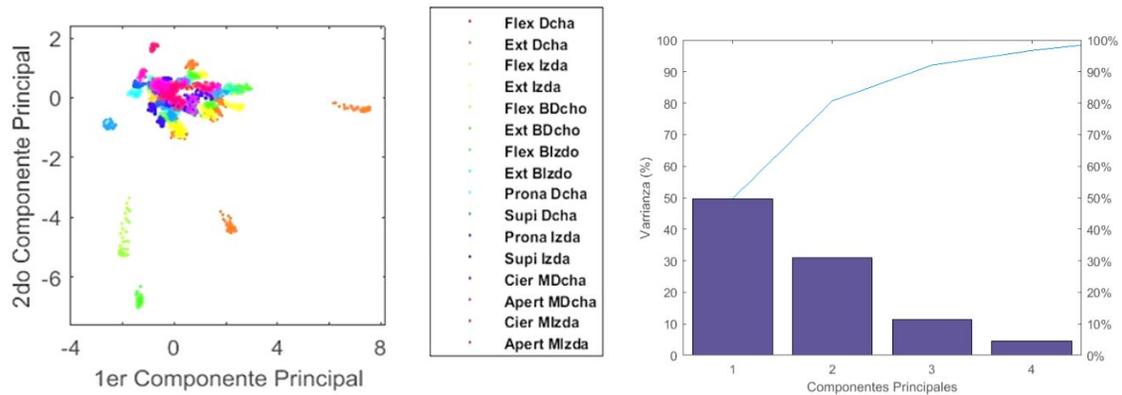


(c) Componentes Principales 1 y 2- ojos abiertos.

(d) Porcentajes de varianza para cada uno de los PC's- ojos abiertos.

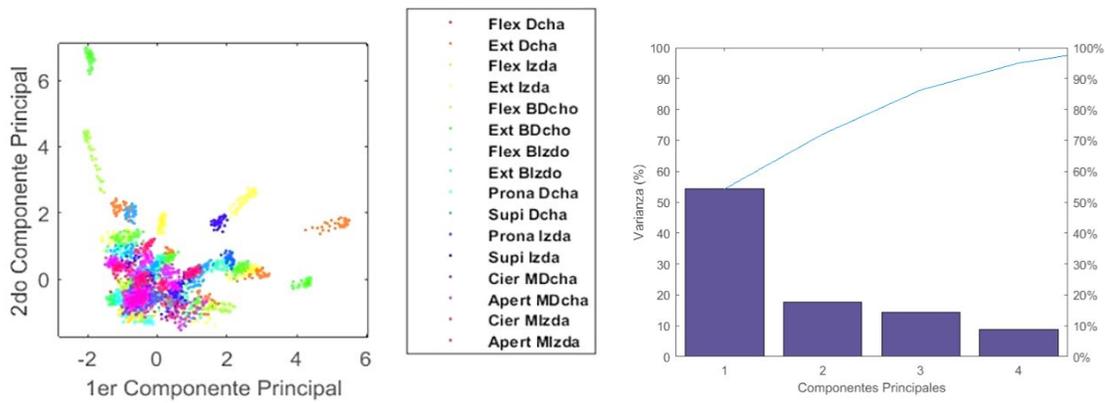
Figura 6.7 Dispersión de los datos por medio de PCA - base de datos del laboratorio.

Debido a que en las figuras 6.7(a), 6.7(c), 6.8(a), 6.8(c), 6.7(b), 6.7(d), 6.8(b) y 6.8(d), se muestra poca dispersión de los datos, se consideró aumentar el número de componentes principales. Se decidieron 4 componentes principales debido a que el punto de inflexión (el mayor aumento relativo) de la varianza entre un componente principal y el siguiente se obtiene del tercero al cuarto, además, la suma de los porcentajes de varianza mayor al 90%.



(a) Componentes Principales 1 y 2- ojos cerrados.

(b) Porcentajes de varianza para cada uno de los PC´s- ojos cerrados.



(c) Componentes Principales 1 y 2- ojos abiertos.

(d) Porcentajes de varianza para cada uno de los PC´s- ojos abiertos.

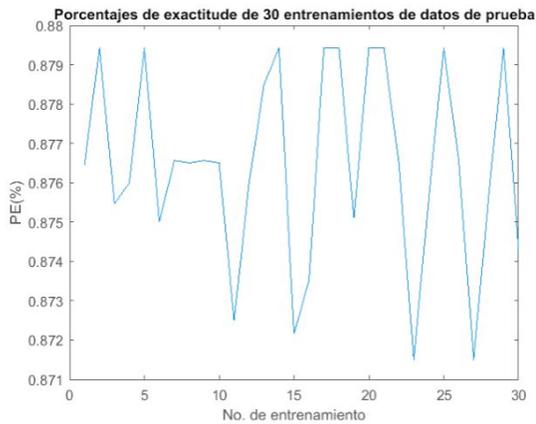
Figura 6.8 Dispersión de los datos por medio de PCA - base de datos de la clínica.

6.3 Clasificación con redes neuronales artificiales.

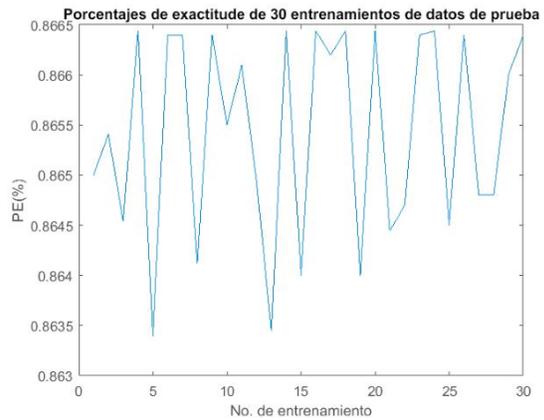
Para realizar la clasificación se creó una red neuronal feed-forward backpropagation con un algoritmo de aprendizaje “Levenberg - Marquardt backpropagation”, una capa oculta tipo

“Hyperbolic tangent sigmoid” con 12 neuronas, una capa de entrada tipo “Symmetric saturating linear” con 11 neuronas y una capa de salida con 16 neuronas. Para la selección de neuronas y parámetros para el entrenamiento y la validación de la red neuronal, se realizaron pruebas variando el número de épocas, después aumentando la tasa de aprendizaje, siguiendo con el aumento del número de neuronas y por último disminuyendo el error. Con cada combinación de parámetros y neuronas se realizó un promedio de porcentajes obtenidos después de 30 entrenamientos y pruebas 6.9. El mayor promedio fue el indicador de que esos parámetros eran los mejores para la red neuronal. Los parámetros de clasificación para el entrenamiento de la red neuronal para el sistema de adquisición de la clínica y laboratorio son: 3500 épocas, 0.001 de error y una tasa de aprendizaje de 0.02.

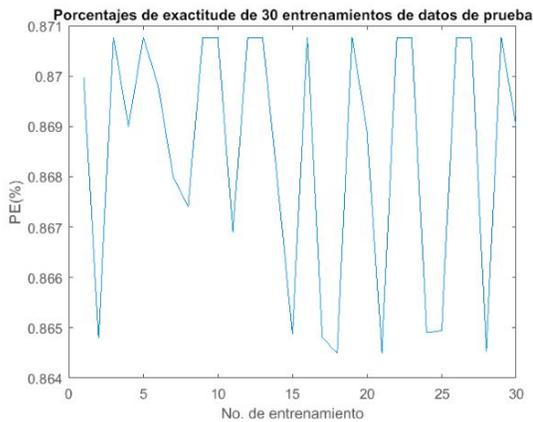
Durante las pruebas de las ANN entrenadas el porcentaje de exactitud más alto de prueba fue de 87.943% para la clasificación de movimientos con ojos cerrados y 86.644% con ojos abiertos para el caso de la base de datos generada en el laboratorio. figura 6.10, donde E_m son los errores de las pendientes y E_b los errores de intersección. En las figuras 6.10(b), 6.10(d), 6.11(b) y 6.11(d), se muestran las sensibilidades y especificidades de la regresión lineal, donde un mayor número de movimientos con ojos abiertos muestran un menor porcentaje de sensibilidad y especificidad en comparación con los movimientos con ojos cerrados.



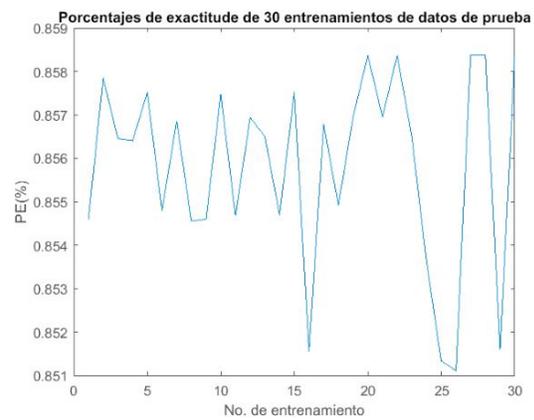
(a) Base de datos del laboratorio ojos cerrados.



(b) Base de datos del laboratorio ojos abiertos.



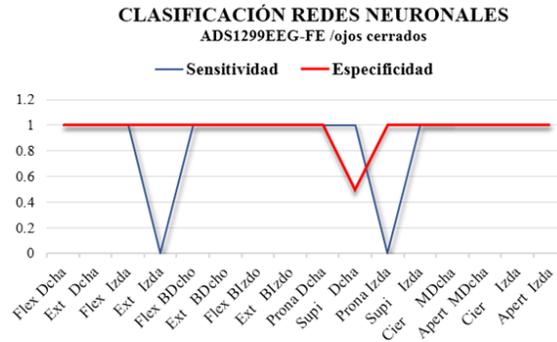
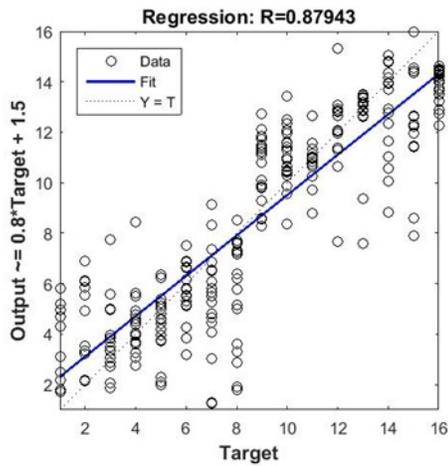
(c) Base de datos de la clínica ojos cerrados.



(d) Base de datos de la clínica ojos abiertos.

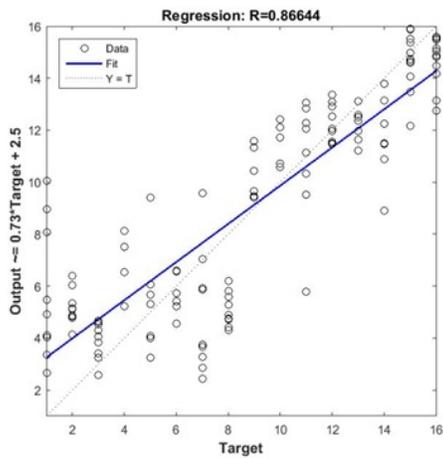
Figura 6.9 Porcentajes de exactitud de 30 entrenamientos de datos de prueba.

Para la base de datos generada en la clínica, se tiene un porcentaje de exactitud de prueba de 87.077% para la clasificación de movimientos con ojos cerrados y 85.837% para los ojos abiertos, figura 6.11. En las figuras 6.11(b) y 6.11(d), se muestran las sensibilidades y especificidades de la regresión lineal, donde un mayor número de movimientos con ojos abiertos muestran un menor porcentaje de sensibilidad y especificidad en comparación con los movimientos con ojos cerrados.



(a) Regresión de movimientos con ojos cerrados. $y = 0.801x + 1.503$
 $E_m = 0.199, E_b = -1.5$

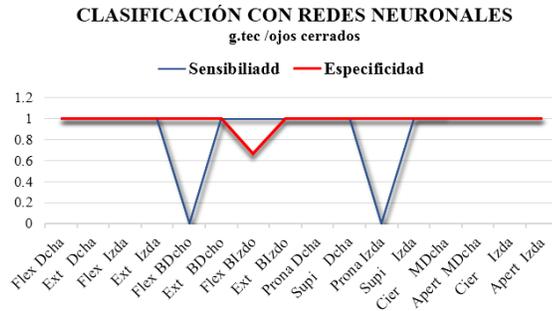
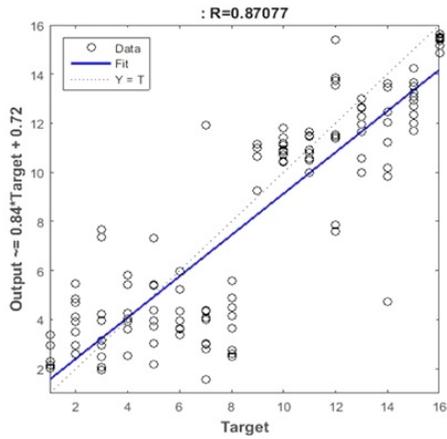
(b) Sensibilidad y especificidad ojos cerrados.



(c) Regresión de movimientos con ojos abiertos. $y = 0.7344x + 2.52$
 $E_m = 0.2656, E_b = -2.52$

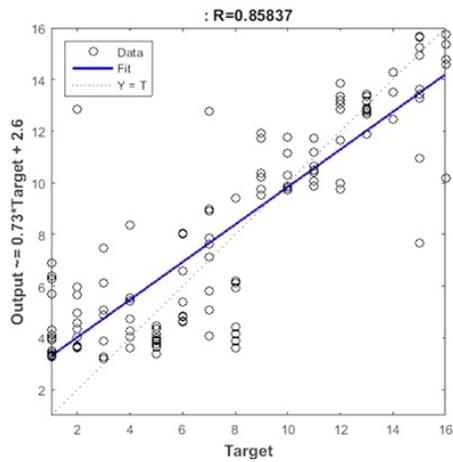
(d) Sensibilidad y especificidad ojos abiertos.

Figura 6.10 Regresión lineal - base de datos obtenida en el laboratorio.



(a) Regresión de movimientos con ojos cerrados. $y = 0.8411x + 0.7207$
 $E_m = 0.1589, E_b = 0.7207$

(b) Sensibilidad y especificidad ojos cerrados.



(c) Regresión de movimientos con ojos abiertos. $y = 0.7267x + 2.5724$
 $E_m = 0.2733, E_b = -2.5724$

(d) Sensibilidad y especificidad ojos abiertos.

Figura 6.11 Regresión lineal - base de datos obtenida en la clínica.

Con las matrices de confusión obtenidas de la clasificación para la base de datos generada en el laboratorio, se deduce que los movimientos con ojos cerrados menos identificados por la red neuronal son los movimientos extensión codo izquierdo y pronación izquierda, y para movimientos con ojos abiertos son los movimientos extensión extremidad superior derecha, supinación mano derecha y pronación mano izquierda. Y para la base de datos generada en la clínica, los movimientos con ojos cerrados menos identificados son los movimientos flexión extremidad superior derecha y pronación izquierda y con ojos abiertos los movimientos de extensión extremidad superior derecha, supinación derecha, pronación izquierda y apertura izquierda, tabla 6.2, tabla 6.3, tabla 6.4 y tabla 6.5.

Tabla 6.2 Matriz de confusión - ojos cerrados. Base de datos del laboratorio.

Clase																	Porc
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	(%)
Flex Dcha	1	9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100
Ext Dcha	2	0	6	0	0	0	0	0	0	0	0	0	0	0	0	0	100
Flex Izda	3	0	0	5	0	0	0	0	0	0	0	0	0	0	0	0	100
Ext Izda	4	0	0	0	0	1	1	0	1	1	2	0	0	0	0	1	0
Flex BDcho	5	0	0	0	0	3	0	0	0	0	0	0	0	0	0	0	100
Ext BDcho	6	0	0	0	0	0	11	0	0	0	0	0	0	0	0	0	100
Flex BIzdo	7	0	0	0	0	0	0	8	0	0	0	0	0	0	0	0	100
Ext BIzdo	8	0	0	0	0	0	0	0	8	0	0	0	0	0	0	0	100
Prona Dcha	9	0	0	0	0	0	0	0	0	10	0	0	0	0	0	0	100
Supi Dcha	10	0	0	0	0	0	0	0	0	0	9	0	0	0	0	0	100
Prona Izda	11	0	0	0	1	0	0	0	0	2	3	0	0	0	0	0	0
Supi Izda	12	0	0	0	0	0	0	0	0	0	0	0	9	0	0	0	100
Cier MDcha	13	0	0	0	0	0	0	0	0	0	0	0	0	6	0	0	100
Apert MDcha	14	0	0	0	0	0	0	0	0	0	0	0	0	0	9	0	100
Cier MIzda	15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	9	100
Apert MIzda	16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	13 100

Tabla 6.3 Matriz de confusión - ojos abiertos. Base de datos del laboratorio.

Clase																	Porc	
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	(%)	
Flex Dcha	1	10	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	
Ext Dcha	2	0	8	0	0	1	0	0	0	0	0	0	0	0	0	0	90	
Flex Izda	3	0	0	6	0	0	0	0	0	0	0	0	0	0	0	0	100	
Ext Izda	4	0	0	0	8	0	0	0	0	0	0	0	0	0	0	0	100	
Flex BDcho	5	0	0	0	0	5	0	0	0	0	0	0	0	0	0	0	100	
Ext BDcho	6	2	0	1	0	0	3	0	2	0	0	0	2	0	0	1	27	
Flex BIzdo	7	0	0	0	0	0	0	8	0	0	0	0	0	0	0	0	100	
Ext BIzdo	8	0	0	0	0	0	0	0	9	0	0	0	0	0	0	0	100	
Prona Dcha	9	0	0	0	0	1	0	0	0	10	0	0	0	0	0	0	95	
Supi Dcha	10	0	2	0	0	2	0	0	0	0	3	0	0	0	0	2	35	
Prona Izda	11	0	1	0	0	1	0	0	1	0	0	3	0	0	1	0	38	
Supi Izda	12	0	0	0	0	0	0	0	0	0	0	0	8	0	0	0	100	
Cier MDcha	13	0	0	0	0	0	0	0	0	0	0	0	0	7	0	0	100	
Apert MDcha	14	0	0	0	0	0	0	0	0	0	0	0	0	0	7	0	100	
Cier MIzda	15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	8	100	
Apert MIzda	16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	8	100
																	86	

Tabla 6.4 Matriz de confusión - ojos cerrados. Base de datos de la clínica.

Clase																	Porc
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	(%)
Flex Dcha	1	13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100
Ext Dcha	2	0	12	0	0	0	0	0	0	0	0	0	0	0	0	0	100
Flex Izda	3	0	0	10	0	0	0	0	0	0	0	0	0	0	0	0	100
Ext Izda	4	0	0	0	9	0	0	0	0	0	0	0	0	0	0	0	100
Flex BDcho	5	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Ext BDcho	6	0	0	0	0	0	9	0	0	0	0	0	0	0	0	0	100
Flex BIzdo	7	0	0	0	0	0	0	6	0	0	0	0	0	0	0	0	100
Ext BIzdo	8	0	0	0	0	0	0	0	4	0	0	0	0	0	0	0	100
Prona Dcha	9	0	0	0	0	0	0	0	0	7	0	0	0	0	0	0	100
Supi Dcha	10	0	0	0	0	0	0	0	0	0	6	0	0	0	0	0	100
Prona Izda	11	6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.5
Supi Izda	12	0	0	0	0	0	0	0	0	0	0	0	8	0	0	0	100
Cier MDcha	13	0	0	0	0	0	0	0	0	0	0	0	0	7	0	0	100
Apert MDcha	14	0	0	0	0	0	0	0	0	0	0	0	0	0	6	0	100
Cier MIzda	15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	9	100
Apert MIzda	16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	10	100

87

Tabla 6.5 Matriz de confusión - ojos abiertos. Base de datos de la clínica.

Clase																	Porc	
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	(%)	
Flex Dcha	1	16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100	
Ext Dcha	2	0	12	0	0	0	0	0	0	0	0	0	0	0	0	0	100	
Flex Izda	3	0	0	10	0	0	0	0	0	0	0	0	0	0	0	0	100	
Ext Izda	4	0	0	0	8	0	0	0	0	0	0	0	0	0	0	0	100	
Flex BDcho	5	0	0	0	0	8	0	0	0	0	0	0	0	0	0	0	100	
Ext BDcho	6	0	0	1	0	0	2	0	0	1	0	0	5	0	0	0	25	
Flex BIzdo	7	0	0	0	0	0	0	8	0	0	0	0	0	0	0	0	100	
Ext BIzdo	8	0	0	0	0	0	0	0	6	0	0	0	0	0	0	0	100	
Prona Dcha	9	0	0	0	0	0	0	0	0	8	0	0	0	0	0	0	100	
Supi Dcha	10	0	1	0	0	0	0	0	0	0	3	0	0	1	0	0	50	
Prona Izda	11	1	0	0	0	1	0	1	0	1	0	0	0	0	1	0	20	
Supi Izda	12	0	0	0	0	0	0	0	0	0	0	0	7	0	0	0	100	
Cier MDcha	13	0	0	0	0	0	0	0	0	0	0	0	0	7	0	0	100	
Apert MDcha	14	0	0	0	0	0	0	0	0	0	0	0	0	0	6	0	100	
Cier MIzda	15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	9	100	
Apert MIzda	16	0	0	0	1	0	0	0	0	0	0	1	0	1	0	1	4	50
																	85	

Capítulo 7

Discusión

Durante las pruebas realizadas, la señal EEG fue de gran importancia para la identificación de movimientos, debido a que tiene bandas de frecuencias específicas para los diferentes movimientos de la extremidad superior que se analizaron en el trabajo.

Con respecto a los diagramas de caja obtenidos en las figuras 6.5 y 6.6, la mayoría de los movimientos presentaron una mediana diferente entre sí, excepto el movimiento de extensión brazo izquierdo y extensión brazo derecho con ojos cerrados, cierre y apertura mano derecha con ojos abiertos de la base de datos del laboratorio y pronación y supinación mano izquierda y supinación y cierre mano derecha de la base de datos de la clínica. Al mismo tiempo, la información de movimientos con ojos cerrados presentó una menor número de datos atípicos que la información de movimientos con ojos cerrados, por lo que los diagramas de caja mostraron una tendencia de un mayor porcentaje de exactitud en la clasificación para movimientos con ojos cerrados que para movimientos con ojos abiertos posiblemente porque en el registro EEG con ojos abiertos se presentaron artefactos como el parpadeo de ojos y la estimulación luminosa que pudo haberse presentado durante las pruebas. Esto se

comprobó haciendo una comparación entre los resultados de los diagramas de caja y los resultados de la clasificación de ANN.

Para hacer un análisis válido fue necesario evaluar todos los recursos gráficos y no visuales como un conjunto y poner especial atención en la forma en que interactúan entre ellos. Los resultados de las pruebas realizadas, tabla A.4, mostraron que la DWT presenta un mejor rendimiento que la FFT, esto pudo ser debido a que la FFT requiere un mayor número de coeficientes que los seleccionados para este trabajo.

El PCA, resultó ser una herramienta dominante para la identificación de patrones de movimiento en las señales EEG, debido a que los mejores porcentajes de exactitud obtenidos para la clasificación de 16 movimientos, con ambas bases de datos (laboratorio y clínica), resultaron estar por arriba del 80% de exactitud para los movimientos con ojos cerrados y ojos abiertos.

En la clasificación de movimientos con redes neuronales, de acuerdo a los resultados de sensibilidad y especificidad, en las figuras 6.10 y 6.11, en promedio la especificidad tuvo un mayor porcentaje que la sensibilidad, lo cual indica que la probabilidad de clasificar correctamente los movimientos en su clase es mayor que la probabilidad de identificar un movimiento en una clase que no le pertenece, esto sería favorable para una aplicación real de una prótesis, por ejemplo, ya que si el sistema llegara a confundir los movimientos, el sujeto realizaría acciones erróneas que podrían llegar a provocar accidentes.

Capítulo 8

Conclusiones y perspectiva

De acuerdo a los resultados y a las discusiones expuestas a priori se puede afirmar con un nivel de confianza de entre un 80 y 90% que las técnicas empleadas con el protocolo elegido pueden clasificar un registro de EEG perteneciente a alguno de los 16 movimientos pertinente al presente trabajo de investigación correctamente dentro de la clase correspondiente.

Para el proceso de adquisición de la señal EEG se utilizó solo una gorra con electrodos de talla mediana, por lo que faltaron gorras de diferentes tallas para los sujetos a registrar debido a que se descartaron sujetos de las pruebas porque la gorra no les ajusto y los electrodos no hicieron contacto y en el caso contrario los electrodos no quedaban en la posición correcta.

Trabajo a futuro.

Con el cumplimiento de los objetivos delimitados y conclusión del presente trabajo, surge la motivación para proyectos futuros, siendo los principales:

- realizar una depuración de los algoritmos que presentaron un mejor resultado en el proceso de la identificación de patrones de movimiento de las extremidades superiores con el fin de trabajar con la adquisición y procesamiento en línea, para así poder aplicar estos algoritmos en un BCI
- aplicar diferentes herramientas de procesamiento, como QDA (por sus siglas en inglés Quadratic Discriminant Analysis QDA), ICA (por sus siglas en inglés Independent Component Analysis ICA) y/o Parámetros de Hjorth, a la base de datos generada, tanto para la extracción de características como para la clasificación de movimientos
- para reforzar los resultados obtenidos en este trabajo es preciso aumentar la base de datos con el incremento del número de sujetos, de canales y de pruebas por sujeto.
- adaptar la metodología propuesta en este trabajo a la identificación de movimientos imaginados, primero para el caso de sujetos con su actividad locomotora normal, y posteriormente, a sujetos que han sufrido de la amputación de alguna de sus extremidades superiores.

Referencias

- [1] H. Martha, Academia Nacional de Medicina, *Acta de la Sesión del 4 de marzo del 2015 Academia Nacional de Medicina, Los amputados, un reto para el estado*, marzo 2015.
- [2] H. Barouti *et al.*, *Amputaciones del miembro superior*, Enciclopedia Médico-Quirúrgica, Elsevier, Paris, pp. 2, enero 2003.
- [3] Prótesis de brazo, <http://www.excelsior.com.mx/nacional/2016/05/31/1095773>, mayo 2015
- [4] Prótesis de brazo, <http://www.eluniversal.com.mx/articulo/techbit/2015/08/2/innovacion-para-la-salud>, agosto 2015.
- [5] Chin-Teng Lin *et al.*, *Noninvasive Neural Protheses Using Mobile and Wireless EEG*, Proceedings of the IEEE, Vol. 96, Issue:7, pp. 1167-1183, julio 2008.
- [6] D. Peleg *et al.*, *Classification of finger activation for use in a robotic prosthesis arm*, IEEE Transactions on Neural Systems and Rehabilitation Engineering, Vol. 10, Issue: 4, pp. 1534-4320, febrero 2003.
- [7] E. Niedermeyer, *Electroencephalography, Basic Principles, clinical applications and related fields*, Lippincott Williams and Wilkins, Quinta Edición, pp. 129, 2005.
- [8] J. McFarland *et al.*, *Brain-Computer Interface Operation of Robotic and Prosthetic Devices*, Computer, Vol.41, No. 10, pp. 52-56, October 2008.
- [9] G. E. Fabiani *et al.*, *Conversion of EEG activity into cursor movement by a brain-computer interface (BCI)*, IEEE Transactions on Neural Systems and Rehabilitation Engineering , Vol.12, Issue: 3 , pp. 331 - 338, julio 2013.

- [10] G. Pfurtscheller *et al.*, *On-line EEG classification during externally-paced hand movements using a neural network-based classifier*, *Electroencephalography and Clinical Neurophysiology*, Vol. 99, Issue 5, pp. 416-425, noviembre 1996.
- [11] M. T. García González *et al.*, *Potenciales bioeléctricos: origen y registro*, Editorial Universidad Autónoma Metropolitana Unidad Iztapalapa, pp. 187-190, 1998.
- [12] J. G. Proakis *et al.*, *Tratamiento Digital de Señales*, Editorial Pearson Educación, Madrid, pp. 458-496, 2007.
- [13] *Presencia del Tema de la discapacidad en la información estadística*, <http://www.inegi.org.mx/est/contenidos/espanol/metodologias/censos/marcoteorico3.pdf>, agosto 2001.
- [14] Prótesis mioeléctrica 3D, <https://fondeadora.mx/projects/nuevo-proyecto-6d8e1e84-9cfa-4431-9f67-042f69cd1782>, julio 2015.
- [15] J.M. Dorador, *Robótica y prótesis inteligentes*, *Revista Digital Universitaria*, Vol. 6, No. 6, pp. 2-15, enero 2004.
- [16] F. Quiroz *et al.*, *Interfaces neuronales y sistemas máquina-cerebro: fundamentos y aplicaciones*, *Revista ingeniería Biomédica*, No. 1, pp. 14-22, mayo 2007.
- [17] M. Zecca *et al.*, *Control of Multifunctional Prosthetic Hands by Processing the Electromyographic Signal*, *Critical Reviews in Biomedical Engineering*, Vol. 30, No. 4-6, pp. 459-485, 2002.
- [18] J.J. Páez, *Aprendizaje de Actividades Motoras en Procesos Prensiles con el uso de una Prótesis Mecatrónica Controlada por Señales Mioeléctricas en Personas Amputadas entre Codo y Muñeca*, *Revista Ciencia y Poder Aéreo*, No. 6, pp 45 - 67, septiembre 2011.
- [19] A.J. Rowan *et al.*, *Conceptos básicos sobre EEG*, Elsevier, Primera Edición, Madrid, pp. 1, 2004.
- [20] S.G. Waxman *et al.*, *Neuroanatomía clínica*, Mc Graw Hill, London, Vigésimo sexta edición, pp. 132-136, 2011.
- [21] B. Kolb *et al.*, *Fundamentals of Human Neuropsychology*, Worth Publishers, 6th edition, pp. 1-20, 2008.
- [22] G.S. Mas, *Fundamentos de Neurociencias*, Editorial UOC, Primera Edición, pp.62-63, 2007.

- [23] G. Buzsáki, *Rhythms of the Brain*, Oxford university press, New York, pp. 1-15, 2006.
- [24] S. Sanei *et al.*, *EEG Signal Processing Chichester*, Editorial John Wiley & Sons Inc. , England, pp. 10-19, 2007.
- [25] J. Barchiesi, *Introducción al Procesamiento Digital de Señales*, Ediciones Universitarias Valparaíso, Chile, pp.13, 2008.
- [26] Windows, <http://www.mathworks.com/help/signal/windows.html>, enero del 2015.
- [27] M. Shen *et al.*, *Detection of dynamic rhythms of electroencephalography by using wavelet packets decomposition*, Proceedings of the 23rd annual EMBS International Conference, Vol. 2 pp. 687-1094, 2001.
- [28] L. Sun *et al.*, *Analysis of non-stationary electroencephalogram using the wavelet transformation*, Signal Processing, 2002 6th International Conference on, Vol. 2, pp. 1520-1523, Agosto 2002.
- [29] D.M. Ballesteros, *Aplicación de la transformada wavelet en la descomposición temporal-frecuencial de señales de electroencefalografía*, umbral Científico, No.3, pp. 82-86, diciembre del 2003.
- [30] C. S. Burrus *et al.*, *Introduction to Wavelets and Wavelets Transforms A Primer*, Editorial Prentice Hall, pp. 1-18, 1998.
- [31] W. Smith, *The Scientist and Engineer's Guide to Digital Signal Processing*, California Technical Publishing, pp. 225-238, 1999.
- [32] C. Brunner *et al.*, *Spatial filtering and selection of optimized components in four class motor imagery EEG data using independent components analysis*, Elsevier Pattern Recognition Letters, Vol. 28, Issue 8, pp. 957-964, Junio, 2007.
- [33] Variance-Covariance Matrix, <http://stattrek.com/matrix-algebra/covariance-matrix.aspx>, febrero 2016.
- [34] A.T. Boye, *Identification of movement-related cortical potentials with optimized spatial filtering and principal component analysis*, Biomedical Signal Processing Control, Vol. 3, Issue 4, pp. 300-304, October 2008.
- [35] D. Peña, *Análisis de Datos Multivariantes*, Editorial McGraw-Hill/Interamericana de España, pp. 137-171, 2002.

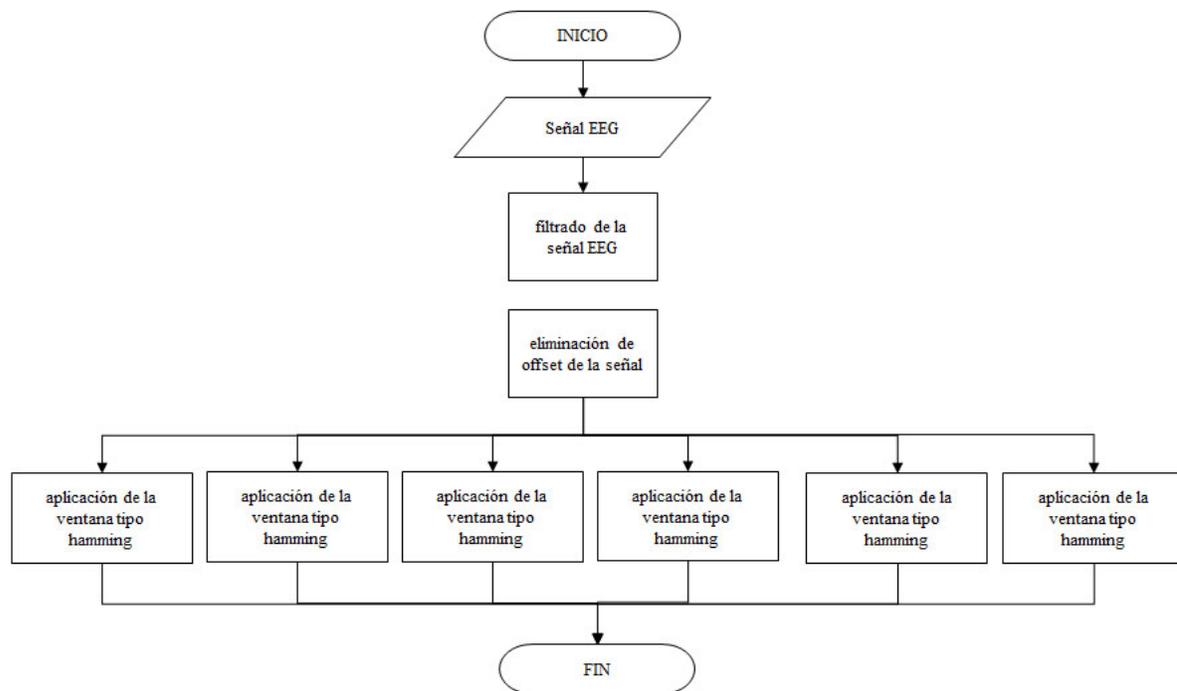
- [36] B. M. Skapura *et al.*, *Neural Networks, Algorithms Applications and Programming Techniques*, Addison-Wesely, pp. 137-171, 1990.
- [37] S. Waldent *et al.*, *Hand Movement Direction Decoded from MEG and EEG*, The journal of neurosciencie, 23 de junio, 2008.
- [38] N. robinson *et al.*, *EEG-Based Classification of Fast and Slow Hand Movements Using Wavelet-CSP Algorithm*, IEEE Transactionss on Biomedical Engineering, Vol. 60, Issue 8, pp. 2123-2132, agosto 2013.
- [39] P. He *et al.*, *Removal of ocular artifacts from electro-encephalogram by adaptive filtering*, Medical and Biological Engineering and Computing, Vol. 42, Issue 3, pp. 407-412, mayo 2004.
- [40] E. Cinar *et al.*, *New classification techniques for electroencephalogram (EEG) signals and a real-time EEG control of a robot*, Neural Comput & Applic, Vol. 22, Issue 1, pp. 29-39, enero 2013.
- [41] L. Vézard *et al.*, *EEG classification for the detection of mental states*, Applied Soft Computing, pp. 113-132, febrero 2015.
- [42] D. Caldwell *et al.*, *Electroencephalographic and eye movement patterns during sleep in chronic schizophrenic patients*, Electroencephalography and Clinical Neurophysiology, Vol. 22, Issue 5, pp. 414, 420, mayo 197.
- [43] F. Lee *et al.*, *Characterization of four-class motor imagery EEG data for the BCI-competition 2005*, J Neural Eng., diciembre 2005.
- [44] E. Lalor *et al.*, *Steady-state VEP-based brain-computer interface control in an immersive 3D gaming environment*, EURASIP Journal on Applied Signal Processing. 2005, pp. 3156-3164, octubre 2004.
- [45] P. Lin *et al.*, *Exploration of computational methods for classification of movement intention during human voluntary movement from single trial EEG*, Clinical neurophysiology, Vol. 118, issue 12, pp. 2637-2655 December 2007.
- [46] S. Lemm *et al.*, *Probabilistic modeling of sensorimotor mu-rhythms for classification of imaginary hand movements*, IEEE Trans Biomed Engineering, pp. 1077-1080, junio 2004.
- [47] A. Subasi, *EEG signal classification using wavelet feature extraction and a mixture of expert model*, Expert System with Application, Vol. 32, Issue 4, pp. 1084-1093, mayo 2007.

- [48] H. Lee, *PCA+HMM+SVM for EEG pattern classification*, Signal Processing and its Applications, Vol. 1, pp. 541-544, julio 2003.
- [49] H. Lee *et al.*, *PCA-based linear dynamical systems for multichannel EEG classification*, Neural information Processing, Vol. 2, pp. 745-749, noviembre 2002.
- [50] Y. Wang *et al.*, *BCI competition 2003-data set IV: An algorithm based on CSSD and FDA for classifying single-trial EEG*, IEEE Transactions on Biomedical Engineering, Vol. 51, Issue 6, pp. 1081-1086, junio 2004.
- [51] N. Hazarika *et al.*, *Classification of EEG signals using the wavelet transform*, Digital Signal Processing Proceedings, Vol. 1, pp.. 89-92, julio 1997.
- [52] S. Valipour, *Spectral analysis of EEG signal for detection of alpha rhythm with open and closed eyes*, International Journal of Engineering and Innovative Technology (IJEIT), Vol. 3, Issue 6, diciembre, 2013.
- [53] Promedio de una señal, <http://www.mathworks.com/help/matlab/ref/mean.html>, 2016.
- [54] A. Khasnobish *et al.*, *A two-fold classification for composite decision about localized arm movement from EEG by SVM and QDA techniques*, Neural Networks (IJCNN), The International Joint Conference on, pp. 1344-1351, Julio 31 - Agosto 5, 2011.
- [55] M. Engin *et al.*, *The classification of human tremor signals using artificial neural network*, Expert Systems with Applications, Vol. 33, Issue 3, pp. 754-761, Octubre 2007.
- [56] T. Gandhi *et al.*, *A comparative study of wavelet families for EEG signal classification*, Neurocomputing, Vol. 74, Issue 17, pp. 3051-3057, octubre, 2011.
- [57] C. S. Burrus *et al.*, *Introduction to Wavelets and Wavelets Transforms A Primer*, Editorial Prentice Hall, pp. 1-18, 1998.
- [58] T Gandhi, *A comparative study of wavelet families for EEG signal classification*, Neurocomputing, Vol. 74, Issue 17, pp. 3051-3057, junio 16, 2011.
- [59] M. Alomari *et al.*, *EEG-Based Classification of Imagined Fists Movements using Machine Learning and Wavelet Transform Analysis*, International of Advancements in Electronics and Electrical Engineering, Vol.3, Issue 3, septiembre, 2014.
- [60] J. Ramirez *et al.*, *A motor imagery BCI experiment using wavelet analysis and spatial patterns feature extraction*, Engineering Applications (WEA), 2012 Workshop on, Mayo 2012.

- [61] M. Alomari *et al.*, *Wavelet Energy based Neural Fuzzy Model for Automatic Motor Imagery Classification*, International Journal of Computer Applications, Vol.28, No. 7, agosto 2011.
- [62] Y. Sheng, *Transforms and Applications Handbook*, Tercera Edición, CRC Press, pp. 10-25, 1996.
- [63] Ricardo Fabbri *et al.*, 2D Euclidean distance transform algorithms: A comparative survey, *Jurnal ACM Computing Surveys (CSUR)*, Vol. 40 Issue 1, febrero 2008.
- [64] H. Vega, *Least squares for different experimental cases*, *Revista Mexicana de Física* Vol. 35, No. 4, pp. 597-602, 1989.
- [65] Sensitivity and specificity, <http://ceaccp.oxfordjournals.org/content/8/6/221.full>, enero del 2015.
- [66] Classification confusion matrix, <http://www.mathworks.com/help/nnet/ref/confusion.html>, enero del 2015.
- [67] C. Miller *et al.*, *Matemática: Razonamiento y Aplicaciones*, Décima edición, Addison Wesley, pp. 759-770.
- [68] Niedermeyer, E. *Alpha-like rhythmical activity of the temporal lobe*, *Clinical EEG (electroencephalography)*, 1990, vol. 21, no 4, p. 210-224.
- [69] *Redes Neuronales de la teoría a la práctica*, <https://www.mql5.com/es/articles/497>, 2016.

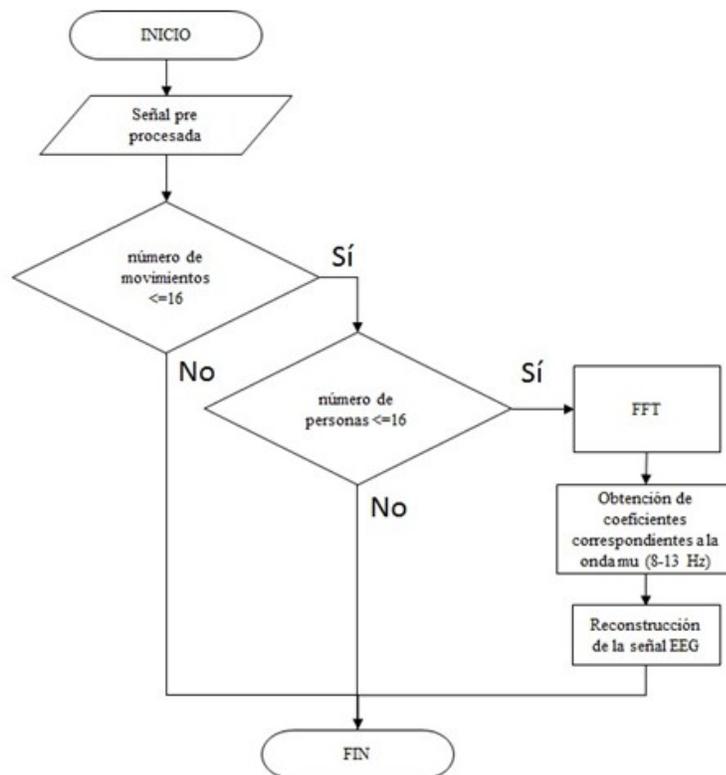
Apéndice

A.1 *Preprocesamiento de la señal EEG*

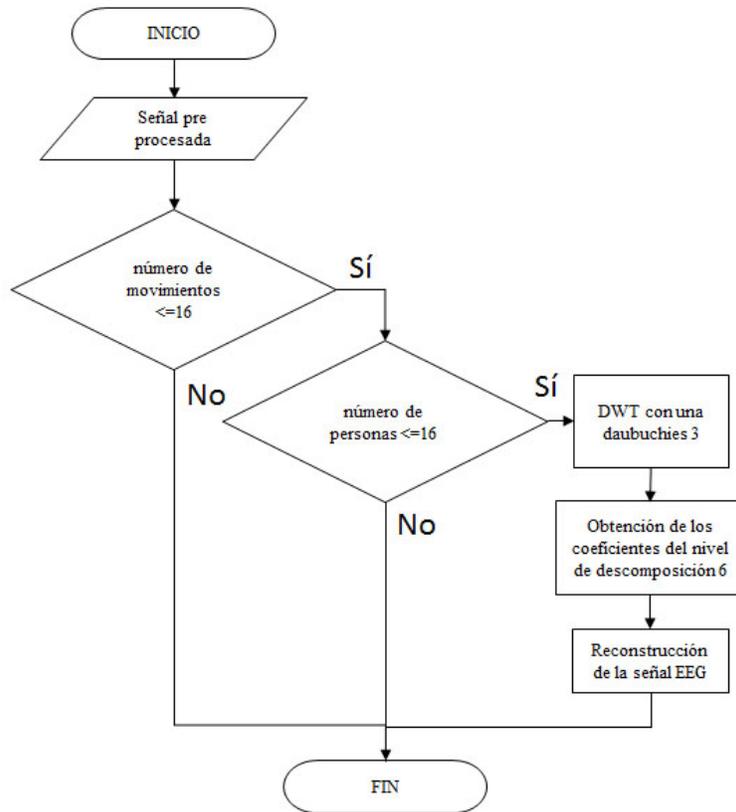


A.2 *Procesamiento de la señal EEG*

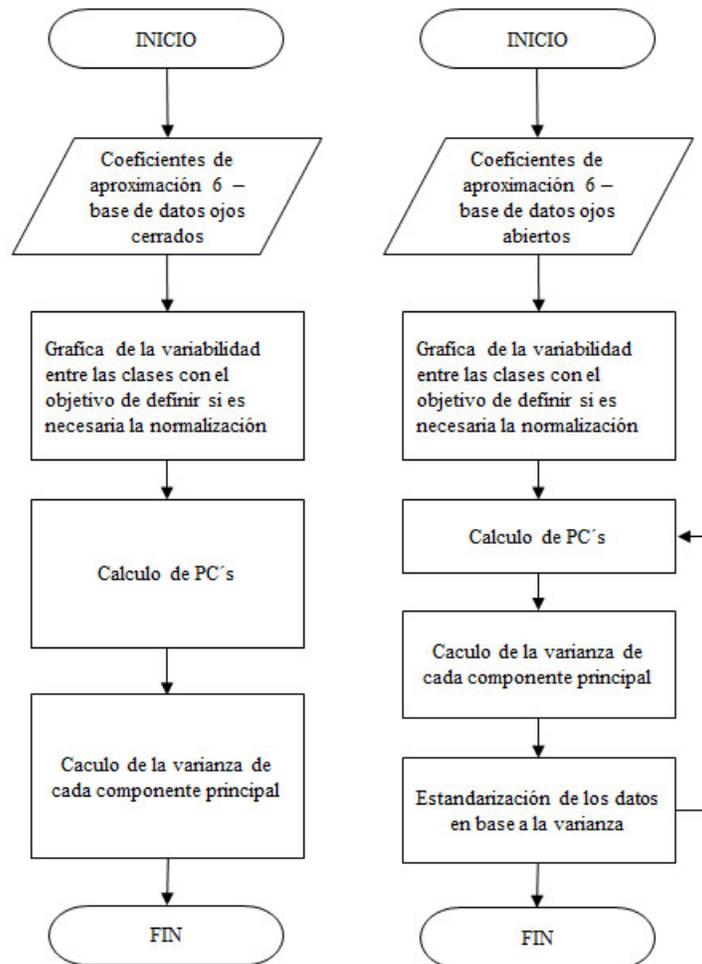
A.2.1 *FFT*



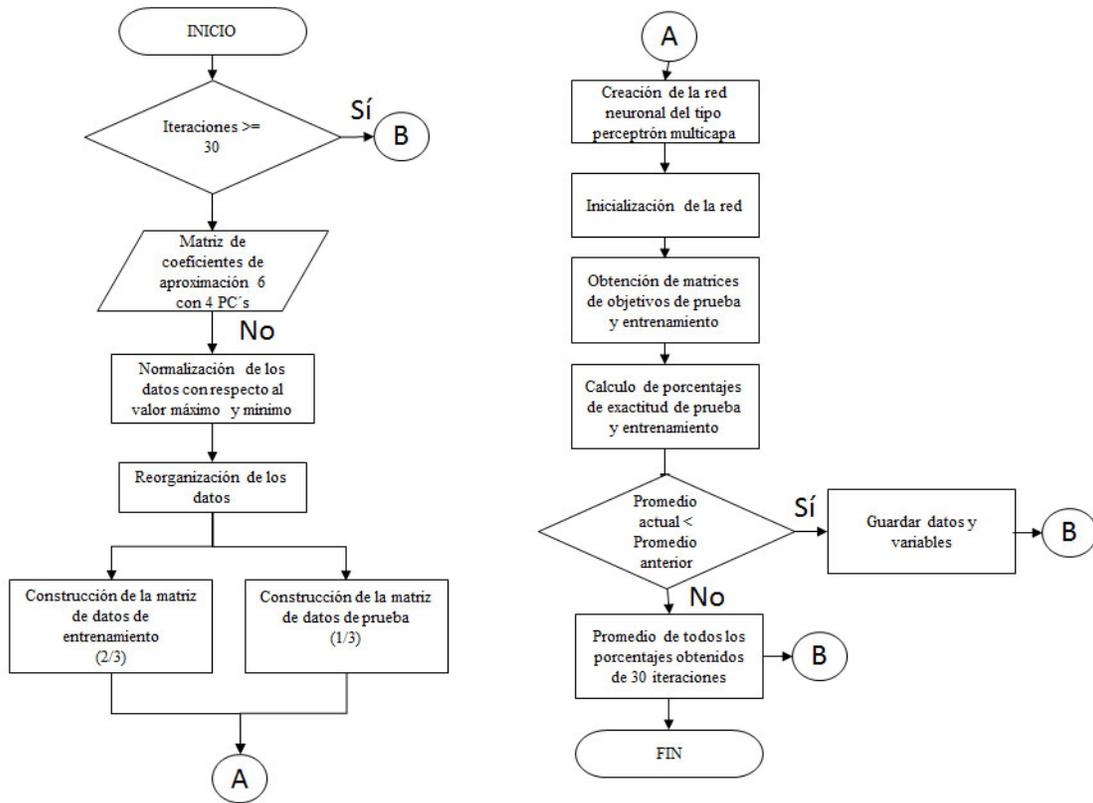
A.2.2 DWT



A.2.3 DWT+PCA



A.2.4 RNA



A.3 Distancias Euclidianas

Tabla A.1 Distancias euclidianas de la señal original y la señal reconstruida para 9 niveles de descomposición y 16 sujetos de prueba.

nivele \ sujeto	1	2	3	4	5	6	7	8	9
1	1E-15	4E-15	1E-14	1E-14	3E-14	6E-14	6E-14	7E-14	7E-14
2	6E-16	2E-15	8E-15	2E-14	4E-14	8E-14	7E-14	7E-14	8E-14
3	5E-16	2E-15	6E-15	1E-14	3E-14	7E-14	6E-14	7E-14	7E-14
4	6E-16	2E-15	7E-15	1E-14	4E-14	7E-14	7E-14	7E-14	8E-14
5	6E-16	2E-15	7E-15	1E-14	3E-14	8E-14	1E-13	1E-13	2E-13
6	6E-16	2E-15	7E-15	1E-14	3E-14	7E-14	1E-13	1E-13	2E-13
7	1E-15	5E-15	1E-14	2E-14	3E-14	8E-14	1E-13	2E-13	4E-13
8	1E-15	5E-15	1E-14	2E-14	3E-14	7E-14	1E-13	1E-13	2E-13
9	1E-15	5E-15	1E-14	1E-14	3E-14	8E-14	1E-13	1E-13	2E-13
10	7E-16	3E-15	8E-15	2E-14	4E-14	8E-14	8E-14	9E-14	9E-14
11	6E-16	2E-15	7E-15	1E-14	3E-14	6E-14	1E-13	1E-13	2E-13
12	8E-16	3E-15	8E-15	1E-14	4E-14	7E-14	8E-14	9E-14	9E-14
13	7E-16	3E-15	9E-15	2E-14	4E-14	8E-14	7E-14	8E-14	8E-14
14	6E-16	2E-15	7E-15	1E-14	4E-14	8E-14	7E-14	8E-14	8E-14
15	5E-16	2E-15	7E-15	1E-14	4E-14	7E-14	7E-14	7E-14	8E-14
16	5E-16	2E-15	6E-15	1E-14	2E-14	6E-14	1E-13	1E-13	2E-13

A.4 Porcentajes de Exactitud de la combinación de distintas herramientas

Tabla A.2: Porcentajes de exactitud (PE) de la clasificación con respecto a las ventanas.

DWT/ojos cerrados	Segmento 1		Segmento 2		Segmento 3	
	PE(%)	Tiempo(s)	PE(%)	Tiempo(s)	PE(%)	Tiempo(s)
Ventana	PE(%)	Tiempo(s)	PE(%)	Tiempo(s)	PE(%)	Tiempo(s)
Hamming	95.8269	36.72	94	46.599	96.6154	31.7526
Hanning	96.5769	36.8213	94.1923	32.2548	94.3846	32.4689
Blackman	95.3077	38.5777	94.9692	36.6864	92.3462	44.4125
Chebwin	92.4038	43.61	88.3846	51.9972	93.0577	35.73
Kaiser	98.5385	29.4062	97.1323	39.4645	95.9038	35.3559
Barthannwin	95.25	39.61	95.5	38.7283	95.4808	38.8234
DWT/ojos abiertos	Segmento 1		Segmento 2		Segmento 3	
	PE(%)	Tiempo(s)	PE(%)	Tiempo(s)	PE(%)	Tiempo(s)
Ventana	PE(%)	Tiempo(s)	PE(%)	Tiempo(s)	PE(%)	Tiempo(s)
Hamming	92.8846	41.622	89.8269	46.4605	94.4231	42.5812
Hanning	87.2308	89.6073	90.2885	39.19	95.3846	42.9028
Blackman	91.9808	50.396	79.75	123.07	93.8077	38.338
Chebwin	92.4423	45.7547	87.1538	56.072	83.3208	156.2125
Kaiser	94.8269	47.2595	93.1154	46.386	95.1538	42.0775
Barthannwin	94.0385	45.284	94.2692	48.7422	94.9615	41.515
FFT/ojos cerrados	Segmento 1		Segmento 2		Segmento 3	

Ventana	PE(%)	Tiempo(s)	PE(%)	Tiempo(s)	PE(%)	Tiempo(s)
Hamming	93.4167	49.5047	92.7083	45.2531	93.1042	43.8804
Hanning	91.5625	44.9368	91.3542	53.98	94.1042	40.5183
Blackman	92.1042	48.5607	92.375	40.7821	95.1042	43.7215
Chebwin	90.4167	45.0352	96.2292	41.6629	93.4792	37.2842
Kaiser	94.7292	45.4387	91.25	49.32	94.0625	39.9332
Barthannwin	96.2292	34.779	95.3453	43.2355	94.4363	40.353
FFT/ojos abiertos	Segmento 1		Segmento 2		Segmento 3	
Ventana	PE(%)	Tiempo(s)	PE(%)	Tiempo(s)	PE(%)	Tiempo(s)
Hamming	88.25	73.98	92.5833	52.9255	92.4375	64.23
Hanning	93.125	38.6249	90.9167	50.9037	92.1875	48.8131
Blackman	90.8333	39.4344	93.4583	48.2427	90.75	40.389
Chebwin	92.1042	47.2481	88.75	55.8	93.2292	43.3286
Kaiser	94.123	39.2348	92.5639	45.346	93.9923	43.4645
Barthannwin	91.625	48.5188	91.3735	45.578	91.5	43.012
DWT+PCA/ojos cerrados	Segmento 1		Segmento 2		Segmento 3	
Ventana	PE(%)	Tiempo(s)	PE(%)	Tiempo(s)	PE(%)	Tiempo(s)
Hamming	96.1012	34.242	97.4167	30.5047	97.352	36.599
Hanning	97.223	35.2445	94.1635	38.9368	96.1923	32.2548
Blackman	95.778	38.2123	97.3442	38.5607	95.9887	36.6864
Chebwin	95.2342	37.2435	93.8167	41.0352	97.6846	35.9972

Kaiser	97.3421	32.4545	98.7292	42.4887	97.1323	39.4645
Barthannwin	94.2352	34.4643	97.2292	39.772	95.5	40.452
DWT+PCA/ ojos abier- tos	Segmento 1		Segmento 2		Segmento 3	
Ventana	PE(%)	Tiempo(s)	PE(%)	Tiempo(s)	PE(%)	Tiempo(s)
Hamming	96.1842	38.956	96.0367	38.935	94.352	37.2343
Hanning	96.123	39.345	95.1635	44.234	96.1923	33.5326
Blackman	93.2351	42.446	93.5442	47.234	95.9887	37.2344
Chebwin	91.9823	50.123	91.4513	69.45	94.146	43.235
Kaiser	97.3421	32.1454	97.9292	35.234	97.1323	36.234
Barthannwin	92.2352	45.342	94.192	38.245	92.1234	57.2343

A.5 Formatos

ESTUDIO ENCEFALOGRÁFICO (EEG)

DATOS GENERALES.		
SECCIÓN A. INFORMACIÓN PERSONAL		
Apellido del padre.	Apellido de la madre.	
Nombre (s).	Género. <input type="checkbox"/> Femenino <input type="checkbox"/> Masculino	Edad.
Peso.	Estatura.	
SECCIÓN B. INFORMACIÓN PATOLÓGICA		
Instrucciones. Marca con una "✓" las patologías que presentas, marca con una "X" si alguna vez las has presentado y deja el espacio en blanco si nunca la has presentado.		
Accidente Vascular Cerebral	Hipoxia cerebral	
Enfermedad de Parkinson	Miastenia Gravis	
Cefaleas (Dolor de cabeza)	Neuropatía Periférica	
Distrofia muscular	Parestesia	
Epilepsia	Síndrome de Asperger	
Traumatismo Cerebral	Síndrome de Guillain-Barré	
Autismo	Síndrome de las Piernas Inquietas	
Convulsiones Febriles	Tumores	
Enfermedad de Meniere	Tinnitus	
Parálisis cerebral	Parkinson	
Espina bífida	Vértigo	
Esclerosis Lateral Amiotrófica	Otra (describe).	
Hidrocefalea		
SECCIÓN C.		
Instrucciones marca con una "X" y/o responde con palabras las siguientes preguntas:		
¿Te cuesta trabajo conciliar el sueño?	Sí — No —	¿Cuántas horas duermes por día?
¿Presentas irritabilidad?	Sí — No —	
¿Presentas histeria?	Sí — No —	
¿Presentas estrés frecuentemente?	Sí — No —	
¿Fumas?	Sí — No —	¿Cuántos cigarrillos por día?
¿Bebes alcohol?	Sí — No —	¿Cada cuándo?
¿Has sufrido una operación cerebral?	Sí — No —	¿Cuál y por qué?

INDICACIONES.

Acuda con el cabello recién lavado, limpio y seco, sin productos capilares. Procure acudir sin joyería o reducir esta al máximo posible. Tome su medicación habitual con normalidad. Realice las comidas habituales. Haber dormido mínimo 6hrs el día anterior, no haber ingerido bebidas alcohólicas una noche anterior al registro.

México, Distrito Federal, 25 mayo 2015

REGISTRO ENCEFALOGRÁFICO

El registro encefalográfico (EEG) es con fines de investigación. Lo que se desea estudiar en esta investigación es el comportamiento de las ondas cerebrales al realizar diversos movimientos de brazos.

Se realizará con una tarjeta de adquisición para EEG aislada, una laptop aislada y con electrodos no invasivos. El sujeto de prueba deberá permanecer en un estado de reposo sentado con ojos abiertos y cerrados, en un ambiente controlado. Este registro se llevará a cabo en un ambiente controlado.

El registro EEG consiste en que el sujeto de prueba siga los movimientos de brazo de un video que será reproducido desde un monitor, en cada cambio de movimiento se reproducirá un beep.

En total desde que se empieza con la colocación de los electrodos hasta que se retiran por completo dura unos **40-50 minutos**. Al finalizar el registro, tras retirar completamente los electrodos, puede quedar algún residuo de pasta conductora sobre el cuero cabelludo que se eliminará por completo con un simple lavado de cabeza.

Nombre y firma de la persona que realizará los registros.

Nombre y firma del voluntario